



UNIVERSIDAD
DE LA REPUBLICA



MEJORAS EN EL SISTEMA DE PRONÓSTICOS HIDROLÓGICOS POR ENSAMBLES DEL SIMULADOR DEL SISTEMA ELÉCTRICO EN URUGUAY

Alejandra De Vera

Tutor: Dr. Ing. Rafael Terra

Tesis de Doctorado presentada al Programa de Posgrado en
Ingeniería - Mecánica de los Fluidos Aplicada

Facultad de Ingeniería
Universidad de la República

Montevideo, Uruguay
Diciembre de 2023

INTEGRANTES DEL TRIBUNAL DE DEFENSA DE TESIS

Dr. Gonzalo Casaravilla

(IIE, Facultad de Ingeniería, Universidad de la República, Uruguay)

Dr. Gabriel Cazes

(IMFIA, Facultad de Ingeniería, Universidad de la República, Uruguay)

Dr. Walter Collischonn

(IPH, Universidad Federal de Rio Grande do Sul, Brasil)

Dr. Malaquías Peña

(Departamento de Ingeniería Civil y Ambiental, Universidad de Connecticut,
Estados Unidos)

Agradecimientos

A Rafael Terra, tutor de este trabajo, por su gran dedicación y compromiso. Gracias por confiar en mí y guiar mi desarrollo académico desde mis primeros pasos en el IMFIA. Gracias por la continua motivación.

A la Administración del Mercado Eléctrico (ADME) por el apoyo al desarrollo de esta línea de trabajo y por brindar los datos necesarios para la ejecución de esta tesis. En especial a Ruben Chaer, por su confianza y continuo entusiasmo por promover nuevos desarrollos, y a Guillermo Flieller por su disposición y ayuda a lo largo de todos estos años.

A la Agencia Nacional de Investigación e Innovación (ANII), por el apoyo económico brindado para la realización de las estadías de investigación en la Universidad de Buenos Aires (UBA).

A Juan Ruiz, profesor del Departamento de Ciencias de la Atmósfera y los Océanos (DCAO) de la Facultad de Ciencias Exactas y Naturales (FCEN-UBA), por el tiempo dedicado y la orientación brindada durante las estadías en dicha institución, de las cuales surgieron aportes valiosos para este trabajo de tesis.

A mis compañeros del IMFIA, por su apoyo y aliento tanto en aspectos técnicos como personales. Gracias por la compañía en el día a día. En especial a Mane, porque juntas transitamos las etapas iniciales del desarrollo del sistema de pronósticos hidrológicos.

A mi familia y amigos, por su inmenso cariño, interés y aliento continuo. Gracias por estar siempre presentes.

A Pablo y Franquito, mis pilares fundamentales, por su paciencia, comprensión y apoyo incondicional a lo largo de todo este trayecto.

¡Muchas gracias!

Esta tesis se desarrolló en el marco de diversos convenios de asesoramiento técnico con la Administración del Mercado Eléctrico (ADME) y del proyecto de cooperación regional "CYAN: Climate dynamics analysis from Data" del programa CLIMAT AMSUD otorgado por la Agencia Nacional de Investigación e Innovación (ANII).

Resumen

A lo largo de este trabajo de tesis se proponen diferentes desarrollos metodológicos buscando mejorar el desempeño de un sistema operativo de pronósticos hidrológicos por ensambles acoplado con la simulación del sistema eléctrico de Uruguay, que permite optimizar la operación del sistema y definir el despacho energético. La cuenca de estudio es la cuenca de aporte al Río Negro, cuenca transfronteriza con Brasil, con una extensión superficial de 62.900 km² y en cuyo cauce principal se ubican tres centrales hidroeléctricas en serie.

La estrategia seguida se basa en tres enfoques: (i) una evaluación exhaustiva de los pronósticos hidrometeorológicos por ensambles; (ii) la asimilación de datos observados de caudal; (iii) mejoras en la representación de la incertidumbre asociada a los pronósticos por ensambles de precipitación.

En primer lugar, se desarrolla una metodología para la evaluación de la calidad de los pronósticos por ensambles de precipitación y caudal generados para la cuenca del Río Negro desde la puesta en operación del modelo. Dicha metodología combina indicadores de desempeño y gráficos de diagnóstico, de manera de abarcar diferentes aspectos de la calidad del pronóstico, en este caso el sesgo, la precisión y la confiabilidad. La metodología desarrollada se aplicó a: (i) ensambles de precipitación a quince días del modelo GEFS (versión V12) del NCEP-NOAA (empleados como forzantes del modelo hidrológico), tomando como referencia una estimación en base a la combinación de imágenes satelitales y observaciones en superficie; (ii) ensambles de los caudales de aporte a las centrales hidroeléctricas obtenidos con el modelo hidrológico GR4J forzado por los pronósticos del GEFS, en comparación con las series teóricas de aportes que surgen de un balance hídrico en los embalses. Tanto para la precipitación como para los caudales, se llegó a que las series simuladas capturan satisfactoriamente el comportamiento de las series observadas. En ambos casos se identificaron sesgos positivos en el error de la media del ensamble (tendencia a la sobreestimación), a la vez que se observó una asimetría negativa en su distribución. Durante los primeros días del horizonte de pronóstico el ensamble tiene una dispersión excesivamente baja, de modo que la observación está demasiado a menudo fuera del rango del ensamble; luego, a medida que avanza el horizonte de pronóstico, el ensamble tiende a estar mejor distribuido. Este aspecto es aún más notorio en el caso de los caudales.

Posteriormente, se propone una metodología para la asimilación al modelo hidrológico de datos observados de caudal, la cual puede ser implementada de manera operativa con la información disponible actualmente. Dicha metodología se aleja conceptualmente de los diseños tradicionales de relajación o “nudging” de datos observados a sistemas de pronóstico. En el caso de estudio, la variable observada disponible no es un estado sino una salida del modelo (caudal), por lo

que no puede ser ajustada directamente. Por tanto, en la asimilación que se instrumentó el ajuste se plantea como una corrección de la precipitación antecedente (forzante que representa la mayor fuente de incertidumbre del proceso de modelación) hasta el día de inicio del pronóstico, proporcional a la amplitud del error relativo del caudal simulado. Dicha corrección produce estados del sistema y condiciones iniciales del caudal para el periodo de pronóstico hidrológicamente consistentes. En particular, el ajuste se implementó en tres subcuencas de aporte al embalse de G. Terra (el primero, desde aguas arriba hacia aguas abajo, de los tres embalses localizados consecutivamente sobre el Río Negro). La metodología de asimilación propuesta reduce significativamente el error al inicio del pronóstico, en comparación con el desempeño del modelo hidrológico sin retroalimentación. Sin embargo, para caudales bajos (muy frecuentes en el periodo analizado), no logra corregir el marcado sesgo positivo existente en el modelo original. El desempeño es muy sensible a los “saltos” y limitaciones particulares identificadas en la serie teórica de aportes a G. Terra. La mejora se atenúa a medida que se avanza en el horizonte de pronóstico.

Por último, se establecen las bases de una metodología para mejorar el desempeño del pronóstico por ensambles de precipitación en la cuenca del Río Negro. En particular, se busca mejorar la representación de la incertidumbre que enfrenta el sistema en el horizonte inmediato. A los efectos de explorar metodologías en un modelo más simple que los atmosféricos, se recurrió al modelo Lorenz 63 con asimilación de datos mediante el método EnKF. Allí se evaluaron distintas técnicas para la ponderación de miembros del ensamble según su desempeño reciente, que luego se aplicaron al pronóstico por ensambles de precipitación. Se propuso entonces una técnica simple basada en la construcción de super-ensambles mediante la combinación de “time-lagged ensembles” (múltiples pronósticos inicializados en diferentes momentos, pero todos verificados al mismo tiempo), que incorpora las últimas observaciones (locales) disponibles a través de una ponderación de los miembros en función de su habilidad reciente. La construcción de los super-ensambles equiprobables (sin pesos diferenciales) demostró una mejora en la distribución sin deteriorar el RMSE, lo que se traduce en una mejora de la relación SPREAD/RMSE. Sin embargo, la incorporación de los pesos según el error en el campo de precipitación integrado en la cuenca no resultó en una mejora en los estadísticos evaluados. Este resultado pone de manifiesto la importancia de la selección de una métrica adecuada (más integral y representativa del estado atmosférico) para el cálculo de la habilidad reciente para definir las ponderaciones de los miembros del ensamble.

Palabras clave: Modelación hidrológica; pronóstico por ensambles; incertidumbre, modelo operacional; generación hidroeléctrica; simulación del sistema eléctrico.

Abstract

In this thesis we propose different methodological developments in order to improve the performance of an operational hydrological ensemble prediction system coupled with an electric system modeling for Uruguay, used for management, optimization and dispatch. The study area is the Río Negro basin, a transboundary watershed (Uruguay/Brazil), with a surface equal to 62.900 km². Three hydroelectric plants are located in series in its main channel.

The strategy is based on three approaches: (i) a comprehensive evaluation of the hydrometeorological ensemble forecasts; (ii) the assimilation of observed streamflow data; (iii) improvements in the representation of the uncertainty associated with the precipitation ensemble forecasts.

First, we develop a methodology to evaluate the quality of the ensemble forecasts of precipitation and streamflow generated for the Río Negro basin since the model is operational. This methodology combines performance indicators and diagnostic graphs, in order to cover different aspects of the forecast quality, in this case the bias, precision and reliability. The methodology was applied to: (i) the 15-day ensemble precipitation forecasts from the GEFS V12 model (NCEP-NOAA), taking as reference an estimation based on the combination of satellite retrievals and rain gauge data; (ii) the ensemble forecasts of the daily inflows to the hydroelectric reservoirs obtained with the GR4J hydrological model forced by the GEFS ensembles, in comparison with the “theoretical” inflows derived from a reservoir mass budget. Results suggest that, for both precipitation and hydrological inflows, the ensemble forecasts achieve a good representation of the observed series. In both cases, the ensemble mean error presents a positive bias (tendency for overestimation), while a negative asymmetry was identified in its distribution. During the first days the ensemble has an excessively low dispersion, the observation is too often outside the range of the ensemble. As the forecast lead time advances, the ensemble tends to be better distributed. This behavior is even more pronounced for the hydrological inflows.

Subsequently, we propose a methodology for the assimilation of observed streamflow data into the hydrological model, which can be operationally implemented with the information currently available. This methodology conceptually departs from traditional relaxation or “nudging” of observed data into forecast systems. In this case, the available observed variable is not a state but an output of the model (streamflow), so it cannot be adjusted directly. Therefore, in the assimilation scheme that was implemented, the adjustment is proposed as a correction of the antecedent precipitation (forcing that represents the greatest source of uncertainty in the modeling process) until the start of the forecast, proportional to the amplitude of the relative error of the simulated streamflow. Such correction produces system states and initial flow conditions

for the forecast period which are hydrologically consistent. In particular, the adjustment was implemented in three sub-basins contributing to the G. Terra reservoir (the first, from upstream to downstream, of the three reservoirs located on the Río Negro). The proposed methodology significantly reduces the error at the beginning of the forecast, compared to the performance of the hydrological model without data assimilation. However, for low flows (very frequent in the period analyzed), it fails to correct the marked positive bias existing in the original model. Performance is very sensitive to the “jumps”, a limitation identified in the theoretical inflows series to G. Terra. The improvement attenuates as the forecast lead time advances.

Finally, we set the stage for a methodology to improve the performance of the ensemble precipitation forecast in the Río Negro basin. In particular, it aims to improve the representation of the uncertainty faced by the system in the immediate horizon. In order to explore methodologies in a simpler model than the atmospheric ones, we used the Lorenz 63 model with data assimilation based on the Ensemble Kalman Filter (EnKF) method. There, we evaluated different techniques for the weighting of the ensemble members according to their recent performance, which were then applied to the ensemble precipitation forecasts. A simple technique was proposed based on the construction of super-ensembles by combining “time-lagged ensembles” (multiple forecasts initiated at different times, but all verified at the same time), which incorporates the latest available (local) observations through a weighting of the members based on their recent ability. The construction of the equiprobable super-ensembles (without considering differential weights) demonstrated an improvement in the distribution without deteriorating the RMSE, which translates into an improvement in the SPREAD/RMSE ratio. However, the incorporation of the weights according to the error in the integrated precipitation field in the basin did not result in an improvement in the evaluated statistics. This result highlights the importance of selecting an appropriate metric (more comprehensive and representative of the atmospheric state) for the calculation of the recent ability in order to define the weights of the ensemble members.

Key words: Hydrological modeling; ensemble forecasting; uncertainty, operational modeling; hydropower generation; electric system modeling.

ÍNDICE

1. INTRODUCCIÓN.....	1
1.1 CONTEXTO.....	1
1.2 OBJETIVOS.....	3
1.2.1 Generales.....	3
1.2.2 Específicos	4
1.3 CONTENIDO	5
2. DESCRIPCIÓN DEL SISTEMA DE PRONÓSTICOS HIDROLÓGICOS POR ENSAMBLES	8
2.1 MARCO TEÓRICO	8
2.2 DESCRIPCIÓN DE LA CUENCA DE ESTUDIO	11
2.3 MODELACIÓN HIDROLÓGICA	13
2.3.1 Descripción del esquema de modelación	13
2.3.2 Información empleada	17
2.4 SIMULACIÓN DEL SISTEMA ELÉCTRICO	22
2.4.1 Modelo SimSEE.....	22
2.4.2 Acople de los ensambles	23
2.5 IMPLEMENTACIÓN OPERATIVA.....	24
2.6 SÍNTESIS.....	27
3. EVALUACIÓN DE LOS PRONÓSTICOS POR ENSAMBLES DE PRECIPITACIÓN Y CAUDAL EN LA CUENCA DEL RÍO NEGRO	30
3.1 DATOS DE REFERENCIA.....	30
3.1.1 Precipitación	30
3.1.2 Caudal.....	31
3.2 METODOLOGÍA DE EVALUACIÓN	34
3.2.1 Precipitación	38
3.2.2 Caudal.....	41
3.3 RESULTADOS.....	43
3.3.1 Precipitación	43
3.3.2 Caudal.....	54
3.4 SÍNTESIS.....	65
4. ASIMILACIÓN DE DATOS OBSERVADOS DE CAUDAL AL MODELO HIDROLÓGICO	70
4.1 MARCO TEÓRICO	70
4.1.1 Generalidades.....	70
4.1.2 Asimilación de datos en modelación hidrológica.....	73
4.2 METODOLOGÍA PROPUESTA	75
4.2.1 Descripción	75
4.2.1 Implementación.....	77
4.3 EVALUACIÓN.....	79
4.3.1 Evaluación retrospectiva	79
4.3.2 Evaluación en modo pronóstico	90
4.4 SÍNTESIS.....	102
5. DESARROLLO DE METODOLOGÍAS DE PONDERACIÓN DE MIEMBROS EN EL MODELO LORENZ 63.....	107
5.1 DESCRIPCIÓN DEL MODELO LORENZ 63	107
5.1.1 Configuración del experimento	109
5.2 METODOLOGÍA GENERAL.....	112

5.3	CARACTERIZACIÓN DE LA EVOLUCIÓN DEL ERROR Y LA DISPERSIÓN DEL ENSAMBLE	113
5.4	METODOLOGÍAS DE PONDERACIÓN DE MIEMBROS	118
5.4.1	Ponderación de miembros.....	118
5.4.2	Aplicación a distintos ciclos de pronóstico	121
5.4.3	Síntesis.....	122
5.5	EVALUACIÓN DE LAS METODOLOGÍAS DESARROLLADAS.....	124
5.6	ANÁLISIS EN FUNCIÓN DE LA POSICIÓN EN EL ATRACTOR DE LORENZ.....	128
5.6.1	Síntesis.....	135
5.7	SÍNTESIS.....	138
6.	APLICACIÓN DE TÉCNICAS DE “TIME-LAGGED ENSEMBLES” AL PRONÓSTICO DE PRECIPITACIÓN DEL MODELO GEFS	143
6.1	MARCO TEÓRICO	143
6.2	EVALUACIÓN DE SUPER-ENSAMBLES EQUIPROBABLES.....	146
6.2.1	Construcción de super-ensambles.....	147
6.2.2	Metodología de evaluación	148
6.2.3	Resultados	148
6.3	INCORPORACIÓN DE PESOS	152
6.3.1	Definición de los pesos	152
6.3.2	Resultados	158
6.4	SÍNTESIS.....	159
7.	CONCLUSIONES Y LÍNEAS FUTURAS DE TRABAJO	164
8.	REFERENCIAS BIBLIOGRÁFICAS.....	172
9.	ANEXO I: DATOS EMPLEADOS PARA LA MODELACIÓN HIDROLÓGICA.....	186
9.1	EVAPOTRANSPIRACIÓN POTENCIAL DIARIA	186
9.2	CAPACIDAD DE ALMACENAMIENTO DE AGUA DE LOS SUELOS	187

ACRÓNIMOS

ADME	Administración del Mercado Eléctrico (Uruguay)
CEGH	Correlaciones en Espacio Gaussiano con Histograma
DINAGUA	Dirección Nacional de Aguas (Uruguay)
EnKF	Filtro de Kalman por ensambles
ETKF	Filtro de Kalman por ensambles determinístico transformado
GEFS	Global Ensemble Forecast System
GR4J	Modèle du Génie Rural à 4 paramètres Journalier (INRAE)
INIA	Instituto Nacional de Investigación Agropecuaria (Uruguay)
INUMET	Instituto Uruguayo de Meteorología (Uruguay)
JAXA	Japan Aerospace Exploration Agency (Japón)
MDT	Modelo Digital del Terreno
MIEM	Ministerio de Industria, Energía y Minería (Uruguay)
NASA	National Aeronautics and Space Administration (EEUU)
NCEP	National Centers for Environmental Prediction (EEUU)
NOAA	National Oceanic and Atmospheric Administration (EEUU)
OMM	Organización Meteorológica Mundial
SimSEE	Simulador de Sistemas de Energía Eléctrica
SIN	Sistema Interconectado Nacional (Uruguay)
SRTM	Shuttle Radar Topographic Mission (NASA)
RK	Estimación de precipitación “Regression Kriging”
TLE	“Time-Lagged Ensembles”
UTE	Administración Nacional de Usinas y Trasmisiones Eléctricas (Uruguay)

CAPÍTULO 1

INTRODUCCIÓN

1. Introducción

1.1 CONTEXTO

La situación del país refleja una creciente presión sobre los recursos naturales, en particular el agua, debido a las transformaciones productivas acaecidas en las últimas décadas, de alto valor económico y estratégico, fundamentalmente en los sectores agropecuario, forestal y energético. Entre otros aspectos, dichas actividades requieren de un continuo monitoreo del recurso hídrico para asegurar su desarrollo sostenible en un contexto de gran variabilidad espacial y temporal de la precipitación, la cual constituye la fuente última de agua. Esta demanda ha transformado la generación de información hidroclimática y su incorporación a la toma de decisión (planificación, elaboración de políticas, etc.) en una línea de investigación en sí misma, que posibilite la gestión de los riesgos asociados a la variabilidad y el cambio climático.

En el caso particular del sector energético, la creciente incorporación de energías renovables en Uruguay (hidroeléctrica, eólica y solar) ha complejizado la operación y el despacho de energía eléctrica por su alto grado de incertidumbre meteorológica. En el panel superior de la Figura 1-1 se presenta la evolución de la generación por fuente (expresada en GWh) en el Sistema Interconectado Nacional (SIN) desde el 2002 al 2022. En el panel inferior, a modo de ejemplo, se muestra la participación por fuente en la generación total del SIN durante el año 2022 (demanda nacional y exportaciones), en el cual la generación con base en fuentes renovables llegó al 90% (incluyendo un 39% de generación hidroeléctrica). Ambas figuras fueron extraídas del “Balance Energético 2022¹” publicado por el Ministerio de Industria, Energía y Minería (MIEM) de Uruguay.

La energía hidráulica, además de contribuir significativamente a la generación, es un recurso almacenable. Por esta razón la previsión de disponibilidad de agua en los embalses de las centrales hidroeléctricas es clave para la planificación del SIN, contribuyendo a optimizar el uso de cada fuente de energía, con el correspondiente beneficio económico y ambiental. En particular, conocer condiciones de abundancia o déficit hídrico con antelación, permite elaborar ofertas de intercambio con Argentina y Brasil, de gran impacto económico para el país.

¹ <https://ben.miem.gub.uy/balance.php>

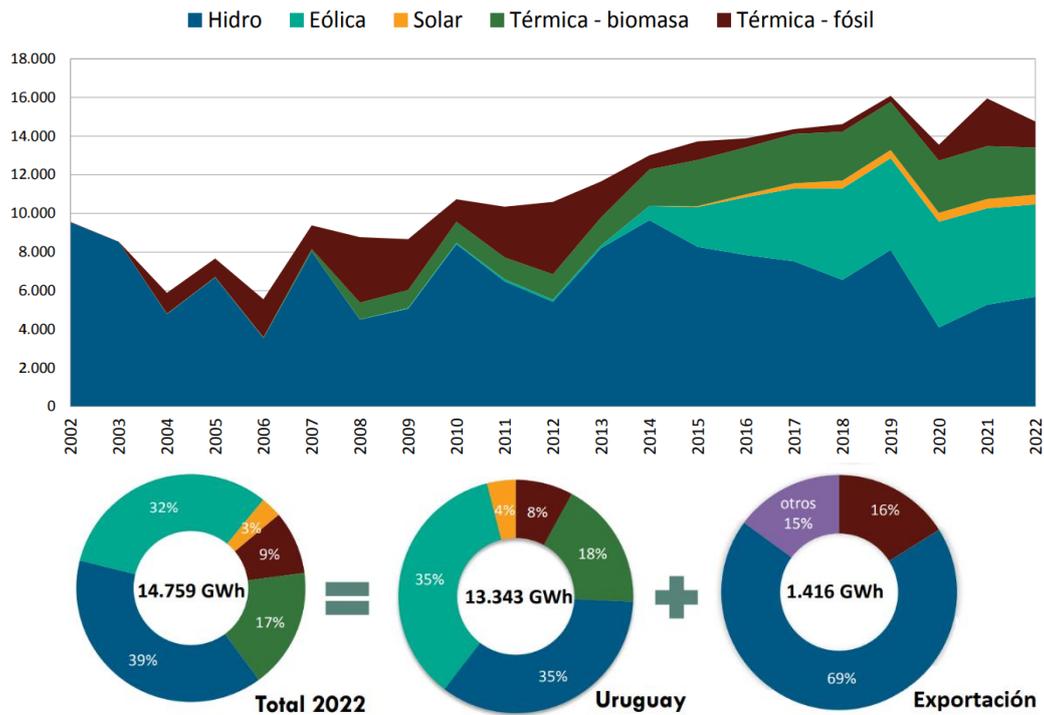


Figura 1-1: Evolución de la generación por fuente (GWh) en el SIN desde el 2002 al 2022 (panel superior) y participación por fuente en la generación total durante el año 2022 (panel inferior). Fuente: Balance Energético 2022, MIEM.

Trabajos previos en Uruguay (Maciel et al., 2012; Maciel et al., 2015) se centraron en la incorporación de información climática asociada al fenómeno El Niño-Oscilación Sur (ENOS) en la simulación de los aportes hidrológicos dentro de los modelos para la gestión del sistema eléctrico con el propósito de informar la planificación energética estacional (escala temporal de varias semanas a seis meses). En el presente trabajo, en cambio, el foco es en la predicción meteorológica a corto y mediano plazo (hasta una o dos semanas) de manera de informar la programación energética semanal.

La realización de previsiones hidrológicas operativas requiere la mejor estimación posible tanto de los parámetros del modelo, como del estado del sistema al inicio del pronóstico (variables de estado del modelo) y de los forzantes meteorológicos. A su vez, la experiencia contemporánea en varias regiones del mundo indica que el empleo de predicciones numéricas de precipitación permite la extensión del horizonte de pronóstico con resultados satisfactorios (Cuo et al., 2011; Troin et al., 2021).

En la actualidad existe cada vez mayor diversidad de herramientas e información disponibles de gran utilidad para la hidrología operativa: (i) datos de redes de monitoreo automáticas y telemétricas; (ii) productos de sensoramiento remoto que brindan estimaciones de variables hidro-meteorológicas con gran resolución espacial y temporal (Hong et al., 2019); (iii) predicción de campos meteorológicos,

en particular precipitación, en base a modelos numéricos de la atmósfera basados en simulaciones por ensambles (Buizza et al., 2019).

En este contexto, desde hace algunos años la Administración del Mercado Eléctrico (ADME) y la Facultad de Ingeniería se encuentran trabajando en el desarrollo de un modelo hidrológico para la simulación de los caudales de aporte a las centrales hidroeléctricas del Río Negro, el cual se encuentra operativo desde el año 2019. La generación de los pronósticos de caudales consta de dos pasos: (i) la estimación de la precipitación ocurrida sobre la cuenca del Río Negro en base a la combinación de imágenes satelitales y observaciones pluviométricas en superficie; (ii) la ejecución de un modelo hidrológico de manera de obtener un ensamble de pronósticos de caudales de aporte a las centrales hidroeléctricas a partir de un ensamble de predicciones numéricas de precipitación. Como resultado, se obtiene un conjunto de pronósticos a catorce días de los caudales de aporte a las centrales hidroeléctricas del Río Negro que ADME incorpora diariamente a la programación de mediano y corto plazo, para luego optimizar la operación del sistema y definir el despacho energético por fuente, los costos de operación y lineamientos para potenciales intercambios.

Hasta la fecha ADME ha tenido una percepción favorable de los resultados obtenidos con el modelo desarrollado, siendo considerado como la fuente de pronóstico por defecto para el despacho energético semanal de la programación de mediano plazo. Esta herramienta, de modelación hidrológica acoplada con la simulación del sistema eléctrico del país, constituye una robusta plataforma de base en la cual seguir trabajando y mejorando la habilidad de los pronósticos hidrológicos. En particular, se entiende necesario incorporar un esquema de asimilación de datos.

Los detalles sobre la descripción del modelo hidrológico, el acople en el simulador del sistema eléctrico, la implementación operativa y los principales resultados obtenidos se encuentran publicados en: De Vera et al., 2020; De Vera et al., 2021; Flieller et al., 2020; De Vera et al., 2022.

1.2 OBJETIVOS

A continuación, se presentan los objetivos generales y específicos planteados en la presente tesis de doctorado.

1.2.1 Generales

En vistas a las necesidades y desafíos mencionados anteriormente, el objetivo de este trabajo de tesis consiste en desarrollar abordajes metodológicos que contribuyan a mejorar la calidad del pronóstico por ensambles de los aportes hidrológicos a las centrales del Río Negro. Los desarrollos propuestos deberán

ser pasibles de ser incorporados en las herramientas de simulación del sistema eléctrico de Uruguay.

De esta manera se busca agregar “valor” al sistema de pronósticos hidrológicos por ensambles empleado por ADME para informar el proceso de toma de decisión de la programación de mediano y corto plazo del SIN.

1.2.2 Específicos

Para cumplir con los objetivos generales, se plantearon los siguientes objetivos específicos enmarcados en tres grandes líneas: (i) Evaluación de los pronósticos hidrometeorológicos por ensambles; (ii) Asimilación de datos observados de caudal; (iii) Representación de la incertidumbre asociada a los pronósticos por ensambles de precipitación.

Evaluación de los pronósticos hidrometeorológicos por ensambles

- Revisión del estado del arte de las metodologías de evaluación de pronósticos hidrometeorológicos por ensambles.
- Evaluación de la calidad de los pronósticos por ensambles generados para la cuenca del Río Negro desde la puesta en operación del modelo:
 - Ensamblés de predicciones numéricas de precipitación del modelo GEFS (Global Ensemble Forecast System) del NCEP-NOAA, empleados como forzantes del modelo hidrológico.
 - Ensamblés de los caudales de aporte a las centrales hidroeléctricas obtenidos a partir del modelo hidrológico alimentado por los pronósticos del GEFS.

Asimilación de datos observados de caudal

- Revisión del estado del arte de las técnicas de asimilación de datos y los sistemas de asimilación operacionales, en particular aplicadas a la modelación hidrológica.
- Desarrollo y evaluación de una metodología para la asimilación al modelo hidrológico (operativo en ADME) de datos observados de caudal en la cuenca del Río Negro.

Representación de la incertidumbre asociada a los pronósticos de precipitación

- Revisión del estado del arte de las metodologías de combinación de ensambles de pronósticos hidrometeorológicos y de ponderación de los miembros en función de su habilidad.
- Desarrollo de metodologías de ponderación de miembros según su habilidad reciente en el modelo Lorenz 63 con asimilación de datos mediante el método de Filtro de Kalman por ensambles (EnKF).

- Agrupamiento en dos sub-ensambles mediante la técnica de Cluster Analysis y determinación del “Mejor”/“Peor” sub-ensamble.
- Construcción de un ensamble no equiprobable asignando la probabilidad o peso de cada miembro según el inverso de la distancia al Análisis.
- Desarrollo y aplicación al pronóstico por ensambles de precipitación del modelo GEFs de una metodología de “time-lagged ensembles”, basada en la construcción de super-ensambles a partir de múltiples pronósticos inicializados en diferentes momentos asignando pesos diferenciales a través de una ponderación simple de los miembros en función de su habilidad reciente.

1.3 CONTENIDO

El presente documento se divide en siete capítulos, incluyendo este primero de introducción. En el segundo capítulo se describe el sistema de pronósticos hidrológicos por ensambles actualmente operativo en ADME, que constituye la plataforma de base en la cual incorporar los abordajes metodológicos propuestos a lo largo de este trabajo. En el tercer capítulo se evalúa la calidad de los pronósticos por ensambles de precipitación y caudal generados para la cuenca del Río Negro desde la puesta en operación del modelo hidrológico. El cuarto capítulo aborda el desarrollo y la evaluación de una metodología para la asimilación de datos observados de caudal al modelo hidrológico. En el capítulo cinco se presenta el desarrollo de metodologías de ponderación de miembros en el modelo Lorenz 63 con asimilación de datos mediante el método EnKF. El capítulo seis desarrolla y evalúa una metodología de “time-lagged ensembles” de precipitación, incluyendo una variante con pesos diferenciales a través de una ponderación simple de los miembros en función de su habilidad reciente. Por último, en el capítulo siete se presentan las conclusiones de este trabajo de tesis y se enumeran algunas de las posibles líneas a desarrollar en el futuro.

CAPÍTULO 2

DESCRIPCIÓN DEL SISTEMA DE PRONÓSTICOS HIDROLÓGICOS POR ENSAMBLES

2. Descripción del sistema de pronósticos hidrológicos por ensambles

En este capítulo se presenta la metodología desarrollada para la generación y acople del ensamble de pronósticos de aportes hidrológicos a las centrales del Río Negro, y su implementación operativa en las herramientas de operación del sistema eléctrico conjuntamente con los pronósticos de velocidad del viento y radiación solar.

2.1 MARCO TEÓRICO

Los estudios realizados por Lorenz (1963) pusieron de manifiesto el *carácter caótico* del comportamiento de la atmósfera y, por ende, la existencia de *incertidumbre* en la realización de pronósticos basados en la *simulación numérica* de la misma. Esta incertidumbre aumenta a medida que se busca realizar pronósticos con mayor antelación y ya desde los primeros estudios se estimó que un plazo de dos semanas constituía el máximo periodo “pronosticable” del sistema en un sentido determinístico. A partir de ello, muchos esfuerzos se han orientado a lograr reducir el error de las predicciones, entender su comportamiento y estimar cuál es la incertidumbre asociada a los pronósticos del tiempo.

En este sentido, se han realizado grandes avances en el campo de la *asimilación de datos*, buscando conocer con mayor precisión las condiciones iniciales, y también en el desarrollo de los modelos, de manera de representar más adecuadamente los procesos físicos que determinan el comportamiento de la atmósfera (Kalnay, 2003). Por otro lado, Epstein (1969) introdujo la metodología del *pronóstico por ensambles* o conjuntos la cual, en contraste con los pronósticos determinísticos, busca representar la incertidumbre asociada a la predicción numérica de la atmósfera y se basa en la realización de múltiples simulaciones de la atmósfera empleando condiciones iniciales ligeramente perturbadas y/o modelos ligeramente diferentes (Figura 2-1). Una de las hipótesis principales del pronóstico por ensambles es que, si la forma de obtener los diferentes pronósticos es adecuada, las propiedades estadísticas del conjunto se asemejan a las propiedades estadísticas de la verdadera función de distribución de los estados futuros de la atmósfera. De esta manera, brinda información sobre la incertidumbre a lo largo del horizonte de la previsión (a través de la dispersión de los miembros del ensamble), a la vez que permite obtener una reducción del error medio en los pronósticos.

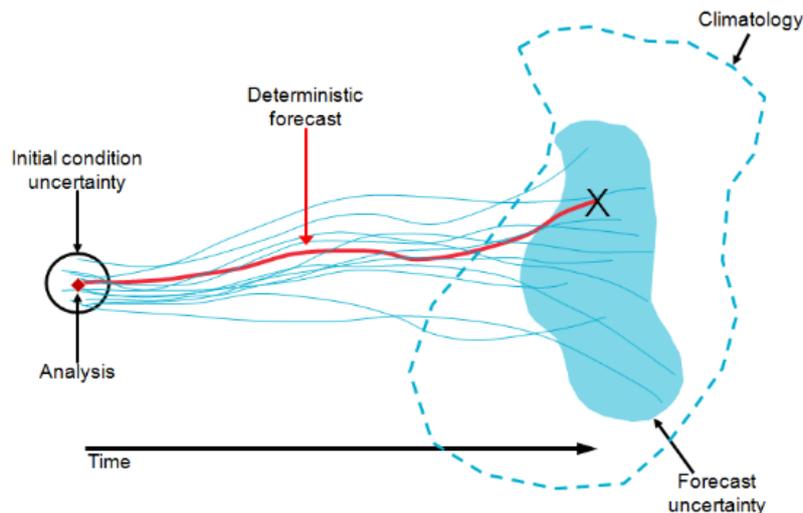


Figura 2-1: Representación esquemática del pronóstico por ensambles
 (Fuente: <https://www.metoffice.gov.uk/research/weather/ensemble-forecasting/what-is-an-ensemble-forecast>)

En las últimas dos décadas la mayoría de los centros operacionales de pronóstico ha comenzado a desarrollar y emplear modelos probabilísticos basados en simulaciones por ensambles (Buizza et al., 2019). En la Tabla 2-1 se presenta un resumen con las principales características de los sistemas operacionales globales a mediano plazo por ensambles (OG-ENS²) al 2019: National Centers for Environmental Prediction (NCEP), European Centre for Medium Range Weather Forecast (ECMWF), Australian Bureau of Meteorology (BMRC), Chinese Meteorological Administration (CMA), Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), Japanese Meteorological Administration (JMA), Korean Meteorological Administration (KMA), UK Met Office (UKMO), Meteorological Service of Canada (MSC).

² *Operacional* significa que estos ensambles producen pronósticos diariamente. *Global* significa que sus pronósticos cubren todo el mundo. *Mediano plazo* significa que proporcionan pronósticos de al menos hasta 7 días, con algunos de ellos extendiéndose hasta 2 semanas o incluso 1 mes.

Tabla 2-1: Principales características de los sistemas operacionales de pronóstico por ensambles (Fuente: Buizza et al., 2019).

Table 1 Main characteristics of the nine TIGGE OG-ENS, listed in alphabetic order by the production center (column 1); initial uncertainty method (column 2), model uncertainty simulation (Y/N, column 3), truncation and approximate horizontal resolution (column 4), number of vertical levels and top of the atmosphere in hPa (column 5), forecast length in days (column 6), number of perturbed members for each run (column 7), total number of members (including the control forecast) per day (column 8), and date since when data have been stored in TIGGE (column 9). Note that the BMRC OG-ENS data are available only up to the end of 2010, when BMRC stopped producing global ensemble forecasts

Centre	Initial unc.	Model unc.	Truncation (degrees, km)	# Vert	Fest	#	#runs	#	In TIGGE
	method (area)			(TOA, hPa)		length (d)		pert	
BMRC (AU)	SV(NH,SH)	NO	TL119 (1.5°; 210 km)	19 (10.0)	10	32	2 (00/12)	66	Sep-07/Jul-10
CMA (CHI)	BV(globe)	NO	T213 (0.56°; 70 km)	31 (10.0)	10	14	2 (00/12)	30	May-07
CPTEC (BR)	EOF(40S:30N)	NO	T126 (0.94°, 120 km)	28 (0.1)	15	14	2 (00/12)	30	Feb-08
ECMWF (EU)	SV(NH, SH, TC) + EDA (globe)	YES	TL639 (0.28°; 35 km)	91 (0.1)	0-10	50	2 (00/12)	102	Oct-06
			TL319 (0.56°; 70 km)		15/32				
JMA (JAP)	SV(NH, TR, SH)	YES	TL479 (0.38°; 50 km)	60 (0.1)	11	25	2 (00/12)	52	Aug-11
KMA (KOR)	ETKF(globe)	YES	N320 (0.35°; 40 km)	70 (0.1)	10	23	4 (00/06/12/18)	96	Dec-07
MSC (CAN)	EnKF(globe)	YES	600 × 300 (0.6°, 75 km)	40 (2.0)	16/32	20	2 (00/12)	42	Oct-07
NCEP (USA)	ETR(globe)	YES	T254 (0.70°; 90 km)	28 (2.7)	0-8	20	4 (00/06/12/18)	84	Mar-07
			T190 (0.95°; 120 km)		8-10				
UKMO (UK)	ETKF(globe)	YES	N216 (0.45°; 60 km)	70 (0.1)	15	23	2 (00/12)	48	Oct-06

Initial uncertainty method: SV: Singular vectors, BV: Bred vectors, EOF: Empirical orthogonal functions, EDA: Ensemble of data assimilations, ETKF: Ensemble Transform Kalman filter, EnKF: Ensemble Kalman filter, ETR: Ensemble transform (ET) with rescaling.

La incorporación de pronósticos probabilísticos derivados de los ensambles en el proceso de toma de decisión produce un aumento significativo del valor de la información meteorológica. Dicho valor agregado impacta directamente sobre los productos o herramientas que se pueden desarrollar y que asisten al proceso de toma de decisión de los diferentes usuarios del pronóstico (Kalnay, 2003).

Específicamente, en el sector hidroeléctrico y de gestión de embalses, el empleo del enfoque probabilístico o por ensambles se remonta a la década de 1950 y desde entonces ha estado en continuo desarrollo y aplicación. En sus inicios se aplicó a las escalas estacionales en Estados Unidos (Day, 1985) y Francia (Desaint et al., 2009). Recién en las últimas dos décadas las predicciones numéricas de campos meteorológicos de alta resolución y los sistemas de pronósticos por ensambles comenzaron a aplicarse conjuntamente en la previsión hidrometeorológica (Desaint et al. 2009). Por ejemplo, desde el 2010, la compañía francesa de electricidad (EDF) brinda pronósticos diarios de caudales a corto y largo plazo para 130 cuencas a partir de las predicciones meteorológicas de Météo-France y del Centro Europeo de Previsiones Meteorológicas a Plazo Medio (ECMWF) (<https://hepex.irstea.fr/operational-use-of-ensemble-hydrometeorological-forecasts-at-edf-french-producer-of-energy/>). En nuestra región, una compañía brasilera de energía eléctrica (CEMIG) recientemente implementó el pronóstico de caudales por ensambles basado en predicciones

meteorológicas de múltiples fuentes y modelos hidrológicos semi-distribuidos a gran escala (Schwanenberg et al. 2015; Fan et al. 2016). Por otro lado, en la cuenca del río Uruguay, la Comisión Técnica Mixta de Salto Grande (CTM-SG) dispone de un modelo de gestión implementado en FEWS (Alvarado-Montero et al., 2018) que incluye la previsión de los caudales de aporte al embalse mediante el modelo SAC SMA acoplado al modelo de tránsito Muskingum y un modelo hidrodinámico unidimensional HEC-RAS (https://oss.deltares.nl/web/delft-fews/-/salto_grande). Boucher & Ramos (2018) presentan una extensa revisión de la evolución de los sistemas de pronósticos hidrológicos por ensambles para generación hidroeléctrica.

2.2 DESCRIPCIÓN DE LA CUENCA DE ESTUDIO

La cuenca del Río Negro, cuenca transfronteriza con Brasil, ocupa aproximadamente una superficie de 62.900 km², existiendo sobre su cauce principal tres represas hidroeléctricas: Gabriel Terra (en adelante G. Terra), Baygorria y Constitución (Palmar), localizadas consecutivamente desde aguas arriba hacia aguas abajo. En la Tabla 2-2 se resumen las principales características de dicha cuenca.

Tabla 2-2: Principales características de la cuenca de aporte a la central Constitución.

Parámetro	Valor
Extensión superficial (km ²)	62.850
Longitud del cauce principal (km)	800
Desnivel geométrico (m)	390
Pendiente media (m/km)	0,25
Agua disponible ponderada (mm)	105

El sistema conformado por las tres represas hidroeléctricas del Río Negro constituye, a la fecha, aproximadamente el 20% de la energía eléctrica total generada en el país (ADME, 2022). Complementariamente, sobre el río Uruguay se localiza la central hidroeléctrica binacional (Argentina-Uruguay) de Salto Grande.

En la Figura 2-2 se presenta la localización de las cuatro centrales (con su respectiva potencia instalada), la delimitación de la cuenca de aporte a la central Constitución y su discretización en subcuencas para la modelación hidrológica (ver sección 2.3.1), incluyendo una tabla con el área (km²), la pendiente media (%), el tiempo de concentración (hr) y el agua disponible (AD) media (mm) de cada subcuenca (identificada según un ID).

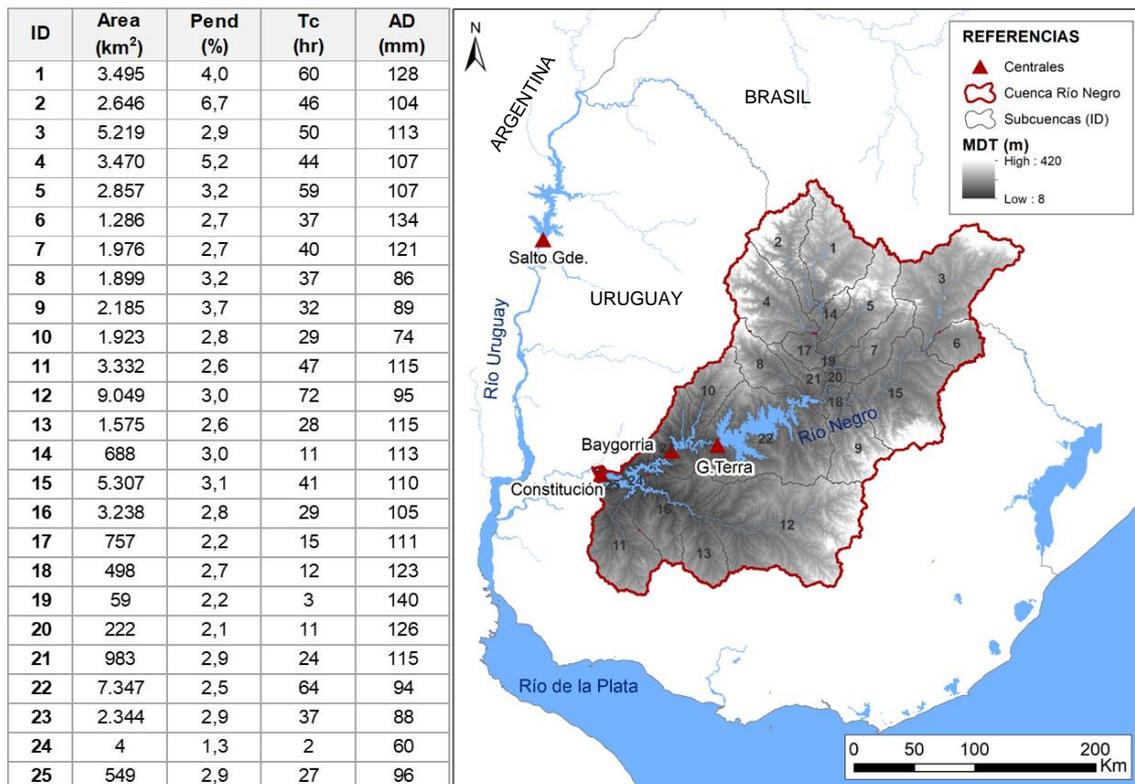


Figura 2-2: Localización de las centrales hidroeléctricas (triángulos rojos) y delimitación de la cuenca de aporte a la central Constitución. Se incluye una tabla con el área de la cuenca de aporte (km²), la pendiente media (%) del cauce principal, el tiempo de concentración (hr) y al agua disponible ponderada (mm) de cada subcuenca (identificada según un ID).

En la Tabla 2-3 se resumen las principales características de las centrales hidroeléctricas, en la que puede observarse que la represa G. Terra es la que tiene mayor capacidad de regulación.

Tabla 2-3: Principales características de las centrales hidroeléctricas existentes en Uruguay.

Central	Coordenadas UTM 21S (km)	Potencia instalada (MW)	Volumen máximo embalsado (Hm ³)	Cuenca de aporte (km ²)
Gabriel Terra	(554, 6367)	152	8.800	39.500
Baygorria	(518, 6363)	108	570	4.100 (incremental)
Constitución	(458, 6343)	333	2.854	18.900 (incremental)
Salto Grande	(411, 6540)	945	5.000	244.000

El aumento de la demanda de agua como consecuencia de nuevos escenarios de producción agrícola y forestal dentro de la cuenca y el aumento de la demanda de energía eléctrica que se viene registrando en los últimos años, ponen de

manifiesto la necesidad de generar herramientas para gestionar adecuadamente los recursos hídricos en la cuenca del Río Negro (Crisci & Terra, 2014).

2.3 MODELACIÓN HIDROLÓGICA

Para la realización de previsiones hidrológicas operativas en tiempo real es necesario un equilibrio entre la complejidad del modelo, la información requerida, el costo computacional y la precisión de los pronósticos (Piazzini et al., 2021). Un aumento en la complejidad del modelo no implica necesariamente una mejora en el desempeño, principalmente debido a limitaciones en la información disponible y a los problemas de identificabilidad (“identifiability”) en la estimación de los parámetros. Si bien los modelos hidrológicos distribuidos contemplan la distribución espacial de las variables y parámetros en la cuenca, pueden ser computacionalmente caros y generalmente son muy sensibles a la estrategia de calibración. Por otro lado, los modelos hidrológicos concentrados son una herramienta operativa confiable para la previsión de caudales, debido a su simplicidad, eficiencia computacional y menores requisitos de datos. En particular, los modelos conceptuales de lluvia-escorrentía han demostrado su efectividad en el pronóstico del caudal: modelo Sacramento (Burnash et al., 1973), modelo HBV-96 (Lindström et al., 1997), modelo GR4J (Perrin et al., 2003), modelo MGB-IPH (Collischonn et al., 2007), entre otros.

2.3.1 Descripción del esquema de modelación

Para generar los caudales de aporte a las centrales hidroeléctricas se emplea, en cada subcuenca, un modelo simple de paso diario denominado GR4J (Perrin et al., 2003) acoplado con el método de Muskingum (Chow & Maidment, 1994) para el tránsito de los hidrogramas resultantes.

El *modelo GR4J* (Génie Rural à 4 paramètres Journalier) es un modelo del tipo concentrado de cuatro parámetros (Tabla 2-4), basado en la cuantificación de la humedad del suelo. El mismo utiliza como datos de entrada la precipitación (P) y la evapotranspiración potencial (E) para luego modelar el almacenamiento del agua en el suelo teniendo en cuenta dos reservorios, el reservorio de producción (capa sub-superficial del suelo) y el reservorio de tránsito (no lineal). Una parte del escurrimiento (Q_d) es transitada a través de un único hidrograma unitario (UH2) y, otra parte (Q_r) se transita a través de otro hidrograma unitario (UH1) y se almacena en el reservorio no lineal, para luego formar con ambas partes la escorrentía total (Q). Las variables de estado del modelo son el nivel de agua en los dos reservorios considerados (S y R). Las variables UH1 y UH2 distribuyen la precipitación efectiva sobre sucesivos intervalos de tiempo por lo que, si bien no son estrictamente variables de estado, también acarrear cierta inercia entre intervalos de simulación (Santos et al., 2018; Piazzini et al., 2021).

En este caso, al ser el modelo alimentado por un conjunto de pronósticos de precipitación, se obtiene igual número de previsiones para los caudales.

La cuenca de aporte a la represa de Constitución (62.850 km²) se discretizó en 25 subcuencas de área menor a 9.000 km² (según se presenta en la Figura 2-2), en base al modelo digital del terreno de la NASA SRTM (Shuttle Radar Topographic Mission) con una resolución de 90x90m.

El modelo GR4J se implementa en cada una de estas subcuencas, a partir de los datos diarios de precipitación y evapotranspiración potencial disponibles. La precipitación media areal en cada subcuenca se obtiene a partir del método de los polígonos de Thiessen.

Una vez obtenidos los caudales diarios de aporte de cada subcuenca, los mismos se transitan a lo largo del cauce hasta los puntos de interés aguas abajo mediante el *método de Muskingum*, método para el tránsito hidrológico en ríos que requiere de dos parámetros (Tabla 2-4).

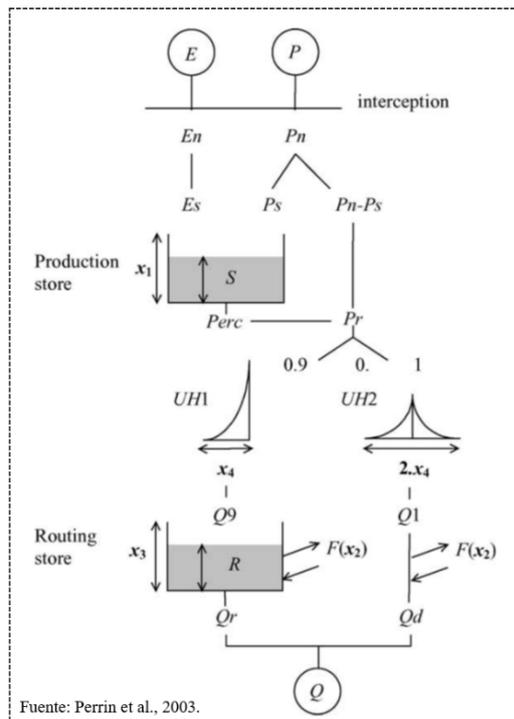
En el caso de las centrales Baygorria y Constitución se trabaja con las cuencas incrementales y se calcula el “aporte propio”, con lo cual no es necesario transitar los caudales erogados (vertido y turbinado) por la central aguas arriba.

En la Tabla 2-4 se presenta la descripción de cada uno de los parámetros del esquema de modelación adoptado (modelo “GR4J+Muskingum”) y en la Figura 2-3 se muestra su representación conceptual esquemática.

Tabla 2-4: Parámetros del esquema de modelación adoptado (modelo “GR4J+Muskingum”).

Parámetro	Modelo	Descripción del parámetro	Unidad
x ₁	GR4J	Capacidad del reservorio de producción	mm
x ₂	GR4J	Coeficiente de intercambio con el agua subterránea	mm
x ₃	GR4J	Capacidad del reservorio de tránsito (no lineal)	mm
x ₄	GR4J	Tiempo base de los hidrogramas unitarios	días
X	Muskingum	Factor de ponderación	---
K	Muskingum	Tiempo de tránsito de una onda de creciente	días

Modelo GR4J:
Cálculo del caudal incremental en cada subcuenca



Modelo Muskingum:
Tránsito a través de la red de drenaje

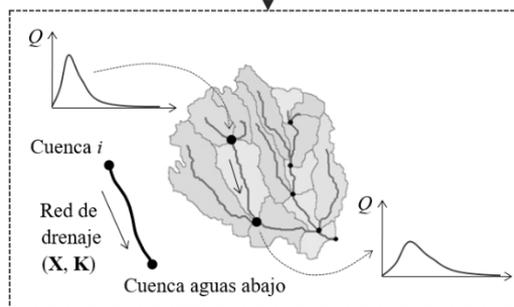


Figura 2-3: Representación esquemática del modelo "GR4J+Muskingum".

Para obtener un buen desempeño del modelo hidrológico es necesario ajustar los parámetros, de forma que el modelo represente lo mejor posible los caudales históricos observados.

Los parámetros del modelo GR4J se ajustaron siguiendo las recomendaciones publicadas por Narbondo et al. (2018) y Narbondo et al. (2020), en donde presentan la aplicación y regionalización del modelo GR4J en cuencas de Uruguay. El parámetro x_1 (que representa la capacidad de almacenamiento del suelo) no se considera como un parámetro de calibración, sino que se le asigna el valor del agua disponible media de los suelos presentes en cada subcuenca.

El parámetro X (adimensional) del método de Muskingum en corrientes naturales se encuentra entre 0 y 0,3 con un valor medio cercano a 0,2. Dado que los resultados del método son poco sensibles al valor de este parámetro (Chow & Maidment, 1994), su valor no fue calibrado y se fijó en 0,2. El parámetro K (expresado en unidades de tiempo) fue ajustado, inspirados en el método de

Muskingum-Cunge, en base a las características físicas de los cauces (longitud, ancho, pendiente media, rugosidad de Manning) y los caudales circulantes.

En la Tabla 2-5 se presentan los valores adoptados para cada uno de los parámetros según la subcuenca. En particular, para la subcuenca del río Yí se adoptaron los valores que surgen de la calibración individual del modelo GR4J realizada por Narbondo et al. (2020). Para el resto de las subcuencas se partió de los parámetros regionalizados y se los ajustó levemente buscando corregir el desfase temporal identificado originalmente.

Tabla 2-5: Valor adoptado para cada uno de los parámetros del modelo “GR4J+Muskingum” según la subcuenca (AD: Agua Disponible, Tc: Tiempo de concentración, L: Longitud de cada tramo del cauce principal, Lm: Longitud media de los tramos del cauce principal).

Parámetro	Descripción del parámetro	Cuenca del río Yí	Subcuencas restantes
x ₁	Capacidad del reservorio de producción (GR4J)	AD mm	AD mm
x ₂	Coefficiente de intercambio con el agua subterránea (GR4J)	-2,5 mm	-2 mm
x ₃	Capacidad del reservorio de tránsito (GR4J)	80 mm	80 mm
x ₄	Tiempo base de los hidrogramas unitarios	1,04*(T _c ^{0,205})	0,5*(T _c ^{0,205})
X	Factor de ponderación (Muskingum)	0,20	0,20
K	Tiempo de tránsito de una onda de creciente (Muskingum)	2*L/Lm (días)	2*L/Lm (días)

A continuación se presentan algunos indicadores de desempeño, comúnmente utilizados en modelación hidrológica, obtenidos para el periodo enero de 2018 a enero de 2023 en la cuenca de aporte a G. Terra y en toda la cuenca de aporte del Río Negro con cierre en Constitución (Cuenca RN). La descripción e interpretación de dichos indicadores se presenta en la sección 3.2.2: raíz del error cuadrático medio (RMSE), porcentaje de sesgo (PBIAS) y coeficiente de eficiencia de Nash-Sutcliffe (NSE).

Tabla 2-6: Indicadores de desempeño obtenidos en la cuenca de aporte a G. Terra y la cuenca del Río Negro con cierre en Constitución para el periodo enero de 2018 a enero de 2023.

Cuenca	RMSE (m ³ /s)	NSE	PBIAS
G. Terra	385	0,75	-2,6%
Cuenca RN	572	0,74	1,7%

No se presentan aquí los indicadores para las cuencas incrementales de Baygorria y Constitución, porque como se verá en la sección 3.1.2.1 las series de caudales

de aporte teóricos a dichas centrales presentan errores sistemáticos (producto de la estimación indirecta en base a un balance hídrico en el embalse, sensible a la estimación de los caudales erogados).

En la sección 4.3.1 (capítulo 4) se incluyen diversas figuras con la comparación de la evolución de los caudales diarios observados y simulados en algunas subcuencas de aporte al embalse de G. Terra (consideradas para la asimilación de datos).

2.3.2 **Información empleada**

2.3.2.1 *Precipitación*

Datos históricos

Los datos históricos de la precipitación ocurrida en la cuenca consisten en una estimación en base a la combinación de imágenes satelitales y observaciones pluviométricas en superficie desarrolladas por De Vera et al. (2021). Las mismas se encuentran disponibles desde febrero de 2017 a la fecha (se actualizan diariamente), con una resolución temporal diaria y una resolución espacial de $0,1^\circ \times 0,1^\circ$.

Dicha metodología, denominada *Regression Kriging* (RK), se basa en el modelo de Kriging Universal (Hengl, 2009; Chilès et al., 2012), un método de interpolación geoestadístico que permite la incorporación de información grillada de alta resolución (estimaciones satelitales) y su calibración en base a información puntual de referencia (estaciones pluviométricas). Adicionalmente, se aplica una máscara de lluvia/no lluvia para corregir la sobreestimación de la ocurrencia de precipitación (producto de la estimación como una suma ponderada de observaciones positivas).

Para ello, en su primera versión considera 19 estaciones pluviométricas y dos productos satelitales GSMaP (JAXA, Japón) y GPM IMERG (NASA, EEUU), en la Tabla 2-7 se presentan sus principales características.

Tabla 2-7: Principales características de las estimaciones satelitales de precipitación consideradas (Fuente: De Vera et al., 2021).

	GSMaP	IMERG
Resolución espacial	$0,1^\circ$	$0,1^\circ$
Resolución temporal	Horaria	Horaria
Latencia (hrs)	4	12
Periodo disponible	2017-Presente	2000-Presente

Como resultado se obtiene la precipitación diaria media areal en 25 subcuencas del Río Negro consideradas en la modelación hidrológica (ver sección 2.3.1). Los

acumulados diarios se calculan a las 10 UTC por ser la hora de registro en las estaciones pluviométricas.

En la Figura 2-4 se presenta, a modo de ejemplo, los mapas de precipitación diaria obtenidos para el 15/12/2019 a partir de los registros puntuales, la estimación satelital bruta, la interpolación entre registros y el producto combinado (estimación RK).

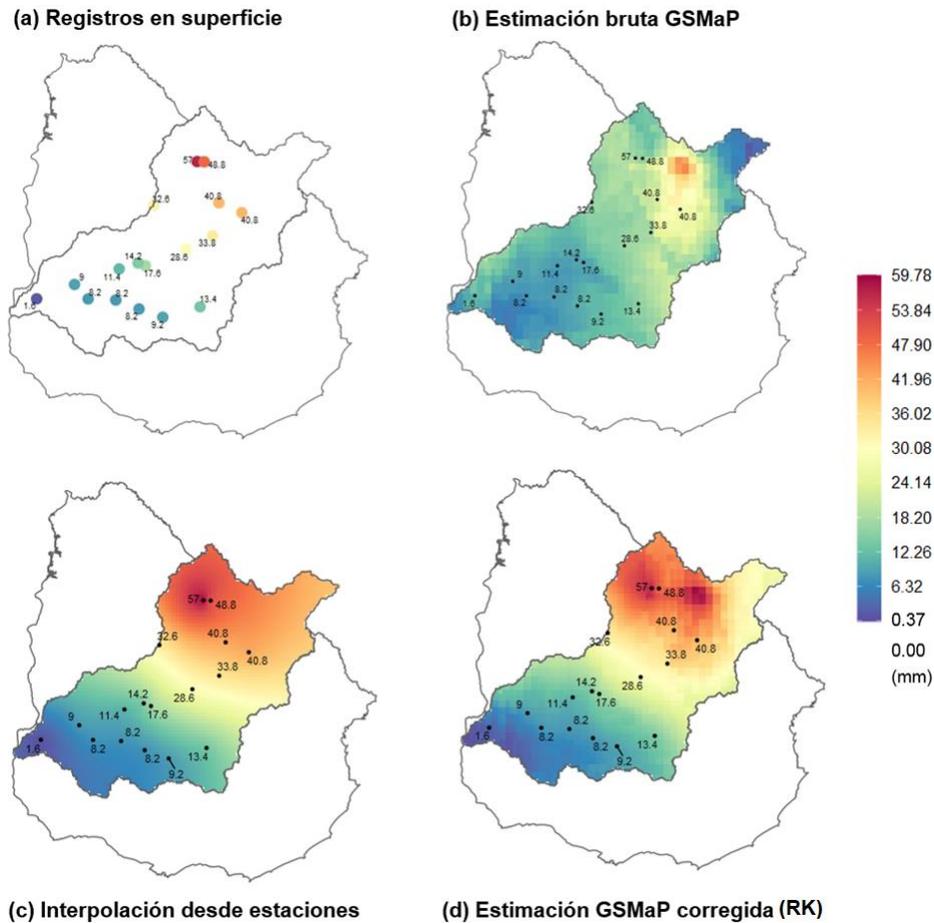


Figura 2-4: Mapas de precipitación diaria obtenidos para el 15/12/2019 a partir de los registros puntuales, la estimación satelital bruta, la interpolación entre registros y el producto combinado (estimación RK).

Se observa que en la región hacia Río Grande Do Sul (Brasil), los dos campos interpolados muestran valores muy diferentes. La interpolación entre registros presenta un comportamiento poco realista, con valores elevados uniformes en una zona suave que se desvanece gradualmente (producto de la estimación como suma ponderada), en vez de zonas irregulares y con máximos puntuales intensamente altos.

En el marco de una consultoría para ADME a cargo de Alfaro (2022) se desarrollaron diversas mejoras el algoritmo de combinación: (i) se incorporaron nuevos datos pluviométricos, incrementando la cantidad de pluviómetros disponibles de un máximo de 19 a 176 (ver Figura 2-5); (ii) se implementaron

nuevos controles de calidad; (iii) se ajustaron los parámetros de los controles existentes para la red pluviométrica de mayor densidad; (iv) se mejoraron aspectos computacionales.

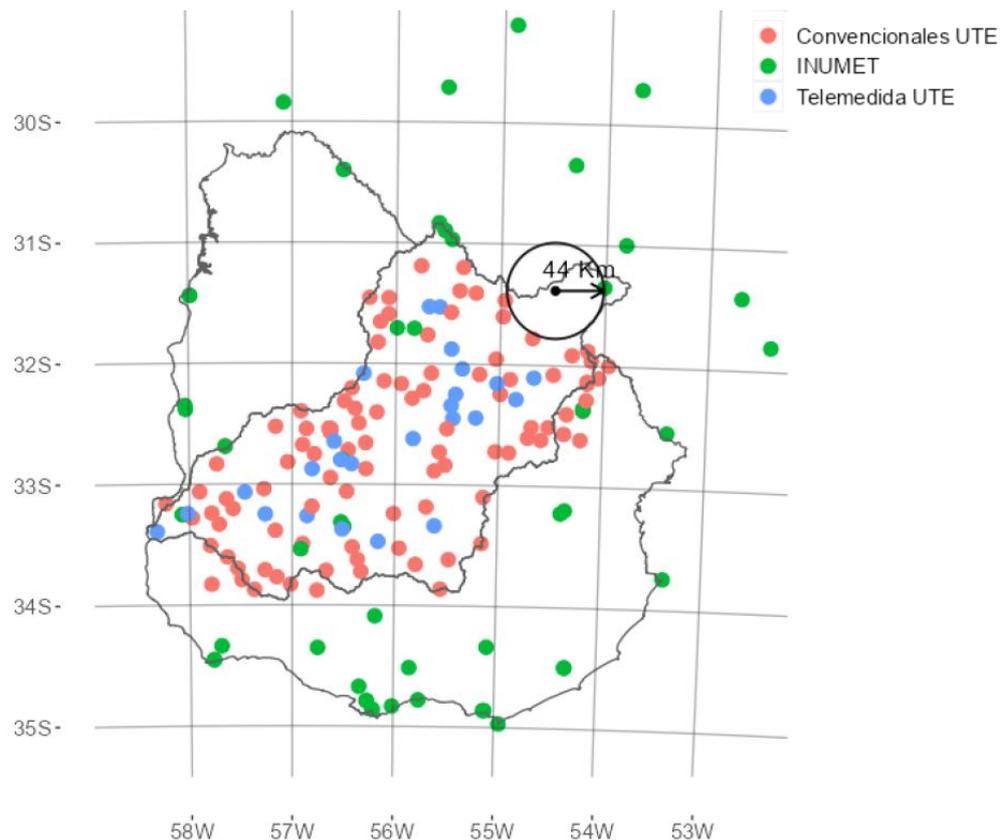


Figura 2-5: Ubicación de las estaciones pluviométricas disponibles y distancia máxima a una observación (Fuente: Alfaro, 2022).

La estimación RK en la cuenca del Río Negro se actualiza diariamente y se emplea para estimar el estado de la cuenca al inicio del pronóstico.

Datos de pronóstico

El modelo hidrológico actualmente operativo en ADME es alimentado por el ensamble de predicciones numéricas de precipitación a 16 días del *modelo GEFS* (*Global Ensemble Forecast System*) del NCEP-NOAA, compuesto por la corrida de control más 30 miembros perturbados, con una resolución temporal de 6 hrs y una resolución espacial de $0,5^\circ \times 0,5^\circ$ (Zhou et al., 2022).

El GEFS ha estado operativo en NCEP desde diciembre de 1992. La versión inicial usaba el "Global Spectral Model" (GSM-NCEP) con una resolución T62L18 (aproximadamente 200 km en horizontal y 18 niveles sigma verticales). Estaba compuesta por 2 miembros perturbados y un miembro de control, las perturbaciones a la condición inicial se generaban mediante el método de los vectores criados ("breeding vector", BV) (Toth & Kalnay, 1993). En sus inicios el GEFS se ejecutaba una vez al día, con un horizonte de pronóstico a 12 días.

En agosto de 2005 (versión V6 en adelante), el GEFS se actualizó para ejecutarse cuatro veces al día (00UTC, 06UTC, 12UTC y 18UTC) y pasó a generar pronósticos de hasta 16 días. Cada uno de estos ciclos tenía 10 miembros perturbados (5 pares) que se inicializaban usando el método BV. Se comenzó a aplicar una técnica de reubicación de tormentas tropicales (“Tropical Storm Relocation”, TSR) para ajustar la ubicación central inicial a la ubicación observada. En 2006 se implementó operativamente el método BV extendido con “Ensemble Transform and Rescaling” (BV-ETR) y ciclos de 6 horas.

A principios del 2010 el GEFS se actualizó con una representación mejorada de la incertidumbre del modelo utilizando el algoritmo “Stochastic Total Tendency Perturbation” (STTP), con actualizaciones cada 6 horas.

A través de otra actualización importante en diciembre de 2015 las perturbaciones iniciales del GEFS se comenzaron a seleccionar de los pronósticos a 6 horas del “Global Data Assimilation System (GDAS) 80-member Ensemble Kalman Filter” (EnKF; Whitaker et al., 2008) junto con la TSR y centralización de las perturbaciones iniciales (Zhou et al. 2017).

En septiembre de 2020 se implementó la última versión disponible del GEFS, versión V12 (Zhou et al., 2022), en la cual el modelo GSM fue reemplazado por el modelo “Finite Volume Cubed-Sphere Dynamical Core” (FV3). Esta versión se ejecuta cuatro veces al día (00UTC, 06UTC, 12UTC y 18UTC) con 30 miembros perturbados y un miembro de control con una resolución C384L64 (alrededor de 25 km de resolución horizontal y 64 niveles verticales híbridos). El horizonte de pronóstico es de 16 días, excepto en el ciclo de las 00 UTC que se extiende hasta 35 días (para respaldar los pronósticos subestacionales).

La evolución de las distintas configuraciones del modelo atmosférico disponibles hasta el momento se resume en la Tabla 2-8. En negrita se resalta la versión empleada en este trabajo (V.12).

Tabla 2-8: Evolución de las distintas configuraciones del modelo atmosférico GEFS.

Version	Date	Initial uncertainty	TS relocation	Model Uncertainty	Resolution	FCST length	Ens. size (members)	Daily frequency
V1.0	1992.12	Bred vector (BV)	None	None	T62L18 ~200km	12	2+1	00UTC
V2.0	1994.03				T62L18 ~200km		10+1 (00UTC)	00UTC
V3.0	2000.06						4+1 (12UTC)	
V4.0	2001.01				T126L28(0-2.5) ~100km		10+1	00UTC
V5.0	2004.03				T62L28(2.5-16) ~200km			
V6.0	2005.08				T126(0-3.5) ~100km			
V7.0	2006.05	(BV- ETR)	TSR	STTP	T62L28(3.5-16) ~200km	16	14+1	00UTC
V8.0	2007.03				T126L28(0-7.5) ~100km			
V9.0	2010.02				T62L28(7.5-16) ~200km			
V10.0	2012.02				T126L28 ~100km			
V11.0	2015.12				T190L28 ~70k			
V12.0*	2020.10				T254L42 (0-8) ~50km			
		T190L42 (8-16) ~70km	20+1	06UTC				
		TL574L64 (0-8) ~33km						
		TL382L64 (8-16) ~50km	18UTC	(16 days)				
		EnKF (f06)	None	SPPT+SKEB	C384L64 (0-35) ~25km	16(35)	30+1+1	00UTC
								(35 days)

Fuente: https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gefs.php

ADME descarga diariamente la simulación iniciada a las 00UTC del modelo GEFS V12, integrada en 60 puntos distribuidos a lo largo de toda la cuenca del Río Uruguay (con una distancia promedio de 100 km).

2.3.2.2 Otros datos

Los siguientes datos son empleados para la modelación hidrológica:

- Ciclo medio anual de evapotranspiración potencial diaria (ETP): construido a partir de datos diarios históricos registrados en el período 1991-2015 en nueve estaciones del Instituto Nacional de Investigación Agropecuaria de Uruguay (INIA) y del Instituto Uruguayo de Meteorología (INUMET) mediante el método de Penman-Monteith. Se ha mostrado en el pasado que el ciclo medio anual de ETP es suficiente para alimentar modelos hidrológicos (Oudin et al., 2010). En el Anexo I se presenta la ubicación de las estaciones consideradas y el ciclo medio anual de ETP obtenido en cada caso.
- Capacidad de almacenamiento de agua de los suelos presentes en la cuenca: el agua potencialmente disponible (AD) de los suelos se obtuvo a partir de la Carta de Reconocimiento de Suelos del Uruguay, escala 1:1.000.000 (MGAP, 2001; Molino y Califra, 2001). En base a esto, se pondera por el área para obtener un valor representativo del suelo en cada subcuenca. En el Anexo I se presenta el mapa de AD resultante.

- Se empleó el modelo digital del terreno (MDT) de la NASA SRTM (Shuttle Radar Topographic Mission) con una resolución de 90x90m (disponible en <http://srtm.csi.cgiar.org/srtmdata/>) para la delimitación de las subcuencas y su caracterización geomorfológica.

2.4 SIMULACIÓN DEL SISTEMA ELÉCTRICO

La modelación del sistema eléctrico se realiza mediante la plataforma de Simulación de Sistemas de Energía Eléctrica “*SimSEE*” (Casaravilla et al., 2008; Chaer, 2008), disponible en <https://simsee.org/>. La misma permite simular la operación óptima del sistema incorporando distintos tipos de pronósticos, tales como generación de energías renovables, demanda eléctrica, precios futuros de tecnologías y combustibles, intercambios internacionales y otros. Es extensamente utilizada en Uruguay (Larrosa et al. 2012; Crisci & Terra, 2014; Maciel et al., 2015; Terra et al., 2019) para simular la operación del sistema energético tanto en el largo plazo (planificación de inversiones) como en el corto plazo (operación del sistema y simulación del mercado).

2.4.1 Modelo SimSEE

El *modelo SimSEE* fue desarrollado en el año 2007 por el Instituto de Ingeniería Eléctrica de la Facultad de Ingeniería de la Universidad de la República, en el marco del proyecto de desarrollo tecnológico PDT-47-12 financiado por el BID.

El *SimSEE* permite realizar *simulaciones de operación óptima* de sistemas de generación eléctrica en la que participan distintos tipos de actores: generadores (centrales de generación hidroeléctrica, parques eólicos, parques solares, centrales de generación en base a combustibles fósiles, etc.), demandas, red eléctrica (nodos y arcos) e interconexiones eléctricas (demandas o generadores según sean exportaciones o importaciones).

La operación óptima del sistema de generación eléctrica consiste en disponer de una *política de operación*, es decir una valorización de los recursos almacenables del sistema, de forma tal de poder evaluar en todo momento la conveniencia o no de usar cada recurso. El recurso almacenable de mayor importancia en este caso es al agua en las represas hidroeléctricas, en particular en la represa G. Terra por ser la que tiene mayor capacidad de regulación.

La obtención de dicha política de operación se logra en *SimSEE* a través de una etapa de optimización con el objetivo de minimizar el valor esperado del costo total del sistema en el horizonte de tiempo de estudio (costo futuro, CF) para todas las realizaciones posibles de las variables aleatorias que intervienen (entre las que se encuentran los aportes hidráulicos a las represas).

El *SimSEE* minimiza el valor esperado del CF mediante el procedimiento conocido como “*Programación Dinámica Estocástica*”. El procedimiento consiste en

asumir conocido el valor del CF en la última etapa del horizonte de tiempo y calcular, en cada etapa desde el futuro hacia el presente, el mínimo valor esperado del costo futuro para cada estado del sistema, para una cantidad suficiente de las realizaciones posibles de las variables aleatorias.

Para simular las distintas realizaciones de las variables aleatorias es necesario tener un *proceso estocástico* que genere series sintéticas que describan apropiadamente la incertidumbre asociada a cada variable mediante sorteos sucesivos. A continuación, se realiza una breve descripción de cómo se realiza esto en SimSEE.

Generación de series sintéticas

La generación de series sintéticas de las variables aleatorias se realiza en SimSEE a partir de la identificación de un modelo que represente al conjunto de series reales manteniendo algunas características importantes de las mismas, tales como su histograma de frecuencias y coeficientes de auto-correlación. Dicho modelo se denomina “CEGH”: Correlaciones en Espacio Gaussiano con Histograma (Chaer, 2005).

El modelo CEGH consiste en construir un conjunto de funciones de deformación (una para cada semana del año) que transformen las series de datos reales (en este caso, aportes hidráulicos) en series gaussianas de media cero y varianza uno. Luego, en el Espacio Gaussiano (EG), las series de datos transformadas son reproducidas a través de la salida de un filtro lineal alimentado por una fuente de ruido blanco gaussiano, cuyos coeficientes son estimados utilizando las series originales transformadas (garantizando que se mantengan los coeficientes de auto-correlación de las series). Una vez determinadas las series sintéticas transformadas (a partir del filtro lineal) las mismas se “antitransforman” a través de la inversa de la función de deformación correspondiente a cada semana, para obtener las series sintéticas en el espacio real.

Este sintetizador es utilizado por el SimSEE para caracterizar la incertidumbre esperada durante la optimización, donde se determina la política de operación óptima. Asimismo, de dicho generador estocástico es posible obtener series sintéticas de las variables para ser utilizadas en la etapa de simulación, para calcular costos esperados y su dispersión.

2.4.2 Acople de los ensambles

En SimSEE los pronósticos, tanto hidrológicos como de generación en base a energías renovables no convencionales y de demanda, se modelan mediante fuentes CEGH (una fuente se define como una entidad capaz de generar valores numéricos para ser utilizados por las demás entidades, Actores y Fuentes).

En base a los histogramas de una serie histórica se genera una transformación no lineal mediante deformadores por paso de tiempo que mapean la serie a EG para

la fuente. En EG el proceso estocástico se modela como un sistema lineal, tal como se presenta en la siguiente ecuación.

$$X_{k+1} = AX_k + \Lambda_k BR_k + S_k$$

Donde X_k es el valor de la señal (estado del proceso) para el paso de tiempo k , A es la matriz de filtros de correlación (que representa la tendencia histórica), B es la matriz global de ruido, R_k es una señal de ruido blanco gaussiano, Λ_k es la matriz de atenuadores de ruido y S_k es el sesgo para el paso k .

El ensamble de pronósticos de caudal se incorpora a la fuente (dentro del sintetizador de aportes hidrológicos) a través de los sesgos y los atenuadores de ruido por paso de tiempo (De Vera et al., 2020; Flieller et al., 2020):

- Se ajusta el sesgo (S_k) para que la salida de la fuente siga en valor esperado al ensamble de pronósticos.
- Se ajustan los atenuadores de ruido (Λ_k) por máxima verosimilitud (que modifican el nivel de ruido que se introduce sobre cada miembro), de modo que el conjunto de miembros de la muestra sintética presente la misma dispersión que el ensamble de pronósticos.

De esta manera, el pronóstico se emplea para ajustar las series sintéticas generadas por el CEGH (que describen la climatología de caudales) según una coyuntura dada por cada pronóstico hidrológico.

2.5 IMPLEMENTACIÓN OPERATIVA

La implementación operativa del acople de las herramientas de modelación hidrológica y simulación del sistema eléctrico comprende cinco pasos, los cuales se describen a continuación y se resumen en la Figura 2-6 (adaptado de De Vera et al., 2021).

- **Descarga de datos y acumulación diaria.** Se descargan y procesan los datos de entrada de precipitación: registros de estaciones en tiempo cuasi-real, estimaciones satelitales GSMAP e IMERG y el ensamble de pronósticos del GEFS. Los totales diarios se acumulan a las 10UTC.
- **Control de calidad de datos.** Previo al algoritmo de combinación, se realiza el control de calidad de la información descargada tanto de las observaciones pluviométricas en superficie como de las estimaciones satelitales, en base a la herramienta "Climate Data Tools" (CDT-IRI). Dicho control se centra en la identificación de valores anómalos ("outliers") e incluye la implementación de testeos espaciales según Scherrer et al. (2011). Los valores de los umbrales utilizados en los controles fueron ajustados de forma manual, buscando eliminar los

valores sospechosos más evidentes en el conjunto de datos históricos disponible.

- **Algoritmo de combinación.** Se implementa el algoritmo de combinación de imágenes satelitales y observaciones pluviométricas en superficie para obtener la estimación de precipitación RK sobre la cuenca de Río Negro.
- **Modelación hidrológica.** En base a la estimación RK y el pronóstico por ensambles de precipitación GEFS, se implementa el modelo GR4J en las 25 subcuencas de la cuenca de aporte a la central Constitución. La escorrentía obtenida en cada subcuenca se transita a lo largo de la red de drenaje utilizando el modelo de Muskingum para simular los ensambles de caudales diarios de aporte a las centrales hidroeléctricas del Río Negro.
- **Simulación del sistema eléctrico.** El ensamble de pronósticos de caudales es integrado al modelo existente del SIN, particularmente al sintetizador CEGH de la sala de simulación de la programación semanal del SimSEEVATES, que optimiza la operación del sistema y define el despacho energético por fuente, los costos de operación y lineamientos para potenciales intercambios.

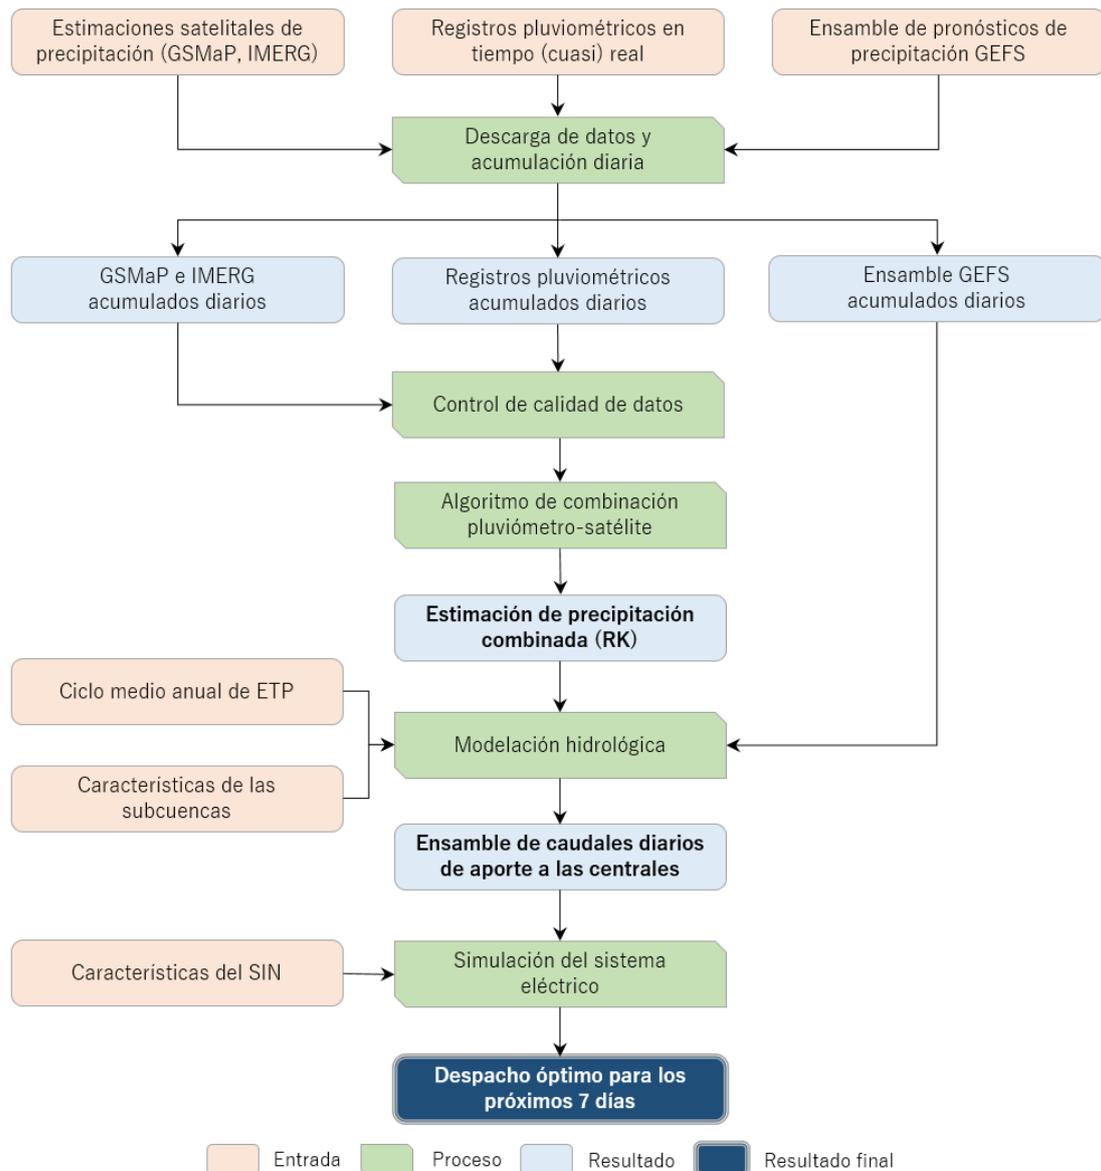


Figura 2-6: Diagrama de flujo de la implementación operativa del modelo hidrológico acoplado al simulador del sistema eléctrico (adaptado de De Vera et al., 2021).

El modelo desarrollado se encuentra integrado al SimSEE desde el 2019 y desde entonces se ha ejecutado bajo la responsabilidad de ADME (cabe destacar que el algoritmo de combinación de imágenes satelitales y observaciones pluviométricas se encuentra operativo desde junio de 2020).

La aplicación (llamada VATES) está continuamente actualizando y ejecutando una sala SimSEE con la representación del sistema de generación uruguaya (integrando la información del estado del SIN y los pronósticos de eólica, solar, hidráulica y la demanda) para generar las distribuciones de las variables de interés de las siguientes 168 horas (7 días) de la operación óptima del SIN.

Los resultados y la información relevantes para la operación se publican automáticamente en el sitio web de ADME: <https://adme.com.uy/>. También

proporcionan la información estadística necesaria para la realización de ofertas de intercambio con otros países, permitiendo especificar el volumen y el precio con niveles de confianza con días de antelación.

2.6 SÍNTESIS

Como producto del trabajo conjunto entre ADME y la Facultad de Ingeniería, se tiene una herramienta operativa de modelación hidrológica de la cuenca del Río Negro acoplada con la simulación del sistema eléctrico del país, que permite optimizar la operación del sistema y definir el despacho energético por fuente, los costos de operación y lineamientos para potenciales intercambios. Hasta la fecha, ADME ha utilizado en su operativa el modelo desarrollado, siendo considerado como la fuente de pronóstico por defecto de las salas de programación para el despacho semanal de la programación de mediano plazo.

La misma estima la precipitación ocurrida sobre la cuenca del Río Negro mediante la combinación de imágenes satelitales y observaciones pluviométricas en superficie en base al uso de modelos de Kriging Universal. Luego, para generar el ensamble de pronósticos de caudales, se alimenta el modelo hidrológico de paso diario GR4J combinado con el modelo Muskingum de tránsito hidrológico con un conjunto de pronósticos de precipitación (modelo GEFS del NCEP-NOAA). El ensamble obtenido se incorpora al sintetizador de aportes del modelo de simulación del sistema eléctrico (SimSEE) a través de los sesgos y una serie de atenuadores por paso de tiempo, ajustados por máxima verosimilitud.

Los resultados y la información relevantes para la operación del sistema se publican diariamente en el sitio web de ADME: <https://adme.com.uy/>.

CAPÍTULO 3

EVALUACIÓN DE LOS PRONÓSTICOS POR ENSAMBLES DE PRECIPITACIÓN Y CAUDAL EN LA CUENCA DEL RÍO NEGRO

3. Evaluación de los pronósticos por ensambles de precipitación y caudal en la cuenca del Río Negro

En este capítulo se presenta la evaluación de la calidad de los pronósticos generados para la cuenca del Río Negro desde la puesta en operación del modelo hidrológico: (i) ensambles de precipitación del modelo GEFS del NCEP-NOAA, empleados como forzantes del modelo hidrológico; y (ii) ensambles de los caudales de aporte a las centrales hidroeléctricas, obtenidos con el modelo actualmente en funcionamiento a partir de los ensambles del GEFS.

La metodología seguida para la evaluación de la calidad de los pronósticos por ensambles de precipitación y caudal se basa en una combinación de indicadores de desempeño y gráficos de diagnóstico, de manera de abarcar diferentes aspectos de la calidad del pronóstico, en este caso el sesgo, la precisión y la confiabilidad.

3.1 DATOS DE REFERENCIA

3.1.1 Precipitación

Los datos históricos empleados para evaluar el ensamble de pronósticos de precipitación GEFS son las estimaciones RK en base a la combinación de imágenes satelitales y observaciones pluviométricas en superficie desarrolladas por De Vera et al. (2021) y actualizadas por Alfaro (2022), presentadas en la sección 2.3.2.1.

En la Figura 3-1 se presenta la serie temporal de la precipitación diaria media areal en la cuenca del Río Negro con cierre en Constitución, obtenida como el promedio ponderado por el área en las 25 subcuencas a partir de la estimación RK para el periodo enero de 2018 a enero de 2023.

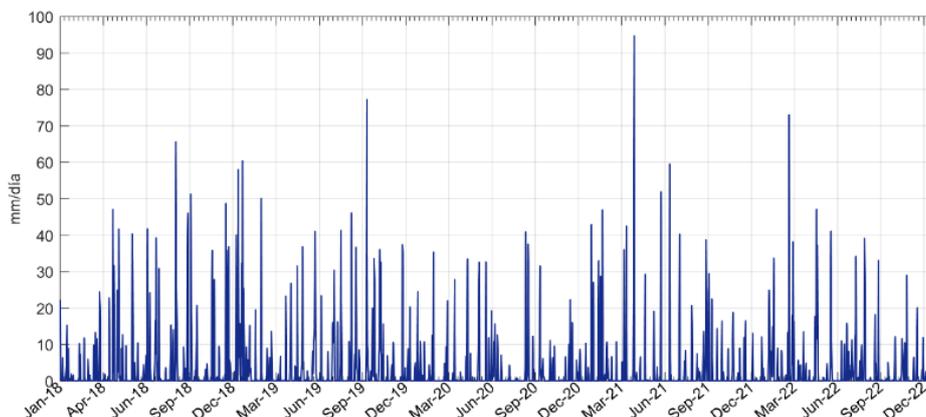


Figura 3-1: Precipitación diaria media areal en la cuenca RN (estimación RK).

3.1.2 Caudal

Para la evaluación de los ensambles de pronósticos de caudal, como referencia, se dispuso de las series diarias de caudales de aporte teóricos a los embalses de G. Terra, Baygorria y Constitución (Figura 3-3) brindadas por la Administración Nacional de Usinas y Trasmisiones Eléctricas de Uruguay (UTE).

Dichas series se denominan “teóricas” ya que consisten en una estimación en base a un balance hídrico en el embalse (Figura 3-2) y no a una observación directa. Específicamente, los caudales de aporte teóricos se obtienen (de forma indirecta) a partir de la medida de la variación de la cota del lago, los caudales turbinados y los caudales vertidos, siendo esta estimación sensible al modelado del lago (curvas para el área y volumen del embalse en función de la cota), al efecto del viento en la superficie del mismo y a la propia estimación de los caudales erogados.

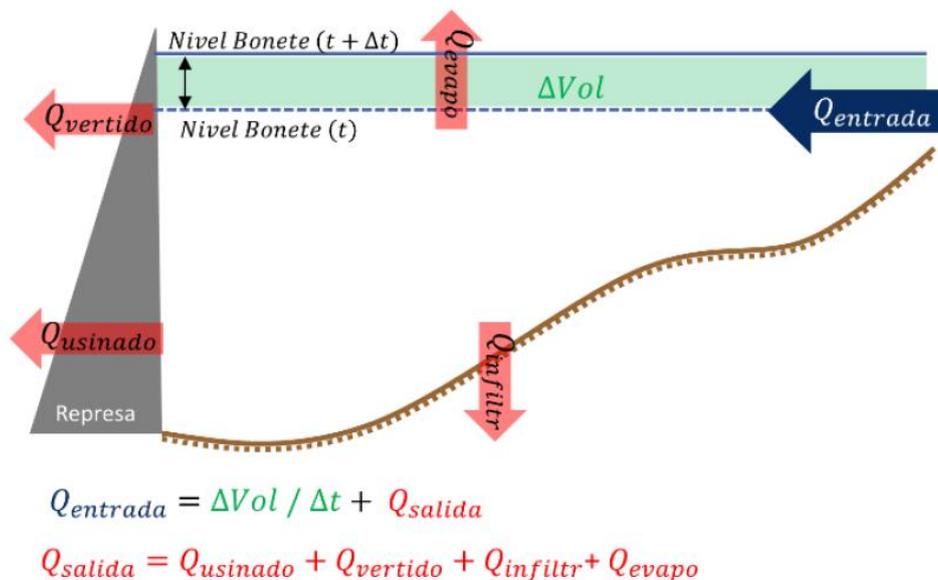


Figura 3-2: : Representación gráfica del balance hídrico en el embalse para estimar el aporte teórico con paso diario (Fuente: IMFIA-IRN, 2022).

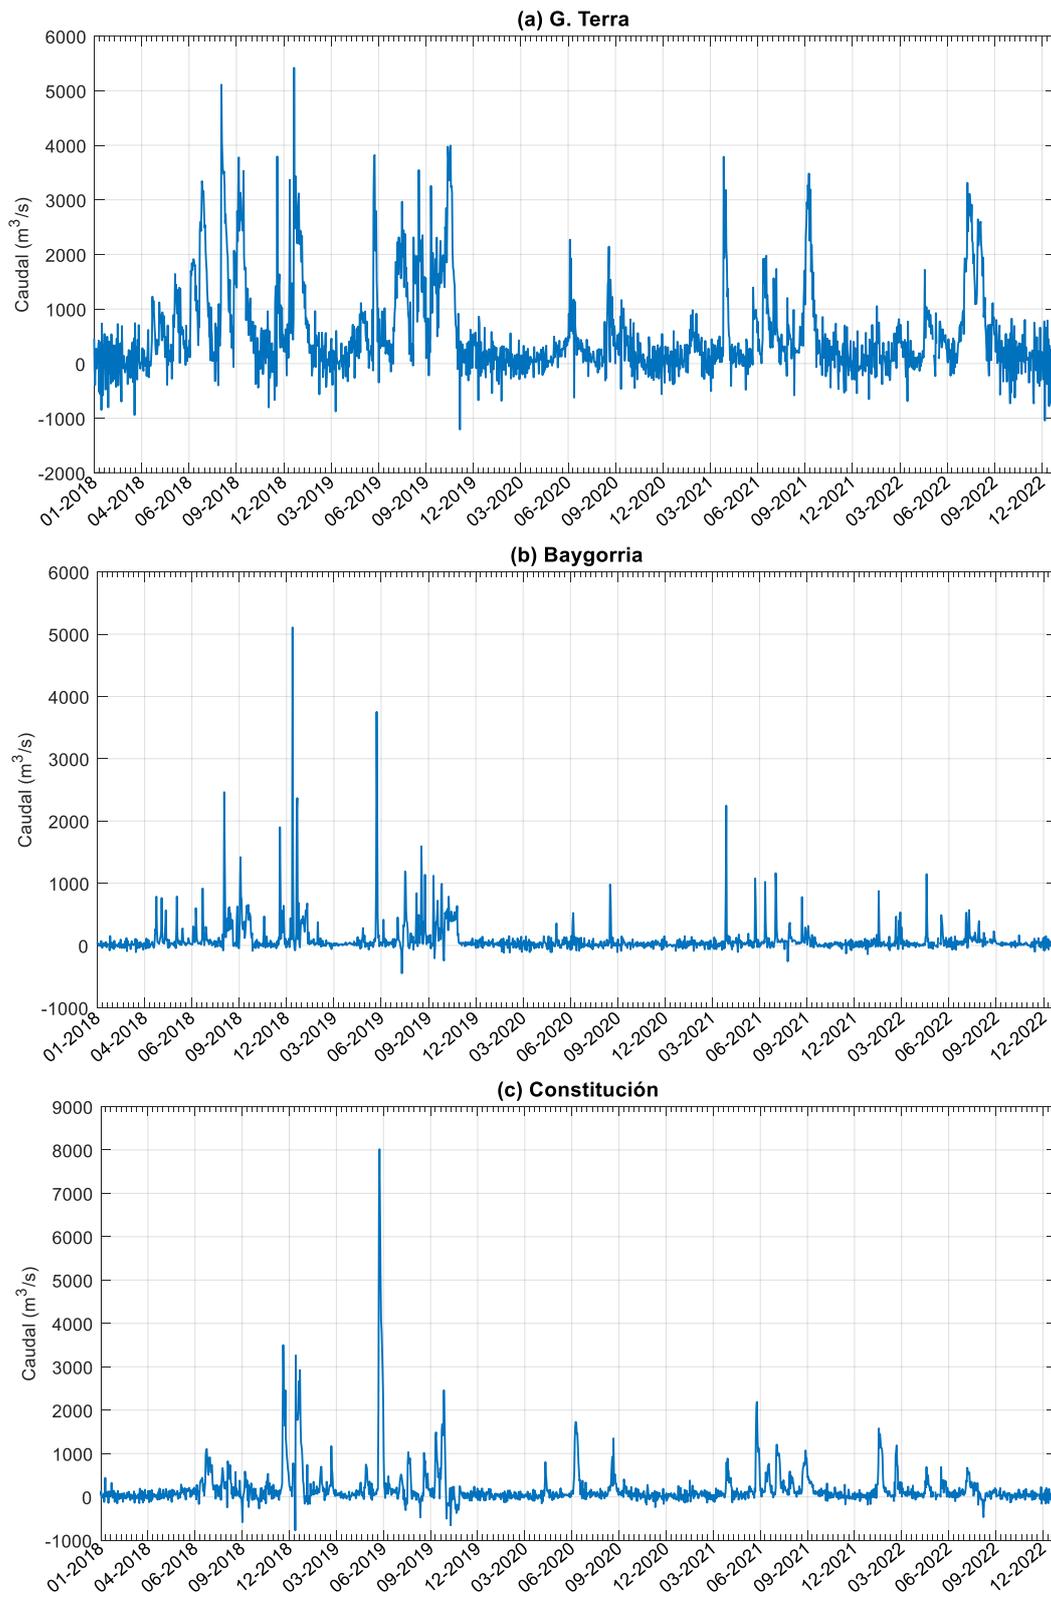


Figura 3-3: Serie diaria de caudales de aporte teórico a las centrales hidroeléctricas del Río Negro: (a) G. Terra, (b) Baygorria incremental y (c) Constitución incremental.

3.1.2.1 Análisis exploratorio de las series “teóricas”

Como se observa en la Figura 3-3, durante el periodo analizado se tienen valores diarios de caudal negativos (del orden del 20% de la longitud de la serie), los cuales pueden deberse al efecto de compensación de valores de caudal excesivos propios de la metodología de estimación (posiblemente asociado a la acción del viento en el embalse y a la hipótesis sobre el tipo de superficie considerada). Este tipo de error en la estimación diaria se anula al considerar promedios de varios días (series “filtradas”) y no afecta a los volúmenes acumulados.

A modo de análisis exploratorio de las series de caudales de aporte teóricos, en la Tabla 3-1 se presenta el porcentaje de datos negativos, la precipitación acumulada en la cuenca, el volumen escurrido acumulado y el coeficiente de escorrentía (definido como el cociente entre el volumen escurrido y la precipitación acumulada) para cada uno de los embalses considerando las correspondientes cuencas incrementales. En la última fila se incluyen también los resultados obtenidos para toda la cuenca de aporte del Río Negro con cierre en Constitución (Cuenca RN). En este caso el “caudal total” en la cuenca RN se obtiene como la suma de los caudales incrementales en las tres centrales. Si bien este caudal no es el que circula realmente por el curso, representa el caudal que “ingresa” diariamente al sistema de represas del Río Negro. El periodo analizado comprende enero de 2018 a enero de 2023.

Tabla 3-1: Análisis exploratorio de las series de caudales teóricos para el periodo enero de 2018 a enero de 2023.

Cuenca	Porcentaje de valores negativos	Área (km ²)	Precipitación acumulada (Hm ³)	Vol. escurrido acumulado (Hm ³)	Coef. de escorrentía medio
G. Terra	19,9%	39.500	239.134	84.101	0,35
Baygorria	21,6%	4.100	23.278	14.516	0,62
Constitución	21,7%	19.180	120.573	29.893	0,25
Cuenca RN	---	62.780	382.985	128.510	0,34

Según DINAGUA (2012), para la región de estudio corresponde un coeficiente de escorrentía promedio anual de entre 0,34 y 0,43 (regiones Centro Sur, Centro Este y Noreste en la Figura 3-4), valor muy próximo al obtenido en G. Terra y en la cuenca RN. Sin embargo, para la cuenca de Baygorria resulta un coeficiente de 0,62 y para Constitución de 0,25. Asumiendo como válida la serie de precipitación (obtenida con la metodología RK), esto refleja una sobreestimación (subestimación) de los caudales de aporte a Baygorria (Constitución). Se entiende que estos errores sistemáticos son mayormente atribuibles a las hipótesis consideradas en el balance hídrico, al efecto del viento en la superficie de los

embalses y a las estimaciones de los caudales erogados (vertido y/o turbinado) en cada central. Tanto Baygorria como Constitución, tienen cuencas de aporte (incrementales) menores a la de G. Terra (con una relación de áreas del 10% y 49% respectivamente) y tienen erogaciones de entrada (caudales erogados por la central localizada aguas arriba) y de salida (caudales erogados por la propia central), por lo que son sensibles a la estimación de dichas erogaciones. En la cuenca RN las estimaciones de erogación en G. Terra y Baygorria no afectan (se cancelan), sí las de Constitución pero se “diluyen” con el aporte de toda la cuenca (no sólo la incremental).

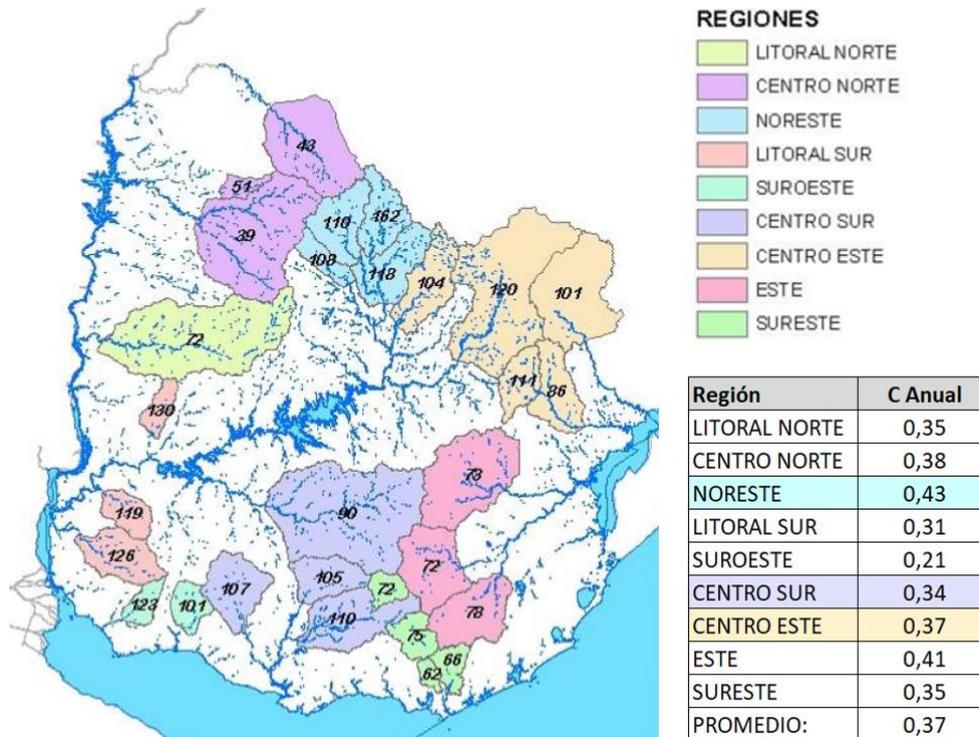


Figura 3-4: Coeficiente de escorrentía en cuencas aforadas según DINAGUA (2012).

Esto constituye una limitante para la evaluación de los pronósticos, así como para la implementación de la metodología de retroalimentación del modelo hidrológico en base a los registros de caudal (a desarrollar en el capítulo 4).

Por lo tanto, para la evaluación de los pronósticos por ensambles de caudal se consideran únicamente los aportes a G. Terra.

3.2 METODOLOGÍA DE EVALUACIÓN

Según Murphy (1993) existen tres tipos de “bondad” de un pronóstico: (i) *consistencia*: un sistema de pronóstico debe proporcionar la mejor y más apropiada información para los usuarios, consistente con el verdadero estado del conocimiento; (ii) *calidad*: es la capacidad del pronóstico para predecir bien un evento de acuerdo con algún criterio objetivo; (iii) *valor*: se refiere a los beneficios

obtenidos por los usuarios cuando el pronóstico se utiliza para informar al proceso de toma de decisiones.

La evaluación de la consistencia y el valor de un pronóstico requiere de forma inherente la consideración del pronosticador y el usuario, y depende de la aplicación para la que se realiza o utiliza. La calidad, por el contrario, se evalúa objetivamente comparando los eventos pronosticados con las observaciones correspondientes. La *verificación de los pronósticos* es el proceso de evaluación de la calidad de los mismos.

Hay muchos indicadores que se pueden utilizar para cuantificar la calidad del pronóstico. En general, se recomienda considerar un conjunto de ellos, de manera de abarcar diferentes *aspectos de la calidad del pronóstico*, dependientes de la aplicación de interés. Entre los principales aspectos (atributos) de la calidad de los pronósticos, se destacan los siguientes: (Bradley et al., 2019; OMM, 2021; Huang & Zhao, 2022):

- Sesgo: describe la diferencia entre el promedio de los pronósticos y la media de las observaciones.
- Precisión: describe la diferencia promedio entre los pronósticos individuales y las observaciones.
- Habilidad: describe la precisión de un pronóstico en relación con un pronóstico de referencia (climatología, persistencia, línea de base, etc.).
- Confiabilidad: describe qué tan bien concuerda en promedio el pronóstico con la observación cuando se emite un pronóstico específico. Para el caso de pronósticos probabilísticos, mide la cercanía entre las probabilidades pronosticadas y la frecuencia observada del fenómeno (condicionada a los valores pronosticados).
- Resolución: describe qué tan distintas son las observaciones para diferentes pronósticos emitidos, es decir, mide la capacidad del pronóstico para distinguir la ocurrencia de la no ocurrencia de un evento (análisis condicionado a los valores pronosticados).
- Nitidez (“Sharpness”): mide el grado de variabilidad de los pronósticos. Para el caso de pronósticos probabilísticos, describe la tendencia a pronosticar valores extremos (probabilidades cercanas a 0% o 100%) en lugar de valores agrupados alrededor de la media (un pronóstico climatológico no tiene “sharpness”).
- Incertidumbre: describe el grado de variabilidad de las observaciones. Es un aspecto importante en el desempeño de un sistema de pronóstico, pero es independiente de la previsión.

En la Tabla 3-2 se presenta un resumen de los indicadores de desempeño más comúnmente empleados en los sistemas de pronósticos hidrometeorológicos operativos.

Ya sea que los indicadores se apliquen a pronósticos determinísticos o probabilísticos de eventos discretos (por ejemplo, definidos como la variable que excede un umbral) o eventos continuos, un proceso de verificación robusto requiere de series temporales de datos largas y homogéneas durante el período de verificación y “pares” de pronóstico-observación que sean representativos de la aplicación de interés.

Tabla 3-2: Indicadores de desempeño comúnmente empleados en sistemas de pronósticos hidrometeorológicos operativos (Fuente: Anctil & Ramos, 2019).

Table 1 Common verification metrics used in operational hydrometeorological forecasting

Quality attribute	Metric name	Type of forecast	Discrete events?
Bias (difference between average forecast and average observation)	Relative mean error (or relative bias)	Single-valued	No
	Frequency bias	Both	Yes
Accuracy (average difference between individual forecasts and observations)	Mean absolute error	Single-valued	No
	Mean square error	Single-valued	No
	Root mean square error	Single-valued	No
	Mean continuous rank probability score (CRPS)	Probabilistic	No
	Brier score	Probabilistic	Yes
	Critical success index (or threat score)	Both	Yes
Correlation (linear relationship between forecasts and observations)	Pearson correlation coefficient	Single-valued	No
	Spearman rank correlation	Single-valued	No
Skill (accuracy of forecast relative to a reference forecast)	Mean absolute error skill score	Single-valued	No
	Mean square error skill score	Single-valued	No
	Mean continuous rank probability skill score	Probabilistic	No
	Brier skill score	Probabilistic	Yes
	Equitable threat score (or Gilbert skill score)	Both	Yes
Reliability (agreement of forecast with observation conditioned on the forecast issued)	Mean square error reliability	Single-valued	No
	Mean CRPS reliability	Probabilistic	No
	Brier score reliability	Probabilistic	Yes
	Reliability diagram	Probabilistic	Yes
	Rank histogram	Probabilistic	Yes
Resolution (differences in outcomes for different forecasts issued)	Success ratio	Both	Yes
	Mean square error resolution	Single-valued	No
	Mean CRPS resolution	Probabilistic	No
Type-2 conditional bias (agreement of observation with forecast conditioned on outcome)	Brier score resolution	Probabilistic	Yes
	Mean square error type-2 conditional bias	Single-valued	No
	Brier score type-2 conditional bias	Probabilistic	Yes

(continued)

Table 1 (continued)

Quality attribute	Metric name	Type of forecast	Discrete events?
Discrimination (differences in forecasts for different outcomes)	Mean square error discrimination	Single-valued	No
	Brier score discrimination	Probabilistic	Yes
	Relative operating characteristic score	Both	Yes
	Relative operating characteristic diagram	Both	Yes
	Probability of detection (or hit rate)	Both	Yes
Sharpness (degree of variability of the forecasts or concentration of the predictive distributions)	Probability of false detection (or false alarm rate)	Both	Yes
	Forecast frequency histogram	Probabilistic	Yes
	Average width of the prediction intervals	Probabilistic	No

3.2.1 Precipitación

En primer lugar, se evaluó la calidad del pronóstico de precipitación por ensambles a 15 días del modelo GEFs en la cuenca del Río Negro, tomando como referencia la estimación en base a la combinación de imágenes satelitales y observaciones en superficie. Si bien el GEFs está disponible con un horizonte de pronóstico de 16 días (384 hrs), para la evaluación se consideró hasta el día 15 ya que no todos los ciclos de pronósticos disponibles llegaban a 16 días. En la implementación operativa en ADME se consideran los pronósticos hidrológicos a 7 días (sala de corto plazo) y a 14 días (sala de mediano plazo).

Para la evaluación se empleó la versión V12 del GEFs (Zhou et al., 2022), compuesta por la corrida de control más 30 miembros perturbados, y se consideró únicamente la simulación iniciada a las 00UTC (por ser la que utiliza ADME en las salas de programación para el despacho semanal).

La evaluación (análoga) de la versión V11 del GEFs (Zhou et al., 2017), que fue la que se empleó desde la puesta en operación del modelo hidrológico hasta octubre de 2020, se presenta en De Vera et al. (2022).

El periodo analizado comprende noviembre de 2020 a diciembre de 2022, por lo que se dispone de 777 ciclos de pronóstico. Cabe destacar que, en Uruguay, dicho periodo se identifica particularmente como un periodo de déficit hídrico. A modo de ejemplo, en la Figura 3-5 se presentan los mapas del Índice de Precipitación Estandarizado (IPE) para el trimestre octubre, noviembre y diciembre (OND) del 2020 y para los años 2021 y 2022 (extraídos de la página web de INUMET). El IPE mide el exceso o déficit de precipitación para un sitio y escala temporal determinados, comparando el acumulado de precipitación para ese lugar y

período contra valores históricos de un período de referencia (en este caso, 1981-2010). El valor no incorpora ninguna información sobre la retención de agua en el suelo ni las características de la cubierta vegetal, refiere únicamente al nivel de precipitación registrado en referencia a un período histórico. Valores del IPE mayores a 0 indican superávit de precipitación con referencia al promedio histórico, y valores menores que 0 indican déficit. Para cualquier escala temporal, un período seco comienza cuando el IPE se hace negativo por primera vez y finaliza cuando se torna positivo. En el caso que el IPE sea continuamente negativo y alcance el valor -1 o menor, se considera que la deficiencia de agua es suficientemente importante como para definir una "sequía meteorológica". La misma puede alcanzar distinta severidad: $IPE \leq -2$: Extremadamente Seco (sequía extrema), $-2 < IPE \leq -1,5$: Muy Seco (sequía severa), $-1,5 < IPE \leq -1$: Moderadamente Seco (sequía moderada), $-1 < IPE \leq -0,5$: Ligeramente Seco, $-0,5 < IPE < 0,5$: Normal (fuente: <https://www.inumet.gub.uy/clima/recursos-hidricos/indice-de-precipitacion>).

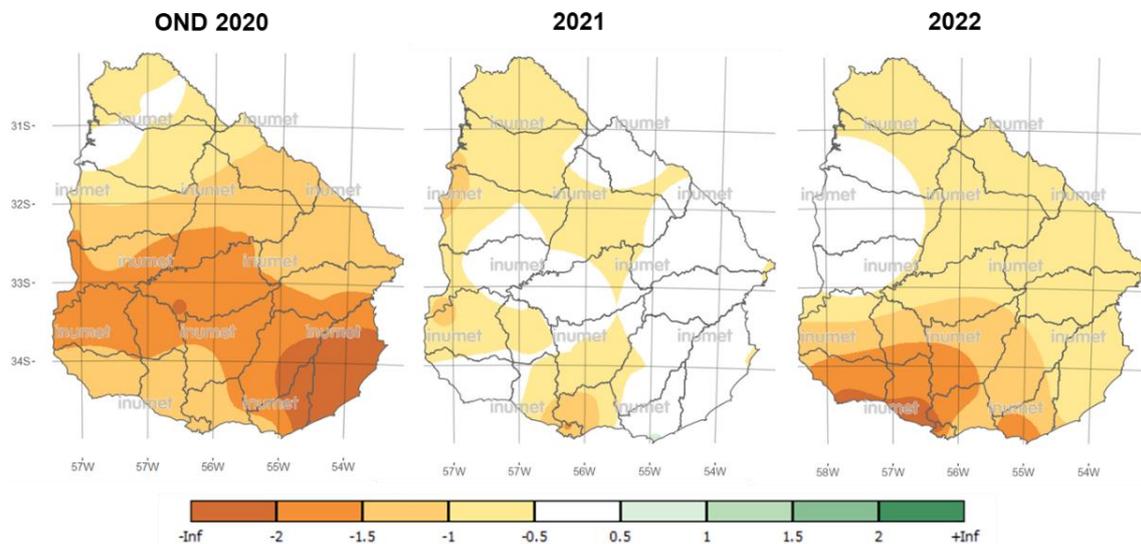


Figura 3-5: Mapas del Índice de Precipitación Estandarizado (IPE) para el trimestre octubre, noviembre y diciembre (OND) del 2020 y para los años 2021 y 2022.

Fuente: <https://www.inumet.gub.uy/clima/recursos-hidricos/indice-de-precipitacion>

Se observa que durante el periodo analizado mayoritariamente se tienen valores de IPE de entre -0,5 y -2 en la cuenca del Río Negro (región Centro Este de Uruguay). Esta condición, como se verá más adelante, incide en el desempeño de los pronósticos de caudal ya que el modelo hidrológico empleado no fue calibrado específicamente para caudales de estiaje.

Para la evaluación se consideró una resolución temporal diaria (acumulado de las últimas 24 horas a las 10UTC) y una agregación espacial en cuatro grandes cuencas, las cuales se presentan en la Figura 3-6:

- TBO: subcuenca del río Tacuarembó (16.171 km²)

- BON: subcuenca incremental de aporte a G. Terra (24.724 km²)
- PAL: subcuenca incremental de aporte a Constitución (22.014 km²)
- RN: cuenca "total" de aporte del Río Negro con cierre en Constitución (62.900 km²).

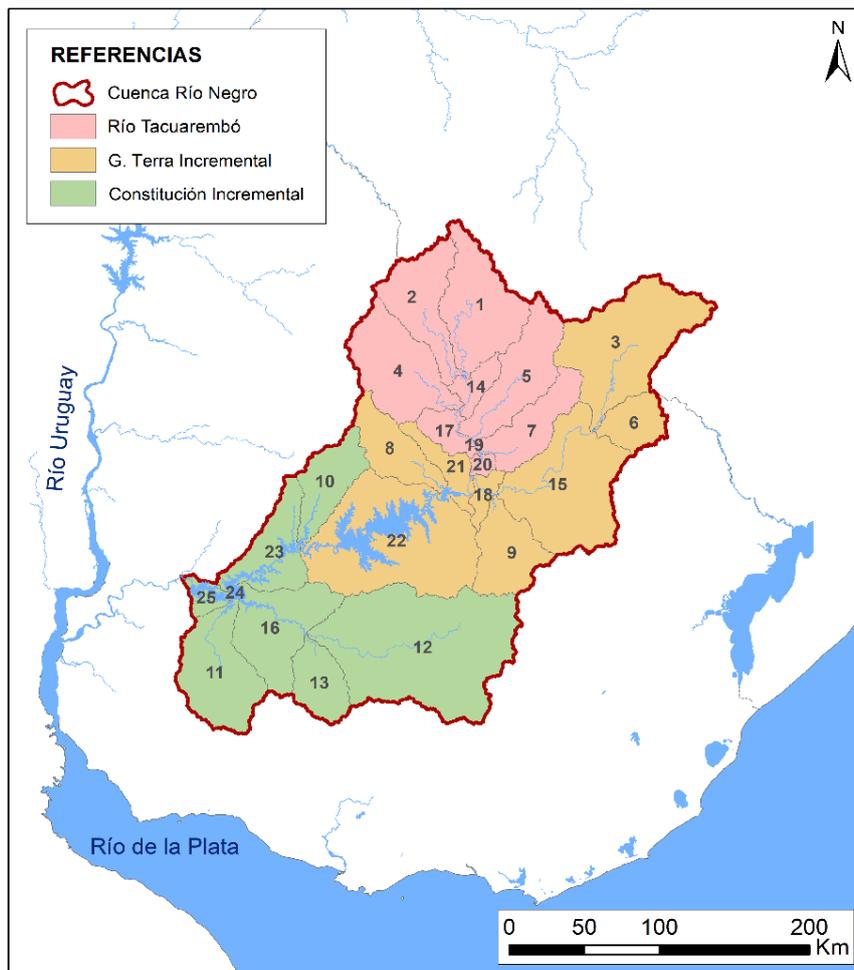


Figura 3-6: Subcuencas consideradas para la evaluación de los pronósticos de precipitación.

La metodología desarrollada se divide en cuatro etapas.

1. Descarga³ y procesamiento de los datos del modelo GEFS.
 - Agregación temporal: Diaria (a las 10UTC).

³ Los pronósticos del GEFS se descargaron del siguiente link, generado por ADME a los efectos de este trabajo: http://pronos.adme.com.uy/gfs_ensemble.php, agregando el ID de la bajada y la variable de interés (por ejemplo: https://pronos.adme.com.uy/gfs_ensemble.php?bajada=2715&vars=precipitation).

- Agregación espacial en subcuencas (dos niveles): 25 subcuencas del modelo hidrológico y 4 grandes cuencas (TBO, BON, PAL, RN).
2. Revisión y selección de indicadores de desempeño para pronósticos probabilísticos.
 3. Evaluación de la precipitación diaria.
 - Caracterización del error y la dispersión del ensamble a lo largo del horizonte de pronóstico (considerando la media del ensamble, la corrida de control y el ensamble completo).
 - Construcción de los histogramas de análisis de rangos (Diagramas de Talagrand) a lo largo del horizonte de pronóstico.
 - Distribución del error del ensamble según intervalos de precipitación observada a lo largo del horizonte de pronóstico.
 - Evaluación del desempeño por subcuenca incremental (TBO, BON y PAL).
 4. Evaluación de la precipitación acumulada a 7 días.

Considerando que el modelo hidrológico se emplea como una herramienta de apoyo a la toma de decisión de la programación semanal, y de manera de minimizar el impacto de un “corrimiento en días” de los pronósticos, se propuso realizar una evaluación del desempeño para los acumulados de precipitación a 7 días.

- Análisis exploratorio de las distribuciones de precipitación acumulada (considerando la media del ensamble y el ensamble completo).
- Distribución del error del ensamble según intervalos de precipitación observada a lo largo del horizonte de pronóstico.
- Identificación de bimodalidad en la distribución del ensamble de precipitación acumulada y análisis de rangos.

3.2.2 Caudal

Una vez evaluado el pronóstico de precipitación por ensambles del modelo GEFS en la cuenca del Río Negro, se procedió a la evaluación del desempeño de los ensambles de pronósticos de caudales de aporte a las centrales hidroeléctricas obtenidos a partir del modelo hidrológico alimentado por los pronósticos del GEFS, tomando como referencia los caudales teóricos de UTE.

Se recuerda que debido a las limitaciones identificadas en la sección 3.1.2.1, únicamente se evaluaron los aportes al embalse de G. Terra. En este sentido, para

la evaluación se considera la serie diaria filtrada mediante un filtro binomial con una ventana centrada de 7 días (presentada en la Figura 3-7).

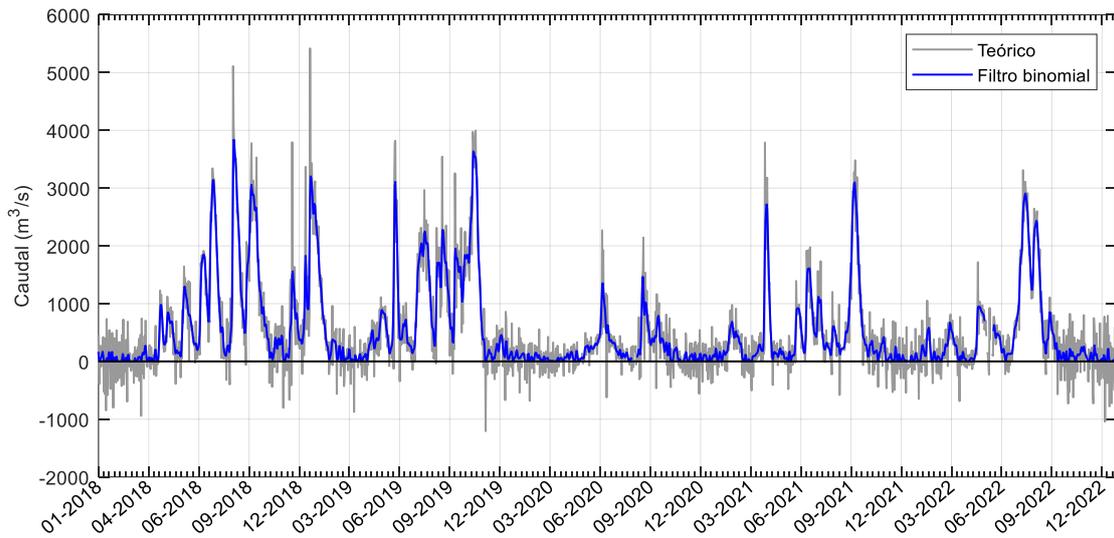


Figura 3-7: Serie diaria filtrada de caudales de aporte teóricos al embalse de G. Terra.

La metodología seguida para la evaluación de los ensambles de pronósticos de caudales es análoga a la desarrollada para los ensambles de pronósticos de precipitación diaria:

- Caracterización del error y la dispersión del ensamble a lo largo del horizonte de pronóstico (considerando la media del ensamble y el ensamble completo).
- Construcción de los histogramas de análisis de rangos (Diagramas de Talagrand) a lo largo del horizonte de pronóstico.
- Distribución del error del ensamble según intervalos de caudal teórico a lo largo del horizonte de pronóstico.
- Comparación del desempeño en las dos cuencas consideradas (G. Terra y RN).

Adicionalmente, se incluyó la inspección visual de la evolución de los pronósticos de caudales a lo largo del horizonte de pronóstico y el cálculo de algunos indicadores de desempeño comúnmente utilizados en modelación hidrológica, como son el porcentaje de sesgo (PBIAS) y el coeficiente de eficiencia de Nash-Sutcliffe (NSE), definidos según:

$$PBIAS (\%) = 100 * \frac{\sum_{i=1}^N (Q_{sim}(i) - Q_{obs}(i))}{\sum_{i=1}^N (Q_{obs}(i))}$$

$$NSE = 1 - \frac{\sum_{i=1}^N (Q_{obs}(i) - Q_{sim}(i))^2}{\sum_{i=1}^N (Q_{obs}(i) - \mu_{obs})^2}$$

El PBIAS mide la tendencia promedio de la serie simulada a ser más grande o más pequeña que los valores observados. El valor óptimo de PBIAS es de 0. Los valores positivos indican un sesgo a la sobreestimación del modelo, mientras que los valores negativos indican una subestimación del mismo.

El NSE mide cuánto de la variabilidad de las observaciones es explicada por el modelo, en comparación con el uso de su media (μ_{obs}) como predicción. Si la simulación es perfecta, $NSE = 1$, mientras que $NSE < 0$ indica que la performance del modelo es peor que simplemente considerar el promedio de las observaciones.

Por último, con el propósito de “cuantificar” el impacto de la falta de asimilación de datos de caudal observados en la versión actual del modelo, se calculó el error al inicio de la simulación. En particular, se compara el valor del caudal teórico filtrado en el “día 0” con el obtenido con el modelo hidrológico alimentado por la estimación de precipitación a partir de la combinación de observaciones en superficie y estimaciones satelitales (estimación RK). Cabe destacar que dicho error inicial es el mismo para todos los miembros del ensamble, ya que únicamente depende de la representación de la precipitación histórica y de su transformación a caudal (es independiente de los pronósticos del GEFS).

3.3 RESULTADOS

3.3.1 Precipitación

3.3.1.1 Precipitación diaria

En primer lugar, se presentan los resultados obtenidos para toda la cuenca de aporte del Río Negro con cierre en Constitución (RN). Luego, se presenta una comparación de los resultados para las cuencas incrementales consideradas (TBO, BON y PAL).

Caracterización de la evolución del error y la dispersión del ensamble

En la Figura 3-8 se presenta un gráfico de caja (boxplot) con la evolución del error de la media del ensamble (calculado como la distancia entre la media y la observación) a lo largo del horizonte de pronóstico. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes) en los ciclos de pronóstico. Adicionalmente, se superpone la dispersión del ensamble (calculada como la desviación estándar de los miembros del ensamble). La línea punteada representa +/- la mediana de la dispersión del ensamble para los 777 ciclos analizados.

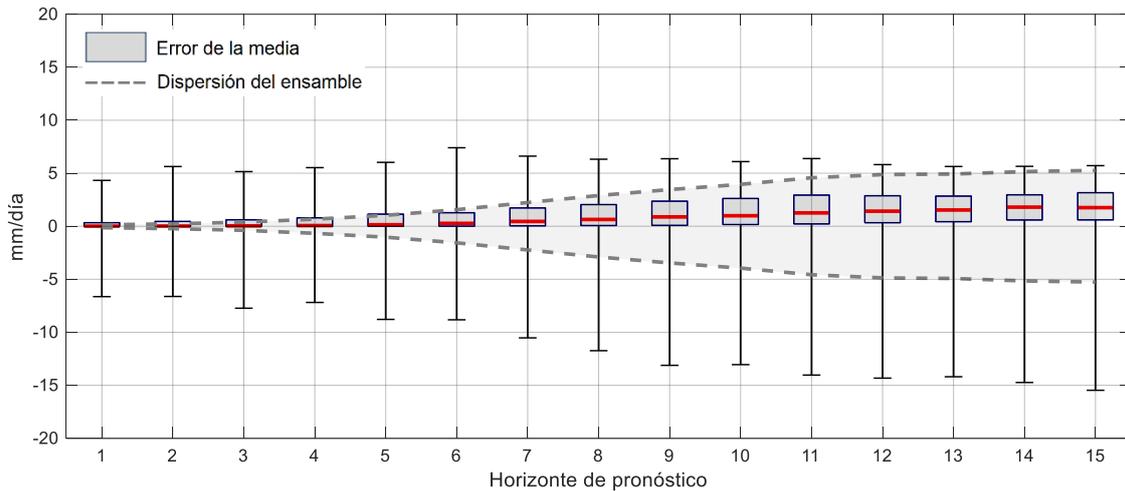


Figura 3-8: Evolución del error de la media (boxplot) y de la dispersión (línea punteada) del ensamble a lo largo del horizonte de pronóstico para la cuenca RN. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes).

Se observa que, como era de esperar, a medida que se avanza en el horizonte de pronóstico, aumenta la dispersión de los miembros del ensamble y el error de su media, es decir que disminuye la predictibilidad del sistema. A partir de los 11 días tanto el error como la dispersión se estabilizan, el error de la media se mantiene “cuasi-estable” en 1,5-2 mm y la dispersión del ensamble tiende a una asíntota de 5 mm. Se observa también una asimetría en la distribución del error de la media del ensamble, mientras que la tendencia central de los errores es hacia valores positivos (el pronóstico es mayor que la observación), la distribución tiene asimetría negativa, es decir que los valores extremos negativos (subestimación) son, en valor absoluto, notoriamente mayores que los positivos (sobreestimación). Esta asimetría aumenta con el horizonte de pronóstico.

A modo de referencia, en la Figura 3-9 se presenta la comparación de la evolución del error de la media del ensamble (serie gris) y de la corrida de control (serie celeste) a lo largo del horizonte de pronóstico. La corrida de control tiene como condición inicial la mejor estimación del estado de la atmósfera sin perturbación adicional. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes) en los ciclos de pronóstico.

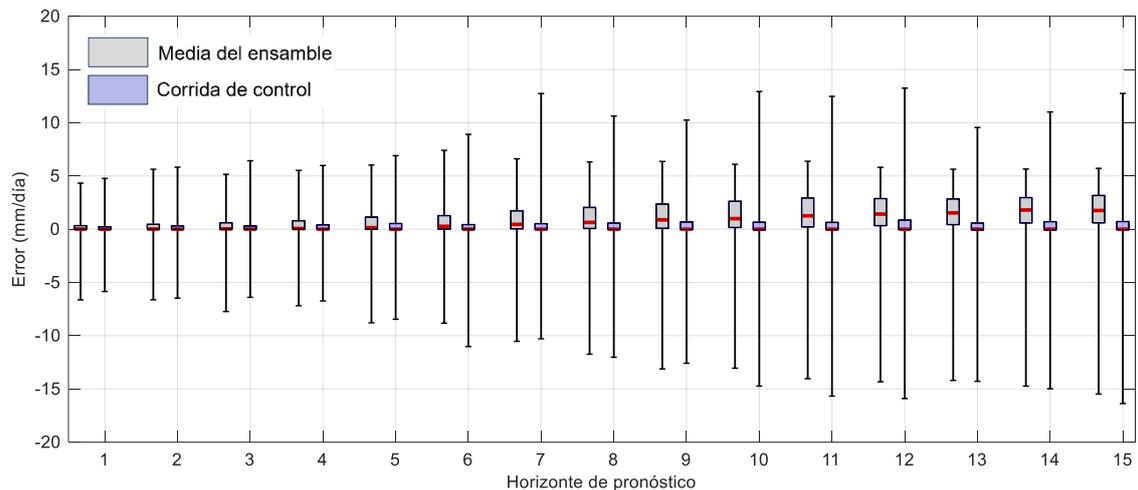


Figura 3-9: Comparación de la evolución del error de la media del ensemble (serie gris) y de la corrida de control (serie celeste) a lo largo del horizonte de pronóstico para la cuenca RN. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes).

Se verifica que la mediana (línea roja) del error de la corrida de control se mantiene en 0 mm, no sufre el sesgo ya señalado en la media del ensemble. La distribución del error de la corrida de control es mucho menos asimétrica que la de la media del ensemble, pero su dispersión es significativamente mayor, como es de esperar pues la corrida de control es única en cada ciclo de pronóstico y no la media de 30 miembros del ensemble.

Finalmente, en la Figura 3-10 se presenta la evolución a lo largo del horizonte de pronóstico de la raíz del error cuadrático medio (RMSE) de los miembros del ensemble, en superposición con la dispersión del ensemble (línea punteada). Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes) para los 777 ciclos analizados. El RMSE del ensemble para cada ciclo de pronóstico y horizonte considerado (t) se calcula como la raíz de la suma del error cuadrático de cada miembro (m) del ensemble dividida el número total de miembros ($N = 30$):

$$RMSE(t) = \sqrt{\frac{\sum_{m=1}^N (Q_{obs}(t) - Q_{sim}(t, m))^2}{N}}$$

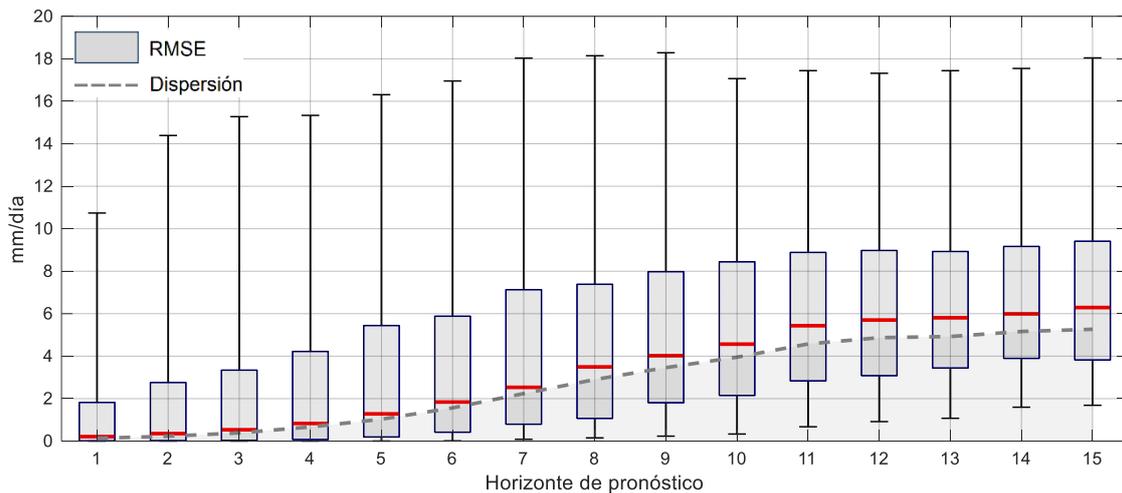


Figura 3-10: Evolución del RMSE (boxplot) y dispersión (línea punteada) del ensamble a lo largo del horizonte de pronóstico para la cuenca RN. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes).

En la figura anterior nuevamente se observa que el error del ensamble crece a medida que se avanza en el horizonte de pronóstico, alcanzando un valor medio “cuasi-estable” de 6 mm a partir del día 11.

Histogramas de análisis de rangos

El histograma de análisis de rangos o Diagrama de Talagrand (Talagrand et al., 1997) es un tipo de histograma en el cual las frecuencias mostradas por las barras representan el porcentaje de veces que la observación o el análisis (el dato empleado para la verificación) cae en los rangos o las clases definidas por los miembros del pronóstico por ensambles. La primera clase representa el rango hasta el miembro del conjunto de la clase más baja, mientras que la última clase representa el rango por encima del miembro del conjunto en la clase más alta. Esto significa que hay $n+1$ clases en el diagrama donde n es el número de miembros del ensamble (en este caso, $n = 30$).

La forma del diagrama, nos permite extraer conclusiones sobre los sesgos del sistema de pronóstico y el alcance de su dispersión. Adicionalmente, puede incluirse en el diagrama la curva (línea horizontal) que representa la frecuencia teórica en cada categoría para un sistema de pronóstico por ensamble perfectamente confiable. Esta frecuencia es $1/(n+1)$. Esto supone que, si el sistema de pronóstico está bien construido, en una muestra grande cada miembro tiene la misma probabilidad de verificarse, es decir, que el esquema de generación crea un rango de miembros igualmente válidos.

Cabe destacar que un histograma de rango “plano” no necesariamente indica que el pronóstico tenga habilidad. Sólo mide si la distribución de probabilidad observada está bien representada por el ensamble.

En base al histograma de análisis de rangos se define un indicador “dif_max” (no paramétrico) que cuantifica la desviación con la horizontalidad, en particular representa la máxima diferencia entre las frecuencias acumuladas:

$$\text{dif_max} = \max_{1 \leq k \leq n+1} \left[\text{abs} \left(\sum_k f_{obs}^k - k \cdot \frac{1}{n+1} \right) \right]$$

donde f_{obs}^k es la frecuencia de las observaciones en el intervalo k , es decir, el porcentaje de veces que la observación cae en dicho rango.

En el panel superior de la Figura 3-11 se presenta la evolución del indicador dif_max a lo largo del horizonte de pronóstico. En los paneles inferiores se presentan los histogramas de rangos para el primer y último día de pronóstico, así como para el horizonte en que el indicador es mínimo (en este caso: día 7).

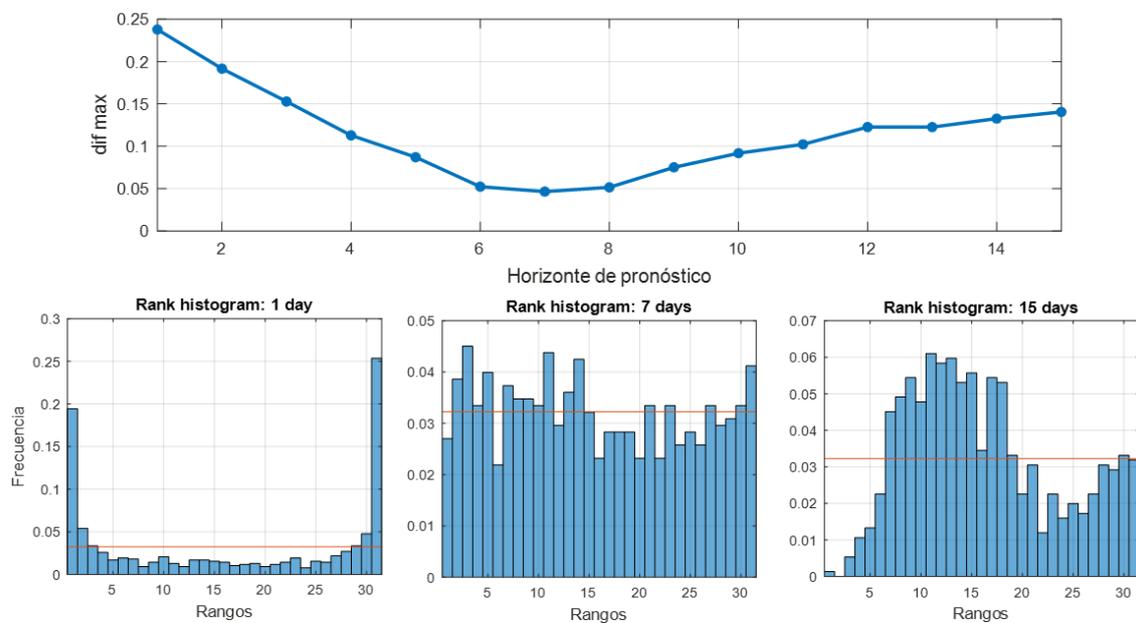


Figura 3-11: Evolución del indicador dif_max a lo largo del horizonte de pronóstico (panel superior) e histogramas de análisis de rangos para los días 1, 7 y 15 (paneles inferiores) para la cuenca RN.

Se observa que en los primeros días es cuando mayor es el indicador dif_max, es decir más se aleja la forma del diagrama de la horizontalidad, mientras que el mínimo se da a los 7 días. Durante los primeros días del pronóstico (panel inferior izquierdo) el diagrama tiene “forma de U” por lo que el ensamble tiene una dispersión excesivamente baja, la observación está demasiado a menudo fuera del rango del ensamble (en el primer y último rango). En los días intermedios (panel inferior central) el ensamble está bien distribuido. Hacia el final del horizonte de pronóstico (panel inferior derecho) el ensamble tiene dispersión alta y con cierto sesgo negativo, la frecuencia del primer rango es prácticamente nula.

Una virtud, pero a la vez limitante, del indicador anterior es que es *no paramétrico*, no distingue si la ubicación de la observación entre los miembros del ensamble

de pronóstico es para días con altos montos de precipitación o montos insignificantes. Por tanto, en la siguiente sección se presenta otra forma de evaluación que sí distingue estas situaciones.

Distribución del error del ensamble según intervalos de precipitación observada

En la siguiente figura se presenta la distribución del error de los miembros del ensamble según tres intervalos de la precipitación observada para los horizontes 1, 7 y 15 días.

Para ello, se seleccionaron dos umbrales de precipitación (5 y 20 mm) y se clasificaron los ciclos de pronóstico según la precipitación observada en cada uno: $P \leq 5$ mm (del orden de 660 ciclos), $5 \text{ mm} < P \leq 20$ mm (del orden de 90 ciclos) y $P > 20$ mm (del orden de 30 ciclos). Luego, para cada ciclo, se calculó el error (diferencia entre el pronóstico y la observación) de cada uno de los miembros del ensamble, se los agrupó según los intervalos de precipitación observada y se construyeron los histogramas correspondientes.

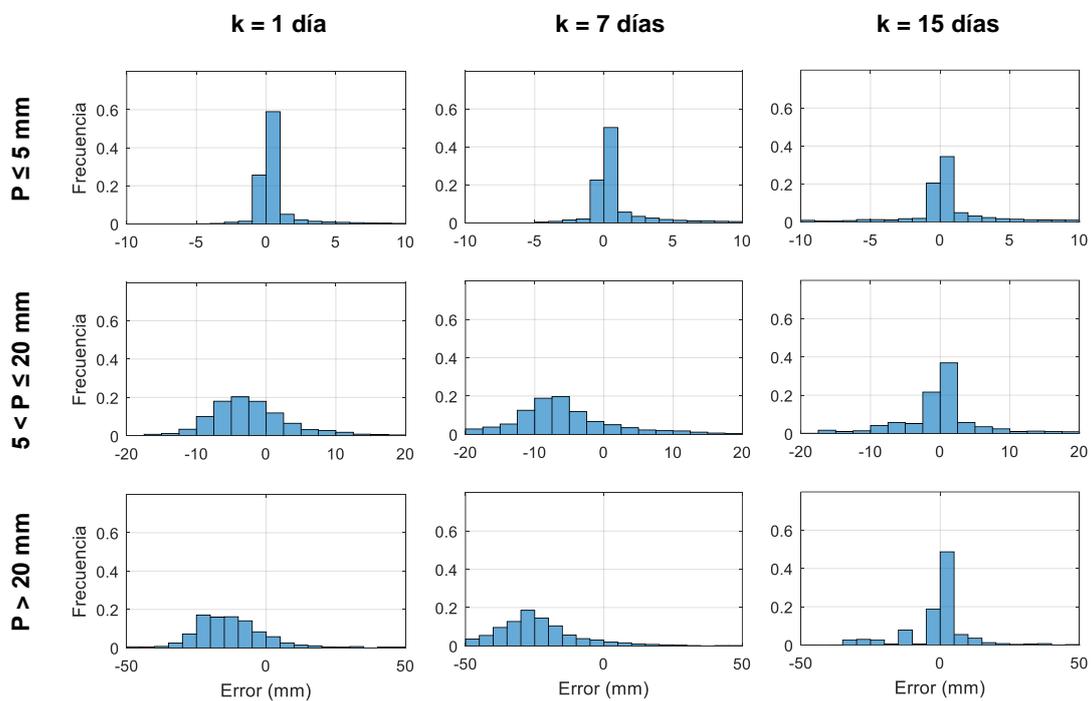


Figura 3-12: Distribución del error de los miembros del ensamble según tres intervalos de la precipitación observada ($P \leq 5$ mm, $5 \text{ mm} < P \leq 20$ mm, $P > 20$ mm) para los horizontes 1, 7 y 15 días en la cuenca RN.

Para los horizontes 1 y 7 días (paneles izquierdos y centrales) se observa que para los montos de precipitación menores a 5 mm (primera fila) la distribución del error del ensamble está centrada en el cero, mientras que para los intervalos de precipitación media y alta (segunda y tercera fila) la distribución presenta sesgos negativos (tendencia a una subestimación). Para el último día del horizonte de

pronóstico (paneles derechos), en los tres intervalos de precipitación considerados la distribución del error del ensamble está centrada en el cero.

Evaluación del desempeño por subcuenca incremental

En la Figura 3-13 se presenta la comparación de la evolución a lo largo del horizonte de pronóstico del error de la media del ensamble y del RMSE de los miembros del ensamble para las cuatro cuencas consideradas (presentadas en la Figura 3-6). En ambos casos, el valor graficado corresponde al percentil 50 de los 777 ciclos analizados.

En general, no se observan grandes variaciones espaciales en el desempeño del pronóstico por ensambles en la cuenca del Río Negro, siendo los resultados obtenidos muy similares para las cuatro cuencas consideradas. La evolución de los errores durante los primeros días de pronóstico es prácticamente indistinguible, comenzando a diferenciarse levemente a partir del día 6. En particular, tanto el error de la media como el RMSE del ensamble, son marginalmente menores en la cuenca PAL (cuenca incremental de Constitución).

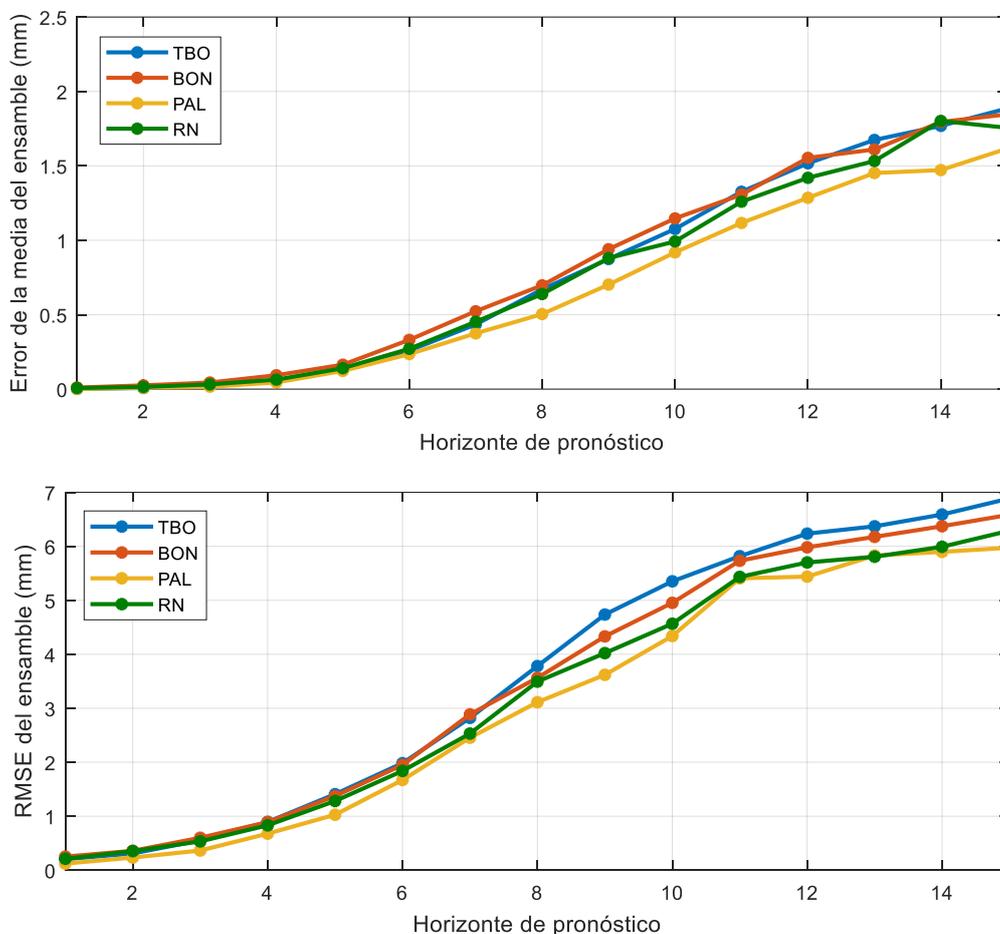


Figura 3-13: Evolución del error a lo largo del horizonte de pronóstico para la media del ensamble y el ensamble completo para las cuatro cuencas consideradas.

En lo que refiere al análisis de los sesgos y la dispersión del sistema mediante la construcción de los histogramas de análisis de rangos y la evaluación del indicador dif_max, los resultados obtenidos son análogos a los presentados para toda la cuenca del Río Negro. En particular se destaca que, en la cuenca incremental de Constitución, en los tres horizontes analizados el sesgo negativo es más acentuado.

3.3.1.2 Precipitación acumulada a 7 días

A continuación, se presentan los resultados obtenidos para toda la cuenca de aporte del Río Negro con cierre en Constitución.

Análisis exploratorio

En la Figura 3-14 se presenta la serie temporal de la precipitación acumulada a 7 días para la estimación RK (puntos azules), la media del ensamble del GEFS (línea negra) y el rango entre el miembro mayor y menor (sombreado gris) para la cuenca RN. Se observa que hay eventos en los cuales construir un “ensamble no equiprobable” asignando distintos pesos a los miembros, en lugar de considerar la media del ensamble, mejoraría el desempeño del pronóstico (los puntos azules caen sobre el sombreado gris, pero están “lejos” -por arriba o por debajo- de la línea negra).

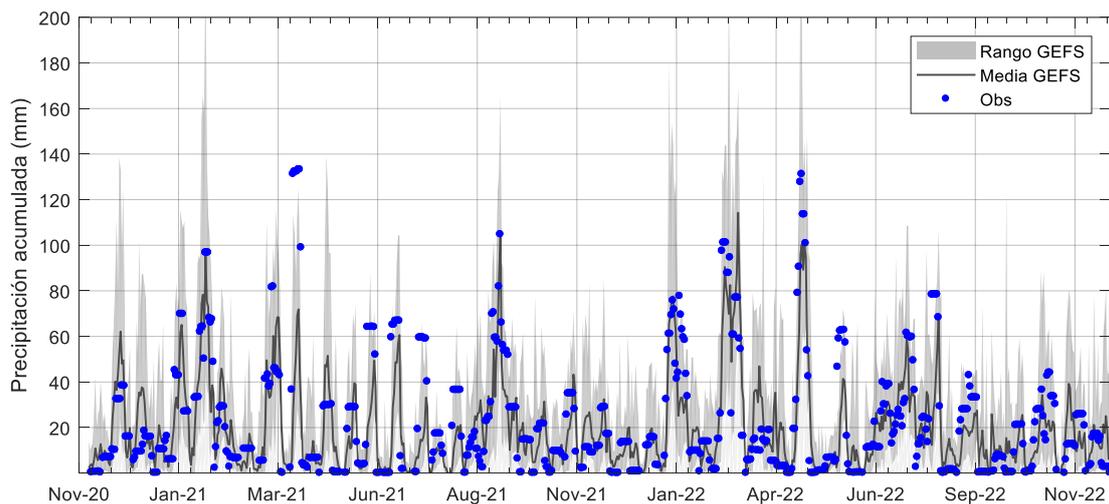


Figura 3-14: Serie temporal de la precipitación acumulada a 7 días para la estimación RK (punto azul), la media del ensamble (línea negra) y el rango entre el miembro mayor y menor (sombreado gris) para la cuenca RN.

Luego, en la Figura 3-15 se presenta la distribución de la precipitación acumulada para la estimación RK (panel izquierdo), el ensamble completo (panel central) y la media del ensamble (panel derecho) para la cuenca RN. Se observa que los pronósticos presentan sesgo a mayor monto de precipitación, el cual se concentra entre los montos de 10 y 40 mm (sobre todo al considerar la media del ensamble).

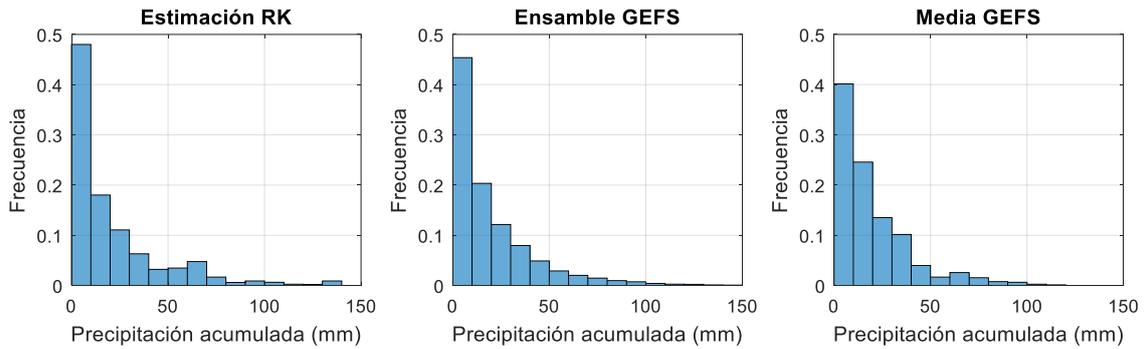


Figura 3-15: Distribución de la precipitación acumulada a 7 días para la estimación RK (panel izquierdo), el ensemble completo (panel central) y la media del ensemble (panel derecho) para la cuenca RN.

Distribución del error del ensemble según intervalos de precipitación observada

En la Figura 3-16 se presenta la distribución del error de los miembros del ensemble según tres intervalos de la precipitación observada. En este caso, por tratarse de precipitación acumulada a 7 días, se seleccionaron los umbrales de 25 y 60 mm: $P \leq 25$ mm (544 ciclos), $25 \text{ mm} < P \leq 60$ mm (156 ciclos) y $P > 60$ mm (77 ciclos).

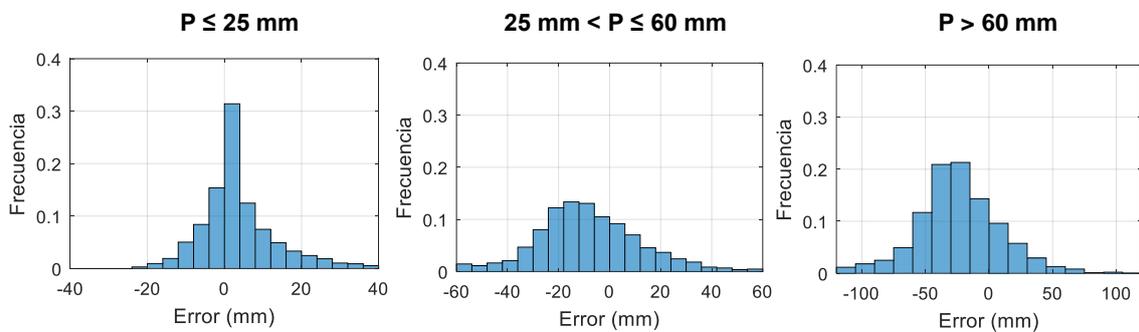


Figura 3-16: Distribución del error de los miembros del ensemble según tres intervalos de la precipitación acumulada observada ($P \leq 25$ mm, $25 \text{ mm} < P \leq 60$ mm, $P > 60$ mm) para la cuenca RN.

Se observa que para los montos de precipitación menores a 25 mm la distribución del error del ensemble está centrada en el cero, mientras que para los intervalos de precipitación media y alta presenta sesgos negativos (tendencia a una subestimación).

Identificación de bimodalidad y análisis de rangos

Por último, con el propósito de avanzar en la identificación de comportamientos bimodales entre los miembros del ensemble, se calculó el coeficiente de bimodalidad de Sarle (BC, SAS Institute 1989) para cada ciclo de pronóstico:

$$BC = \frac{g^2 + 1}{k + \frac{3(n-1)^2}{(n-2)(n-3)}}$$

donde g es el coeficiente de asimetría muestral, k la kurtosis y n el número de elementos de la muestra.

El valor de BC varía entre 0 y 1. La lógica detrás de este coeficiente es que una distribución bimodal con colas ligeras tendrá una kurtosis muy baja, un carácter asimétrico o ambos, todo lo cual aumenta el valor de este coeficiente. El valor de BC para la distribución uniforme es $5/9$ ($\approx 0,56$). Los valores superiores a $5/9$ pueden indicar una distribución bimodal o multimodal, aunque también pueden resultar en distribuciones unimodales muy asimétricas. El valor máximo (1) se alcanza sólo mediante una distribución de Bernoulli con sólo dos valores distintos o la suma de dos funciones delta de Dirac diferentes (una distribución bi-delta).

A modo de ejemplo, en la Figura 3-17 se presenta la distribución de precipitación acumulada del ensamble para dos ciclos de pronóstico en particular, uno “unimodal” con un coeficiente BC de 0,33 (panel izquierdo) y otro “bimodal” con un BC igual a 0,60 (panel derecho). En negro se incluye al valor de la correspondiente precipitación observada.

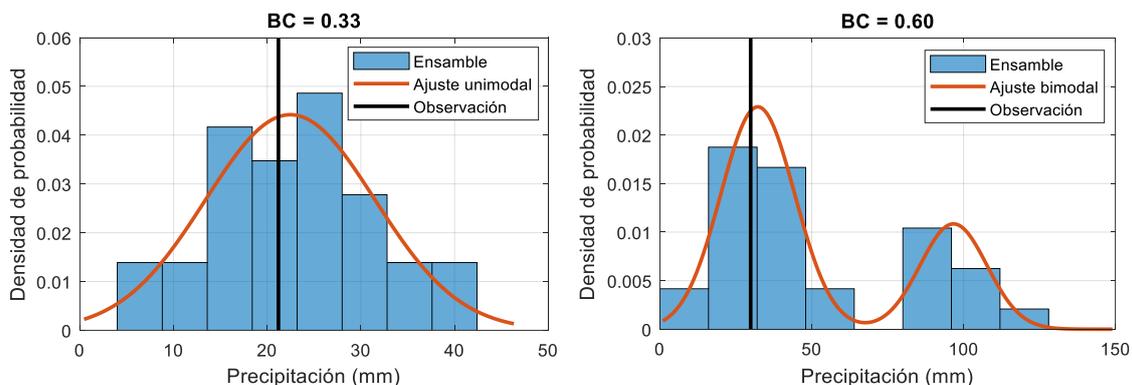


Figura 3-17: Ejemplo de la distribución de precipitación acumulada del ensamble para un ciclo “unimodal” (panel izquierdo) y uno “bimodal” (panel derecho). En negro se incluye al valor de la correspondiente precipitación observada.

En la Figura 3-18 se presenta el diagrama de dispersión del coeficiente BC en función del valor máximo de precipitación pronosticada por el ensamble para cada ciclo de pronóstico (un punto por ciclo). Se incluyen también dos umbrales (líneas rojas), la línea vertical corresponde a un BC de $5/9$ y la línea horizontal corresponde a una precipitación máxima acumulada de 40 mm. Dichos umbrales serán considerados a continuación, para la construcción de los histogramas de análisis de rangos.

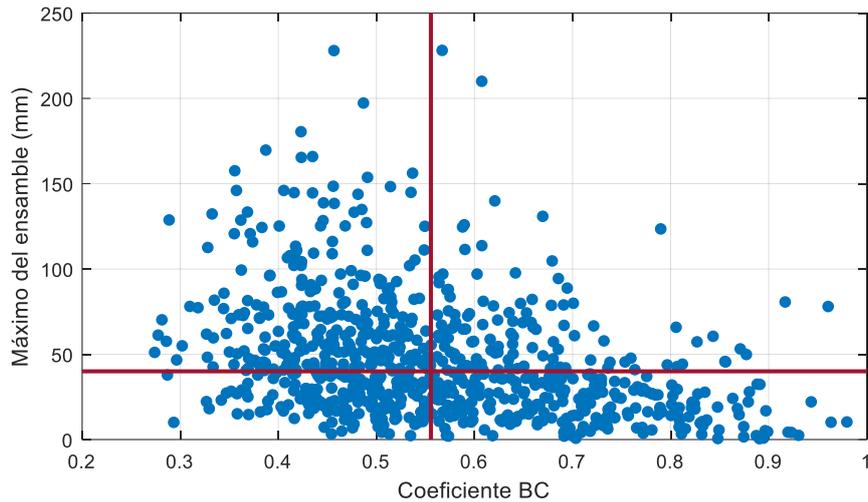


Figura 3-18: Diagrama de dispersión del coeficiente de bimodalidad en función del valor máximo pronosticado por el ensamble para cada ciclo de pronóstico en la cuenca RN (un punto por ciclo).

En la siguiente figura se presentan los histogramas de análisis de rango para: (i) todos los ciclos con una precipitación máxima pronosticada mayor a 40 mm (382 ciclos, panel izquierdo), (ii) los ciclos con una precipitación máxima pronosticada mayor a 40 mm y un coeficiente BC menor o igual a 5/9 (267 ciclos “unimodales”, panel central) y (iii) los ciclos con una precipitación máxima pronosticada mayor a 40 mm y un coeficiente BC mayor a 5/9 (115 ciclos “bimodales”, panel derecho). Se consideraron únicamente los ciclos con una precipitación acumulada máxima mayor a 40 mm ya que aquí nos interesan los días con lluvia, en los que los miembros del ensamble “se separan” entre sí.

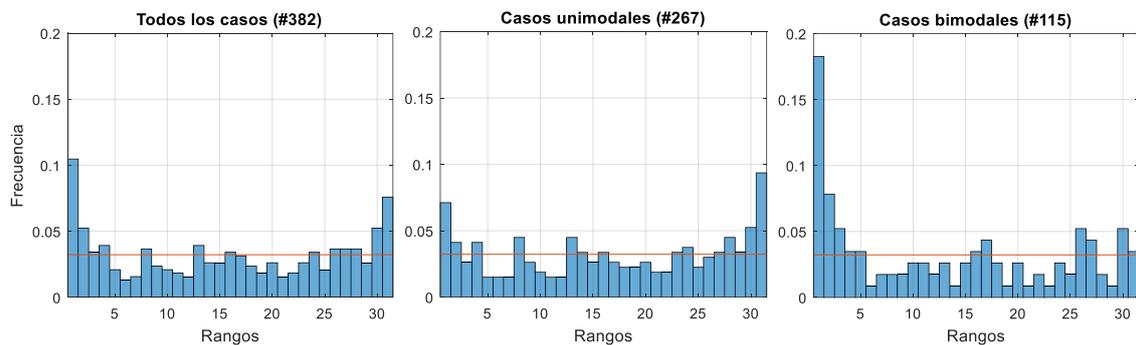


Figura 3-19: Histogramas de análisis de rangos según el coeficiente de bimodalidad para la cuenca RN: todos los ciclos (panel izquierdo), ciclos unimodales (panel central), ciclos bimodales (panel derecho). Se consideraron únicamente los ciclos con una precipitación máxima pronosticada mayor a 40 mm.

Se observa una notoria diferencia en el comportamiento entre los ciclos unimodales y bimodales. En el caso de los ciclos unimodales, el diagrama tiene “forma de U” por lo que el ensamble tiene una dispersión excesivamente baja, la observación está demasiado a menudo fuera del rango del ensamble. Sin embargo, en los ciclos bimodales se tiene una tendencia a la sobrestimación

(sesgo positivo), en aproximadamente el 20% de los casos la observación es menor que el ensamble (primera barra del histograma).

Este resultado sugiere que evaluar diferentes metodologías/procesamientos para los ciclos de pronóstico en función de la bimodalidad del ensamble podría mejorar el desempeño del pronóstico (en el cálculo del coeficiente BC sólo participa el ensamble y no la observación, por lo que puede calcularse “a priori”).

3.3.2 Caudal

A continuación, se presentan los resultados obtenidos en la evaluación del desempeño de los ensambles de pronósticos de caudales de aporte al embalse de G. Terra.

Inspección visual

A modo ilustrativo, en las siguientes figuras se presentan algunos ejemplos de los pronósticos emitidos para la precipitación media areal en la cuenca (panel superior) y los correspondientes caudales de aporte (panel inferior). En el panel superior, el gráfico de barras en azul representa la evolución de la precipitación observada (estimación RK), las líneas continuas grises representan la evolución de cada uno de los miembros del ensamble del GEFS y en trazo gris discontinuo se muestra la evolución de la media del ensamble. En el panel inferior, la línea azul representa la evolución de los caudales teóricos (en trazo grueso se incluye también la serie filtrada), en trazo gris continuo se presenta la evolución de cada uno de los miembros del ensamble y, en trazo gris discontinuo, la evolución de la media del ensamble. En rojo se incluye la evolución del caudal modelado en base a la estimación RK hasta el día del inicio de la simulación del ciclo de pronóstico en cuestión.

En primer lugar, en la Figura 3-20 se puede ver que el caudal teórico oscila en torno al cero durante los periodos de estiaje, lo cual constituye una limitante tanto para la evaluación de los pronósticos como para la implementación de la metodología de asimilación de datos de caudal observados.

En general se observa que, tanto para la precipitación como para el caudal de aporte, las series simuladas capturan satisfactoriamente el comportamiento de las series observadas. En el caso de los pronósticos de caudales, el ensamble presenta muy baja dispersión (prácticamente nula) durante los primeros días del horizonte de pronóstico.

Entre los ciclos de pronóstico seleccionados se identifican ejemplos de omisión⁴ (Figura 3-21, ciclo inicializado el 30/03/2021) y de falsa alarma⁵ (Figura 3-23, ciclo inicializado el 28/04/2022).

Por otro lado, en las Figura 3-22 y Figura 3-23 (ciclo del 25/07/2021) se evidencia la falta de asimilación de datos de caudal observados en la versión actual del modelo, con errores iniciales del orden del $\pm 100\%$ del caudal teórico.

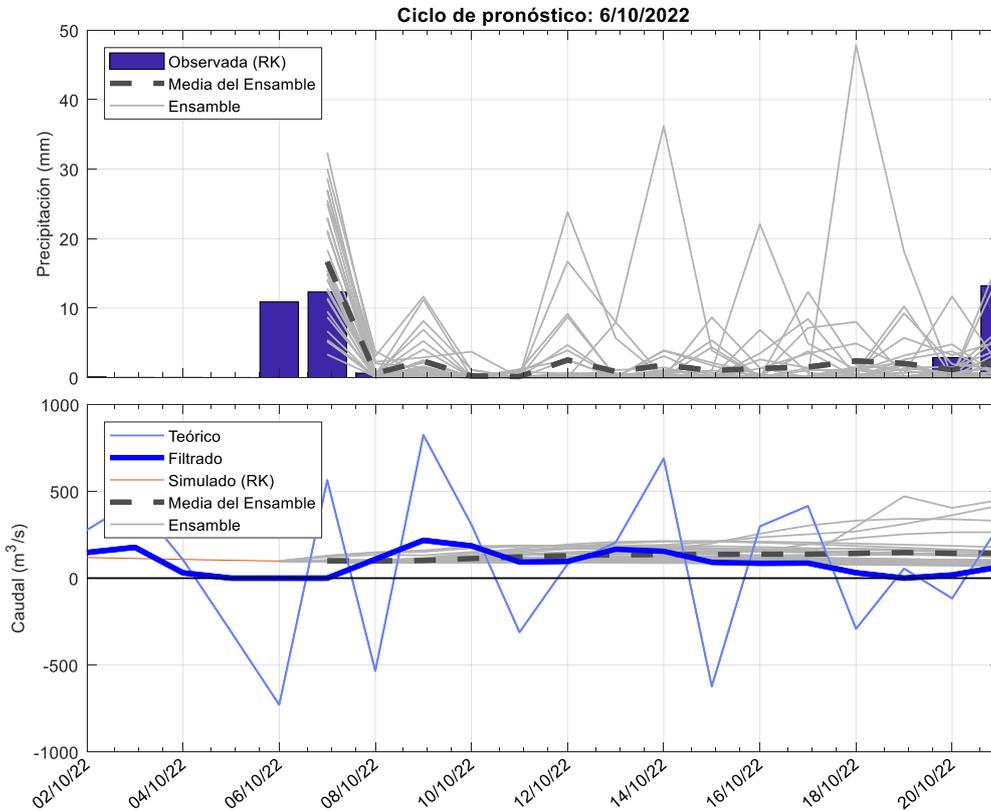


Figura 3-20: Ejemplo de pronósticos para el ciclo inicializado el 6/10/2022 para la cuenca de aporte a G. Terra.

⁴ Dado un umbral X , un caso de “*omisión*” se define cuando la observación es mayor a X y el pronóstico es menor o igual a X .

⁵ Dado un umbral X , un caso de “*falsa alarma*” se define cuando la observación es menor o igual a X y el pronóstico es mayor a X .

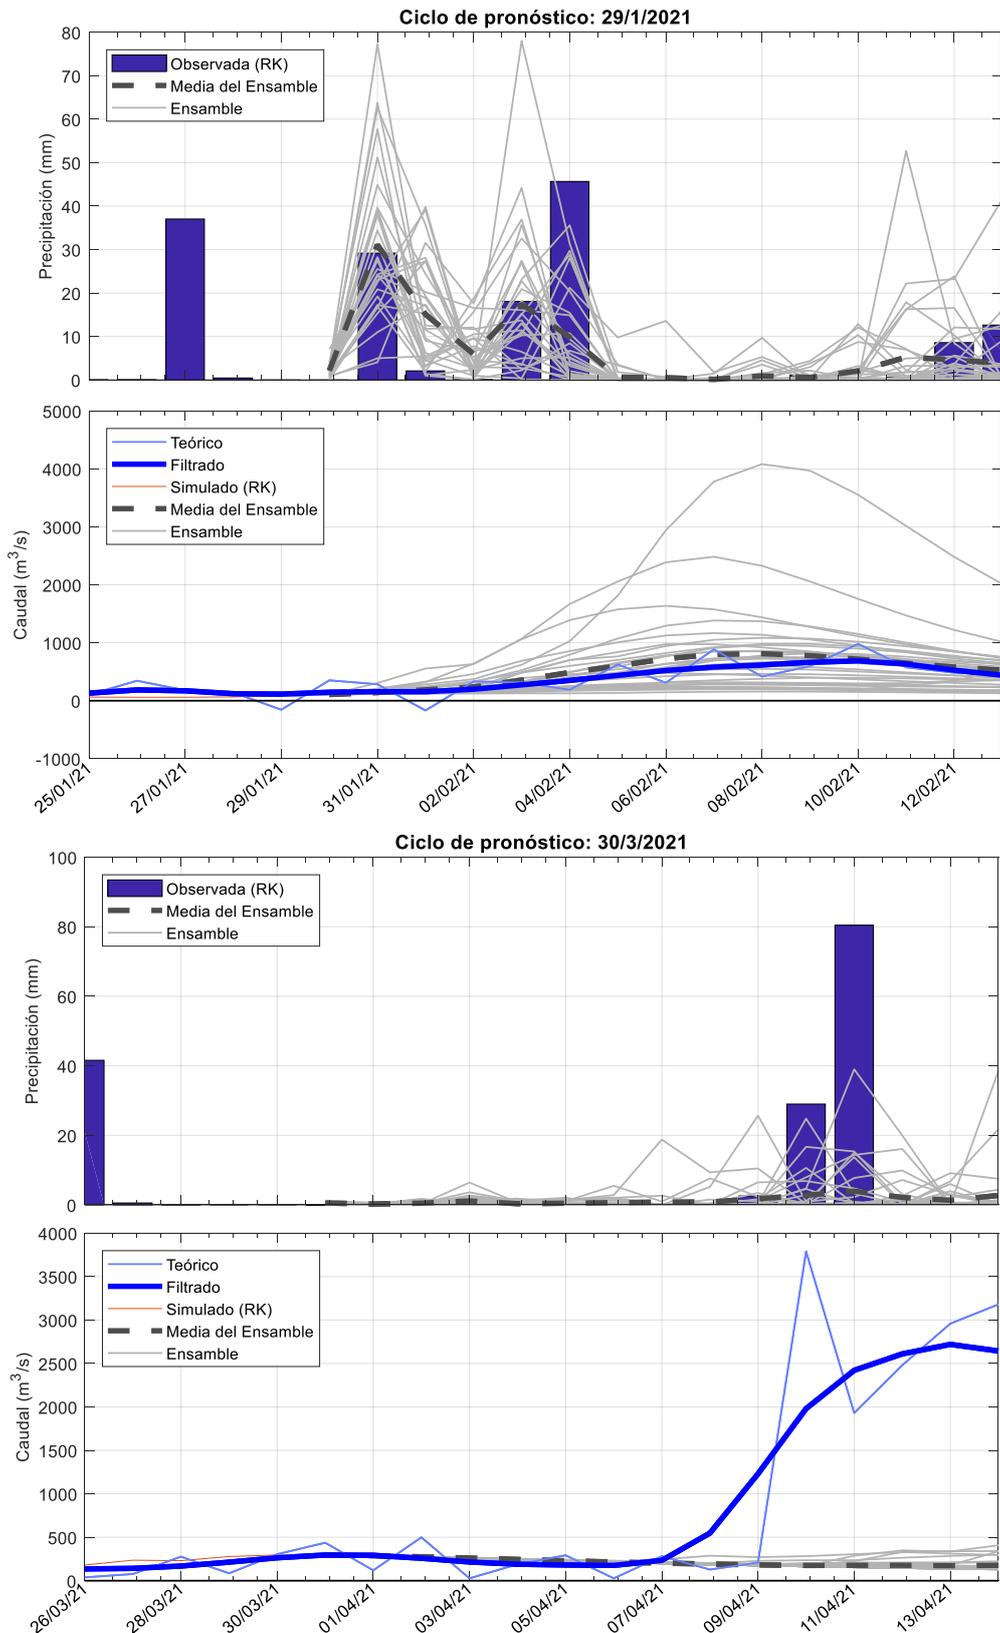


Figura 3-21: Ejemplos de pronósticos para los ciclos inicializados el 29/01/2021 (paneles superiores) y el 30/03/2021 (paneles inferiores) para la cuenca de aporte a G. Terra.

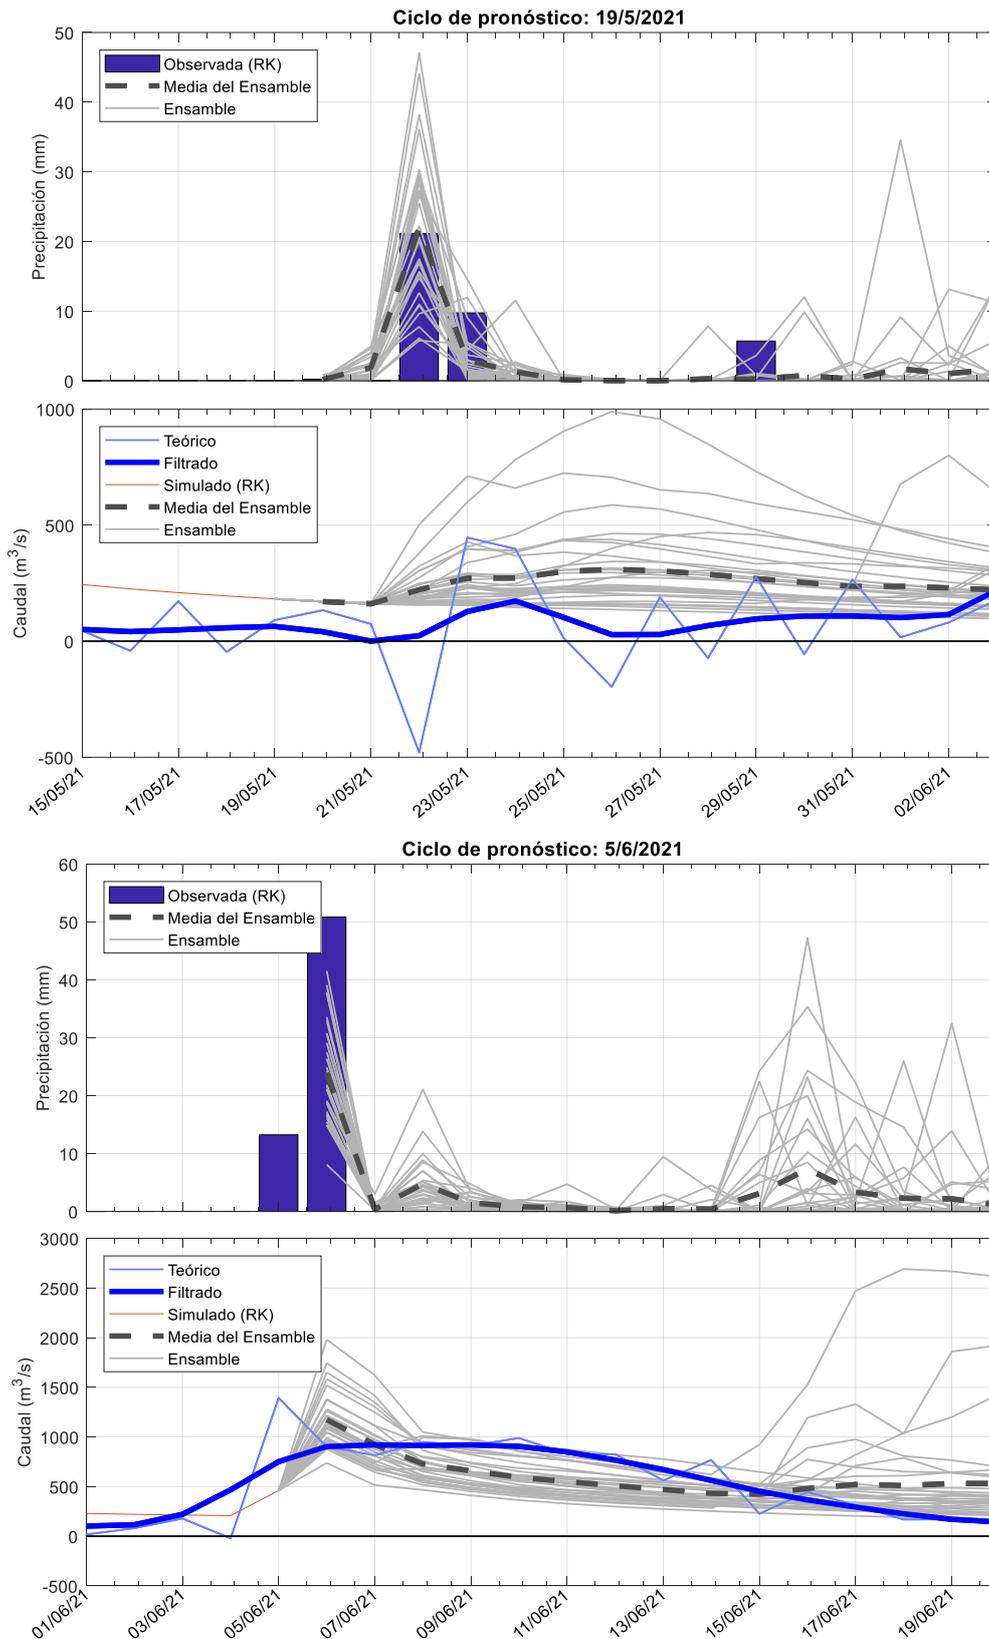


Figura 3-22: Ejemplos de pronósticos para los ciclos inicializados el 19/05/2021 (paneles superiores) y el 5/06/2021 (paneles inferiores) para la cuenca de aporte a G. Terra.

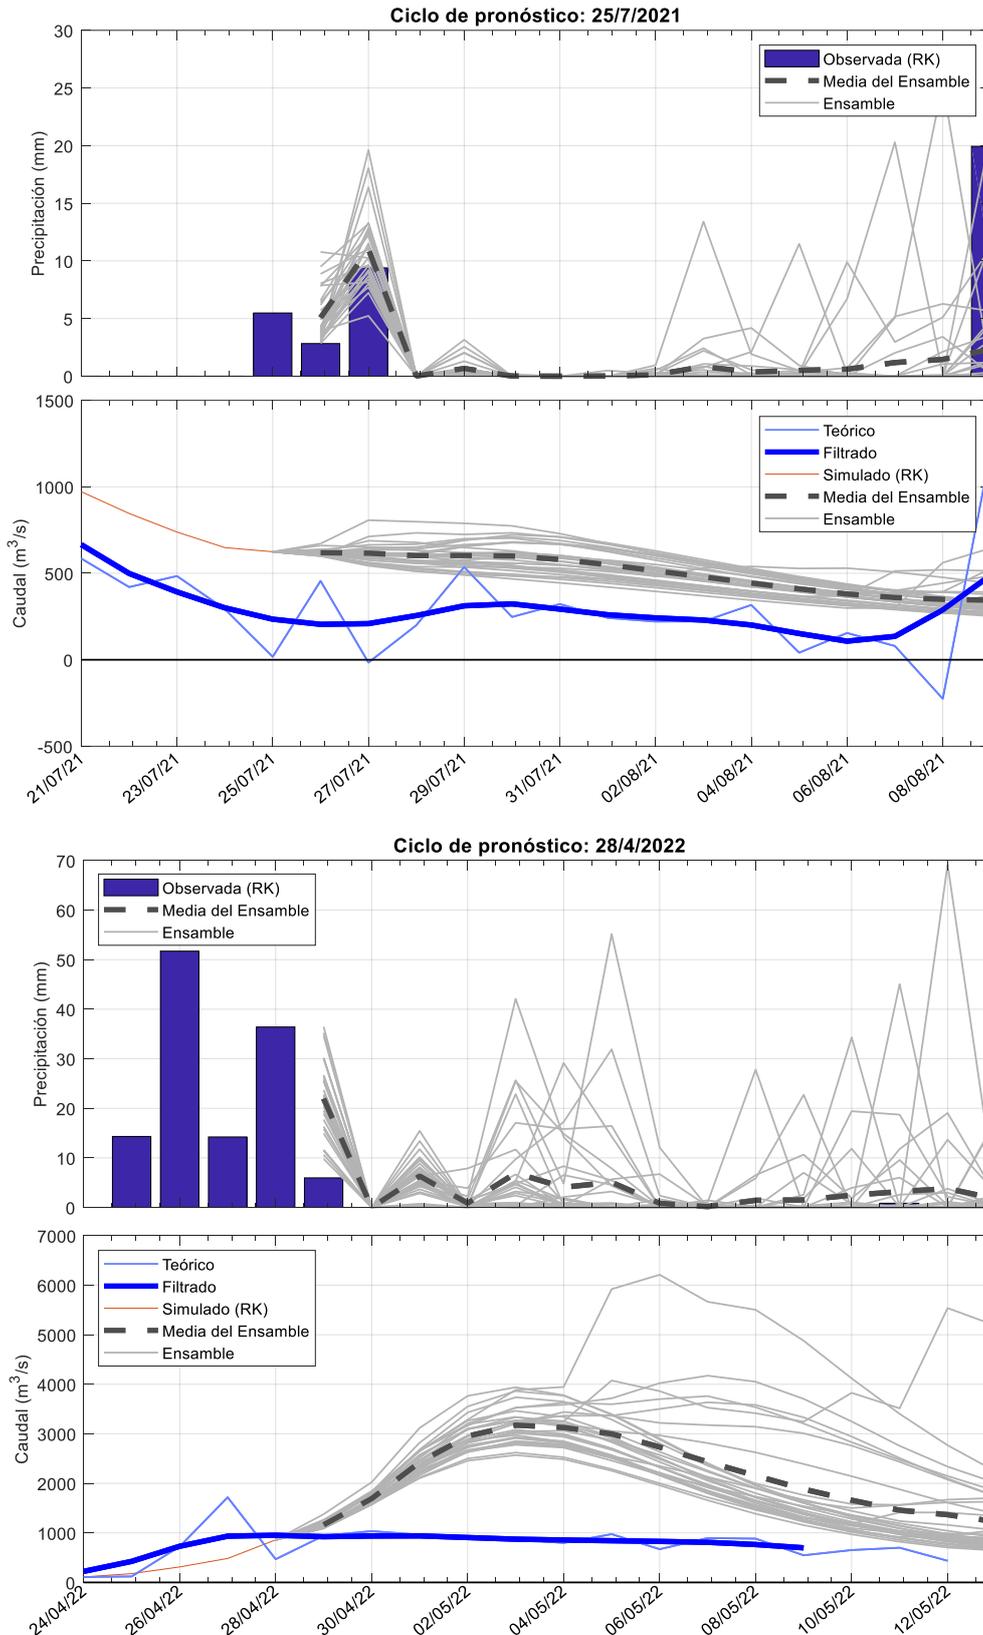


Figura 3-23: Ejemplos de pronósticos para los ciclos inicializados el 25/07/2021 (paneles superiores) y el 28/04/2022 (paneles inferiores) para la cuenca de aporte a G. Terra.

Caracterización de la evolución del error y la dispersión del ensamble

En la Figura 3-24 se presenta un gráfico de caja (boxplot) con la evolución del error de la media del ensamble (calculado como la distancia entre la media y el valor teórico filtrado) a lo largo del horizonte de pronóstico. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes) en los ciclos de pronóstico. Adicionalmente, se superpone la dispersión del ensamble (calculada como la desviación estándar de los miembros del ensamble). La línea punteada representa +/- la mediana de la dispersión del ensamble para los 777 ciclos analizados.

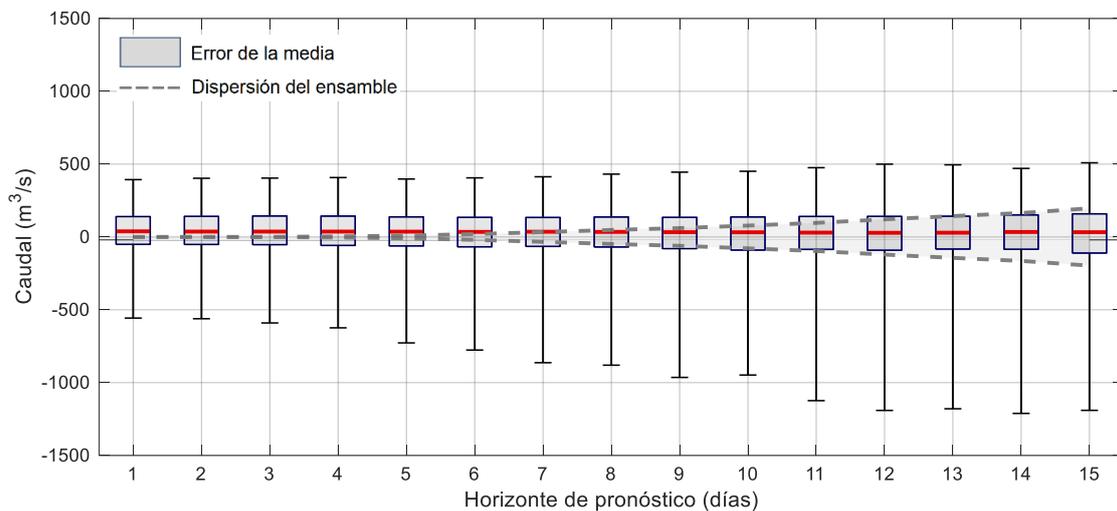


Figura 3-24: Evolución del error de la media (boxplot) y de la dispersión (línea punteada) del ensamble a lo largo del horizonte de pronóstico para la cuenca de aporte a G. Terra. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes).

Se observa que, como era de esperar, a medida que se avanza en el horizonte de pronóstico, aumenta la dispersión de los miembros del ensamble y el error de su media. En este caso, la mediana del error de la media (línea roja del boxplot) se mantiene constante, del orden de 50 m³/s, a lo largo de los 15 días del pronóstico. En los primeros días se identifica un sesgo positivo en la tendencia central del error, heredado de la precipitación, que se atenúa a medida que avanza el horizonte de pronóstico. Nuevamente se observa una asimetría negativa en la distribución del error de la media (ver Figura 3-8).

Durante los primeros horizontes de pronóstico (1 a 5 días), se destaca que la dispersión del ensamble es menor que el error de su media (la dispersión es prácticamente nula).

En la Figura 3-25 se presenta la evolución a lo largo del horizonte de pronóstico del RMSE de los miembros del ensamble, en superposición con la dispersión del ensamble (línea punteada). Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes). El RMSE del ensamble para cada ciclo de pronóstico se calcula como la

raíz de la suma del error cuadrático de cada miembro del ensamble dividida el número total de miembros.

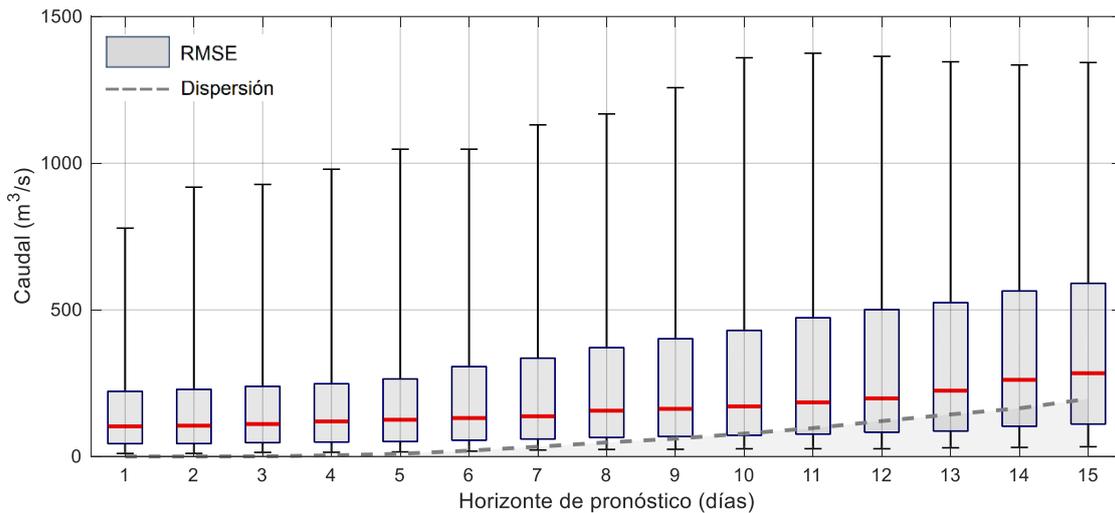


Figura 3-25: Evolución del RMSE (boxplot) y dispersión (línea punteada) del ensamble a lo largo del horizonte de pronóstico para la cuenca de aporte a G. Terra. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes).

En la figura anterior nuevamente se observa que el error del ensamble crece a medida que se avanza en el horizonte de pronóstico, sin alcanzar un valor asintótico (como sí se alcanzaba para la precipitación). En este caso, el RMSE del ensamble es sistemáticamente mayor que la dispersión para todos los horizontes de pronóstico, lo que indica que el ensamble tiene una dispersión excesivamente baja.

Histogramas de análisis de rangos

En la Figura 3-26 se presenta el histograma de análisis de rangos (Diagrama de Talagrand) para cada horizonte de pronóstico. En dicho diagrama están representadas las frecuencias con las que la observación (dato empleado para la verificación) cae en los rangos o clases definidas por los miembros del pronóstico por ensambles, permitiendo extraer conclusiones sobre los sesgos y la dispersión del sistema de pronóstico.

Se observa que a lo largo de todo el horizonte de pronóstico el diagrama tiene “forma de U” lo cual sugiere que el ensamble tiene una dispersión excesivamente baja, la observación está demasiado a menudo fuera del rango del ensamble (en el primer y último rango). Este resultado es consistente con lo observado en la Figura 3-25. A medida que avanza el horizonte de pronóstico, si bien se mantiene la forma del diagrama, el ensamble tiende a estar mejor distribuido con cierto sesgo positivo (tendencia a la sobrestimación).

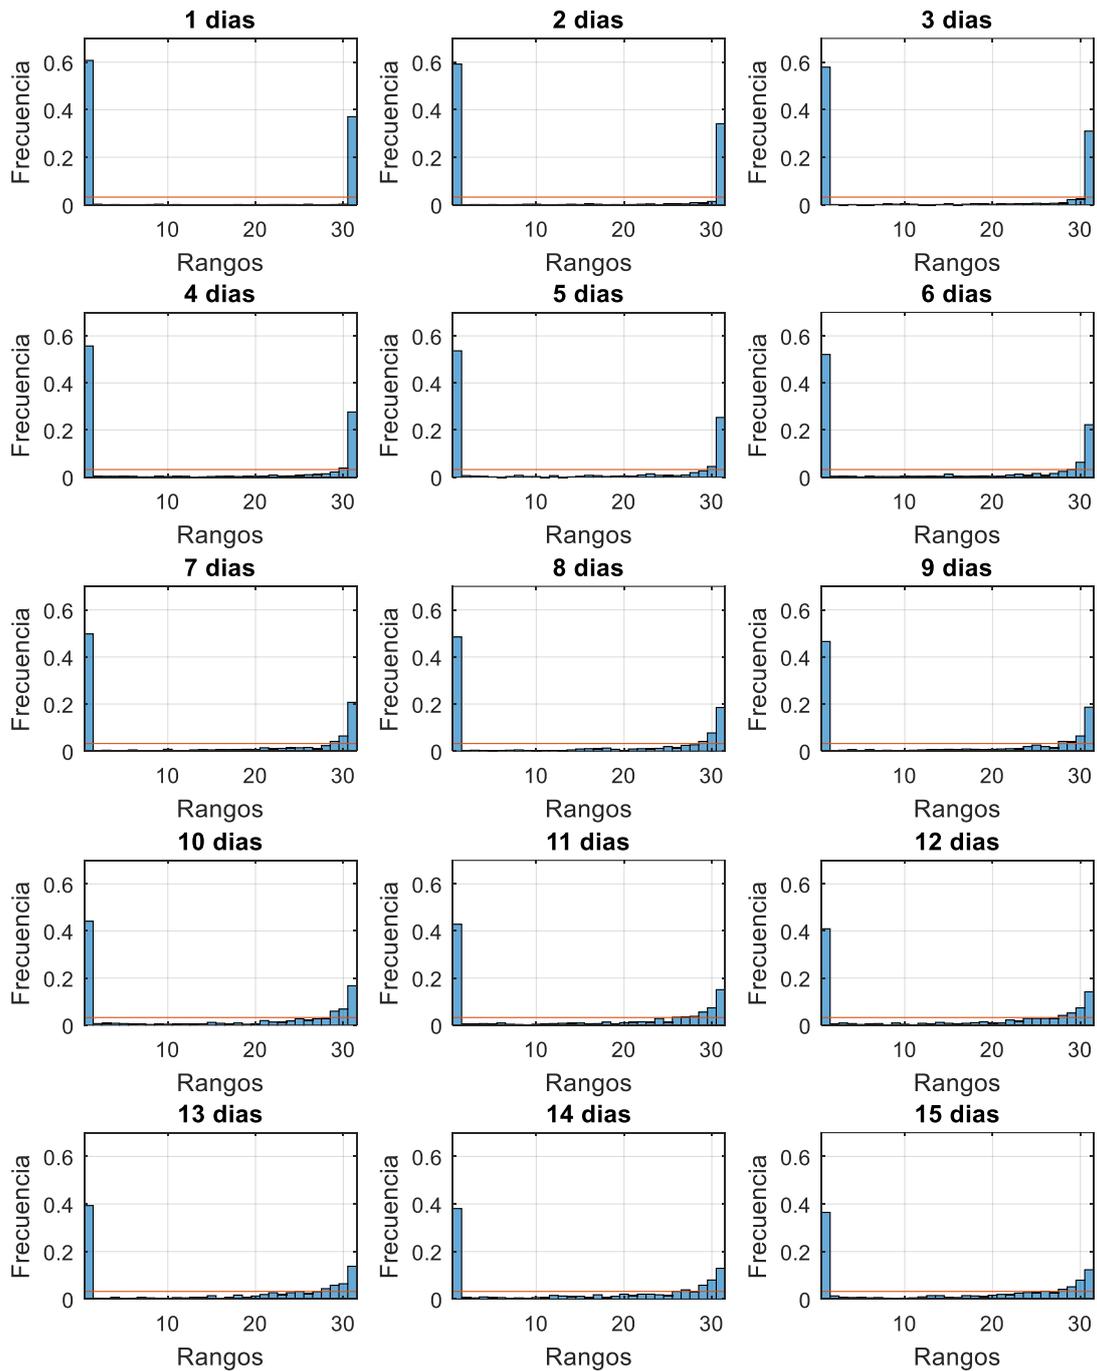


Figura 3-26: Histograma de rangos para cada horizonte de pronóstico para la cuenca de aporte al embalse de G. Terra.

En la Figura 3-27 se presenta la evolución del indicador dif_max a lo largo del horizonte de pronóstico. Dicho indicador (no paramétrico) se define en base al histograma de análisis de rangos y cuantifica la desviación con la horizontalidad, en particular representa la máxima diferencia entre las frecuencias acumuladas.

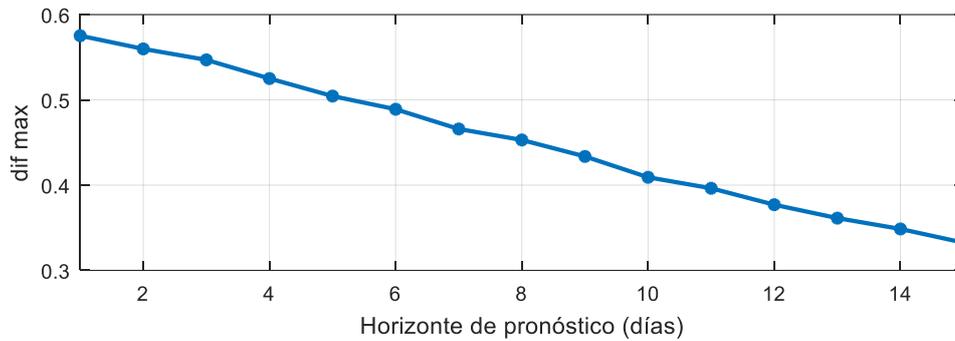


Figura 3-27: Evolución del indicador dif_max a lo largo del horizonte de pronóstico para la cuenca de aporte al embalse de G. Terra.

Se observa que el indicador tiene una tendencia decreciente a lo largo de todo el horizonte de pronóstico.

Distribución del error del ensamble según intervalos del caudal teórico

En la siguiente figura se presenta la distribución del error de los miembros del ensamble según tres intervalos del caudal de aporte teórico filtrado para los horizontes 1, 7 y 15 días.

Para ello, se seleccionaron dos umbrales de caudal (300 y 1000 m³/s) y se clasificaron los ciclos de pronóstico según el caudal teórico filtrado en cada uno: $Q \leq 300$ m³/s (del orden de 510 ciclos), 300 m³/s < $Q \leq 1000$ m³/s (del orden de 170 ciclos) y $Q > 1000$ m³/s (del orden de 85 ciclos). Luego, para cada ciclo, se calculó el error (diferencia entre el pronóstico y la observación) de cada uno de los miembros del ensamble, se los agrupó según los intervalos de caudal teórico y se construyeron los histogramas correspondientes.

En general, para los tres horizontes de pronóstico considerados, la distribución del error del ensamble está centrada en el cero; salvo para el intervalo de los caudales mayores a 1000 m³/s en los que se observa una tendencia a la subestimación.

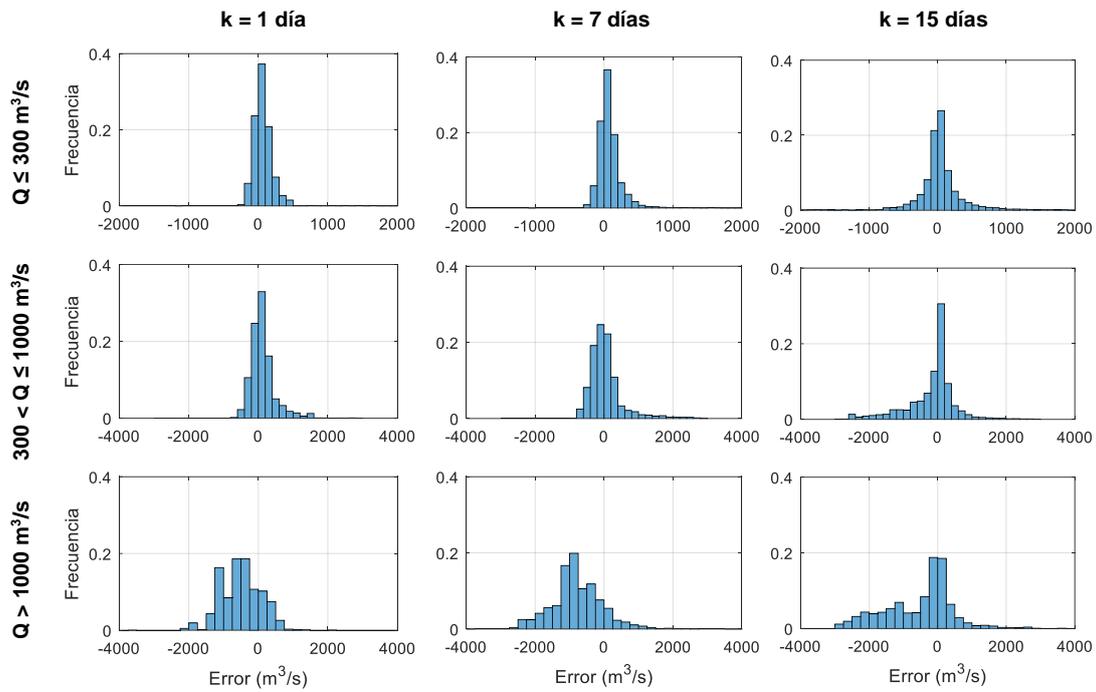


Figura 3-28: Distribución del error de los miembros del ensamble según tres intervalos del caudal teórico ($Q \leq 300 \text{ m}^3/\text{s}$, $300 \text{ m}^3/\text{s} < Q \leq 1000 \text{ m}^3/\text{s}$, $Q > 1000 \text{ m}^3/\text{s}$) para los horizontes 1, 7 y 15 días en la cuenca de aporte a G. Terra.

Indicadores de desempeño

En la Figura 3-29 se presenta la evolución a lo largo del horizonte de pronóstico del indicador PBIAS de la media del ensamble para la cuenca de aporte a G. Terra. A modo de referencia, se incluyen las calificaciones generales para dichos estadísticos reportadas por Moriasi et al. 2015.

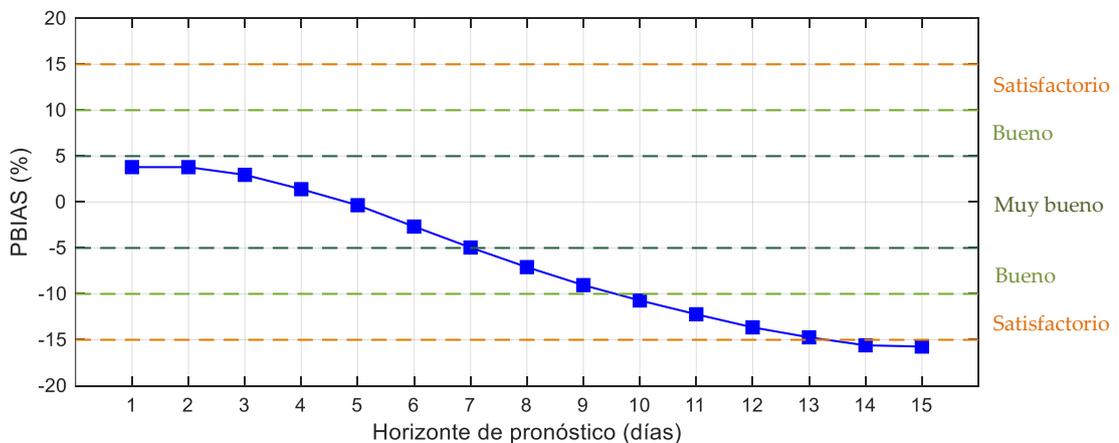


Figura 3-29: Evolución a lo largo del horizonte de pronóstico del indicador PBIAS de la media del ensamble para la cuenca de aporte a G. Terra.

Análogamente, en la Figura 3-30 se presenta la evolución del NSE de la media del ensamble.

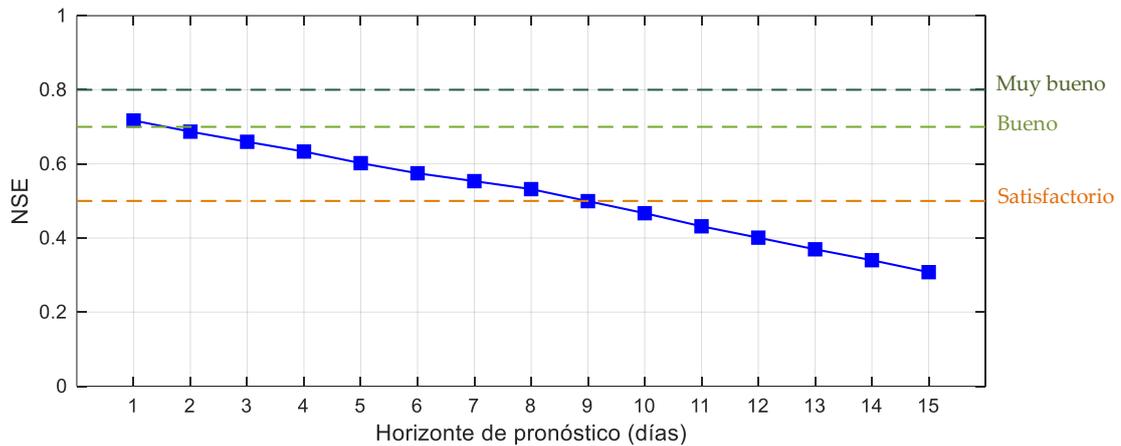


Figura 3-30: Evolución a lo largo del horizonte de pronóstico del indicador NSE de la media del ensamble para la cuenca de aporte a G. Terra.

Se observa un sesgo a la sobreestimación ($PBIAS > 0$) durante los primeros 5 días, que luego cambia de signo alcanzando una subestimación de más del 15% en los últimos horizontes de pronóstico. El desempeño es muy bueno hasta el día 7 ($PBIAS < \pm 5\%$) y entre bueno y satisfactorio hasta el día 13 ($PBIAS < \pm 15\%$).

En el caso del NSE, se tiene un valor de 0,72 en el primer día del horizonte de pronóstico (correspondiente a un desempeño bueno) que luego desciende hasta 0,31 en el último día del horizonte, con resultados satisfactorios durante los primeros 9 días ($NSE > 0,50$).

Error al inicio de la simulación

En lo que refiere al impacto de la falta de asimilación de datos de caudal observados, en el panel izquierdo de la Figura 3-31 se presenta el diagrama de dispersión del caudal simulado a partir de la estimación RK versus el caudal teórico filtrado correspondiente al día de inicio de cada uno de los 777 ciclos de pronósticos analizados. En el panel derecho se presenta el diagrama de dispersión en escala logarítmica. En la Figura 3-32 se presenta la distribución del error al inicio de cada ciclo de pronóstico.

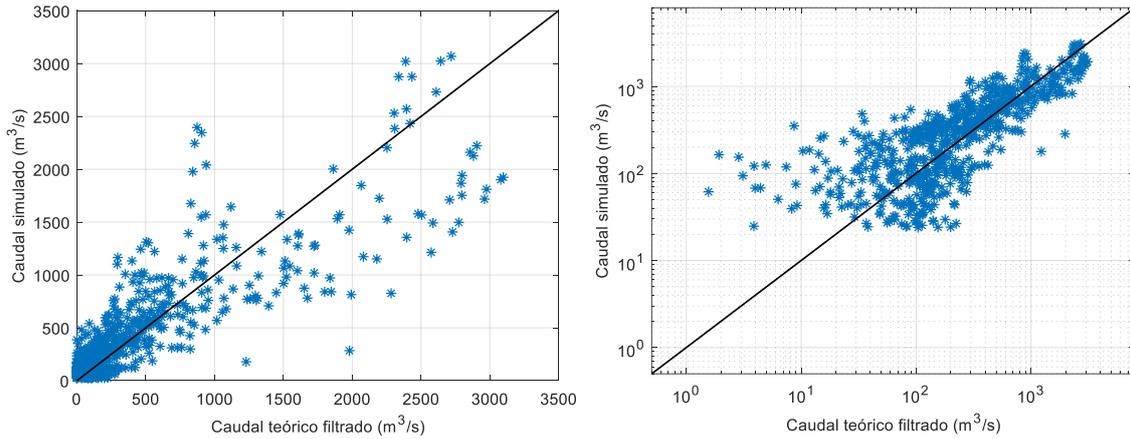


Figura 3-31: Diagrama de dispersión del caudal simulado (eje y) versus el caudal teórico filtrado (eje x) al inicio de cada ciclo de pronóstico en la cuenca de aporte a G. Terra (en el panel derecho se presenta el diagrama en escala logarítmica).

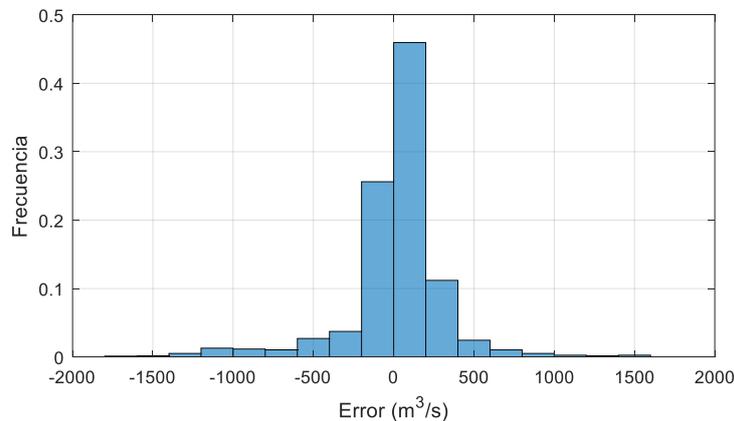


Figura 3-32: Distribución del error al inicio de cada ciclo de pronóstico para la cuenca de aporte a G. Terra.

Se observa que, en general, la nube de puntos está alineada con la recta identidad ($X = Y$), lo cual es consistente con que la distribución del error esté centrada en el cero. El 70% de los ciclos de pronóstico tienen un error inicial menor a $\pm 200 \text{ m}^3/\text{s}$.

En el diagrama de dispersión en escala logarítmica se observa un marcado sesgo positivo (sobrestimación) para los caudales bajos.

3.4 SÍNTESIS

En el presente capítulo se desarrolló una metodología para la evaluación de la calidad de los pronósticos por ensambles de precipitación y caudal. Dicha metodología se basa en la recomendación de emplear una combinación de indicadores de desempeño y gráficos de diagnóstico, de manera de abarcar diferentes aspectos de la calidad del pronóstico, en este caso el sesgo, la precisión y la confiabilidad. En particular, la metodología desarrollada incluye: (1) la

inspección visual de las series temporales por ciclo de pronóstico, (2) la caracterización del error del ensamble a lo largo del horizonte de pronóstico (error de la media y RMSE de los miembros del ensamble), (3) la caracterización de la dispersión del ensamble a lo largo del horizonte de pronóstico (calculada como la desviación estándar de los miembros del ensamble), (4) la evaluación conjunta de la evolución del error y la dispersión del ensamble (“spread-skill evaluation”), (5) la construcción de los histogramas de análisis de rangos (Diagramas de Talagrand) a lo largo del horizonte de pronóstico, (6) el análisis (paramétrico) de la distribución del error del ensamble según intervalos de precipitación/caudal observado a lo largo del horizonte de pronóstico, (7) la evaluación de los indicadores PBIAS y NSE a lo largo del horizonte de pronóstico para la media del ensamble de caudales. Adicionalmente, se avanzó en la identificación de comportamientos bimodales en la distribución de precipitación de los miembros del ensamble mediante el cálculo del coeficiente de bimodalidad de Sarle para cada ciclo de pronóstico.

En primer lugar, la metodología desarrollada se aplicó a los pronósticos por ensambles de precipitación del modelo GEFS (versión V12) del NCEP-NOAA en la cuenca del Río Negro, tomando como referencia una estimación en base a la combinación de imágenes satelitales y observaciones pluviométricas en superficie desarrollada por De Vera et al. (2021) y actualizada por Alfaro (2022). El periodo analizado comprende noviembre de 2020 a diciembre de 2022, por lo que se dispone de 777 ciclos de pronóstico. Cabe destacar que, en Uruguay, dicho periodo se identifica particularmente como un periodo de déficit hídrico. Se consideró una resolución temporal diaria y una agregación espacial en cuatro grandes cuencas: subcuenca del río Tacuarembó (16.171 km²), subcuenca incremental de aporte a G. Terra (24.724 km²), subcuenca incremental de aporte a Constitución (22.014 km²) y cuenca “total” de aporte del Río Negro con cierre en Constitución (62.900 km²).

Posteriormente, se evaluó el desempeño de los ensambles de pronósticos de caudales diarios de aporte a las centrales hidroeléctricas obtenidos a partir de un modelo hidrológico alimentado por los pronósticos del GEFS, tomando como referencia los caudales teóricos de UTE. Debido a las limitaciones identificadas en las series teóricas, únicamente se evaluaron los aportes al embalse de G. Terra. Para la evaluación se consideró la serie teórica diaria filtrada mediante un filtro binomial con una ventana centrada de 7 días.

De los resultados obtenidos en la evaluación de los pronósticos por ensambles se concluye que, tanto para la precipitación como para los caudales de aporte, las series simuladas capturan satisfactoriamente el comportamiento de las series observadas.

Como era de esperar, a medida que se avanza en el horizonte de pronóstico, aumenta el error y la dispersión de los miembros del ensamble, es decir que

disminuye la predictibilidad del sistema. En ambos casos se identificó una tendencia en el error de la media del ensamble hacia valores positivos, es decir, una tendencia a la sobreestimación (sesgos positivos), a la vez que se observó una asimetría negativa en su distribución. Durante los primeros días del horizonte de pronóstico el ensamble tiene una dispersión excesivamente baja, la observación está demasiado a menudo fuera del rango del ensamble. Luego, a medida que avanza el horizonte de pronóstico el ensamble tiende a estar mejor distribuido. Este resultado es aún más notorio en el caso de los caudales de aporte, en el cual la dispersión del ensamble es prácticamente nula hasta el día 5 de pronóstico.

En general no se observaron grandes variaciones espaciales en el desempeño del pronóstico por ensambles en la cuenca del Río Negro, siendo los resultados obtenidos similares para todas las subcuencas consideradas. En el caso de la precipitación, tanto el error de la media como el RMSE del ensamble, son marginalmente menores en la cuenca incremental de Constitución.

En relación a la exploración de comportamientos bimodales en la distribución de precipitación de los miembros del ensamble, se identificó una notoria diferencia entre los ciclos unimodales y bimodales. Esto sugiere que evaluar diferentes metodologías y/o procesamientos para los ciclos de pronóstico en función de la bimodalidad del ensamble de precipitación podría mejorar el desempeño del pronóstico (ya que en el cálculo del coeficiente BC sólo participa el ensamble y no la observación, por lo que puede calcularse “a priori”).

Por último, los resultados obtenidos evidencian la necesidad de la asimilación de datos de caudal observados, ya que se tienen ciclos en los que el error inicial supera el $\pm 100\%$ del caudal teórico.

CAPÍTULO 4

ASIMILACIÓN DE DATOS OBSERVADOS DE CAUDAL AL MODELO HIDROLÓGICO

4. Asimilación de datos observados de caudal al modelo hidrológico

4.1 MARCO TEÓRICO

4.1.1 Generalidades

Definición

El concepto de *asimilación de datos* ha sido definido por Talagrand (1997) como el arte de usar toda la información disponible (proveniente de diferentes fuentes) para estimar de la manera más precisa posible el estado de la atmósfera o el océano (u otro sistema dinámico) en un momento determinado. El “mejor” estado del sistema se estima combinando de forma óptima un modelo numérico (denominado campo preliminar) y observaciones en un “análisis”, considerando los errores asociados a cada una de estas fuentes de información (Lahoz et al., 2010). Las observaciones son discretas en el espacio y en el tiempo y tienen asociados dos tipos de errores: (i) errores instrumentales, aleatorios o sistemáticos (sesgos), (ii) errores de representatividad (discrepancia entre las escalas de las observaciones y el modelo). A su vez, el uso de modelos numéricos también introduce errores, inherentes a la construcción de los mismos, ya sea debido a la falta de comprensión u omisión de algún proceso (los modelos son una representación simplificada del sistema bajo estudio), a errores en la condición inicial o en la estimación de sus parámetros.

De la asimilación de datos se desprenden dos aplicaciones fundamentales:

- **Re-análisis:** Utilizar esta descripción dinámicamente consistente del estado del sistema como mejor aproximación al campo “observado” para describir y estudiar los procesos físicos asociados.
- **Pronóstico:** Considerar el “análisis” para inicializar simulaciones numéricas de pronóstico a diversos plazos.

A la vez, existen múltiples objetivos adicionales que se pueden alcanzar utilizando las técnicas de asimilación: evaluar la estadística de los errores que afectan al sistema, evaluar la efectividad de las observaciones para brindar información acerca del estado del sistema, evaluar la efectividad de los modelos numéricos para describir la dinámica del sistema de interés, etc.

En particular, Lahoz et al. (2010) resaltan la manera en que la asimilación de datos aporta un valor agregado al pronóstico numérico, así como el impacto de la resolución tanto espacial como temporal de la información empleada. Claro está que cuanto mejor sea el “análisis”, es decir cuanto más precisa sea la estimación de las condiciones iniciales del sistema, mejor será la calidad del pronóstico (Kalnay, 2003).

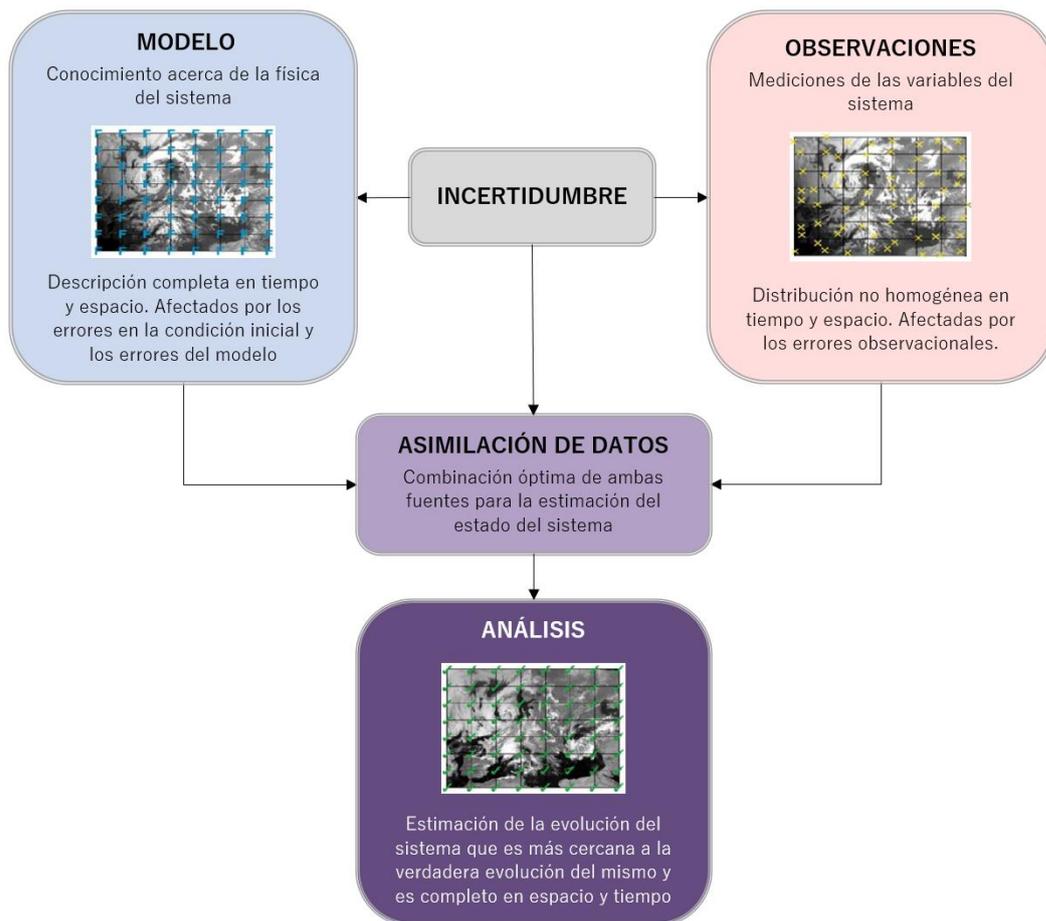


Figura 4-1: : Esquema conceptual de la asimilación de datos.

Clasificación de las técnicas

Se asume que se conoce una distribución a priori para las variables del estado \mathbf{x} , al que se llama $\mathbf{x}^b \in \mathbb{R}^N$, estado del background (preliminar), con matriz de covarianza de errores asociada $\mathbf{B} \in \mathbb{R}^{N \times N}$. Las observaciones para ese instante están representadas por el vector $\mathbf{y}^0 \in \mathbb{R}^M$ y la matriz de covarianza de los errores de las observaciones es $\mathbf{R} \in \mathbb{R}^{M \times M}$. La ponderación del campo preliminar (background) y las observaciones está dada por:

$$\mathbf{x}^a = \mathbf{x}^b + \mathbf{W}[\mathbf{y}^0 - \mathcal{H}(\mathbf{x}^b)]$$

donde \mathbf{x}^a es el análisis, \mathbf{x}^b es el estado del background e \mathbf{y}^0 las observaciones.

El estado preliminar del sistema puede estar dado por, por ejemplo, por un modelo de pronóstico desde un estado pasado. Para poder compararlo con las medidas, el pronóstico del modelo se interpola a la ubicación de las observaciones y, si las variables medidas son diferentes, se convierte de las variables del modelo a las variables observadas. Por lo tanto, la primera aproximación a las observaciones es $\mathcal{H}(\mathbf{x}^b)$, donde \mathcal{H} es el operador de observación que realiza la interpolación y transformaciones necesarias de las variables del modelo al espacio de observación (Kalnay et al., 2003).

La diferencia entre las observaciones y la primera aproximación del modelo $\mathbf{y}^0 - \mathcal{H}(\mathbf{x}^b)$ se denomina "incremento de observación" o "innovación". El análisis \mathbf{x}^a se obtiene al agregar al campo preliminar las innovaciones con pesos \mathbf{W} que se determinan a partir de las estimaciones de las matrices de covarianzas de los errores del pronóstico y las observaciones (Kalnay et al., 2003).

A continuación, se presenta una clasificación de las técnicas de asimilación de datos (que difieren en cómo combinar el campo preliminar y las observaciones) y se describen muy brevemente los fundamentos de cada una.

Técnicas de análisis empírico

- Método de correcciones sucesivas (SCM): Fue el primer método utilizado (Cressman, 1959). Es un esquema iterativo, en el cual los pesos se determinan empíricamente en función de la distancia entre la observación y el campo grillado.
- Relajación newtoniana o "Nudging": Consiste en agregar a las ecuaciones pronósticas del modelo un término que acerca/empuja la solución hacia las observaciones (Hoke & Anthes, 1976). Es especialmente útil cuando no se dispone de información para realizar una interpolación estadística.

Técnicas de interpolación estadística

- Variacionales (3D-Var, 4D-Var): En el enfoque 3D-Var se define una función de costo $\mathcal{J}(\mathbf{x})$ que contempla tanto la distancia entre el estado \mathbf{x} y el background \mathbf{x}^b , como la distancia entre el estado \mathbf{x} y las observaciones \mathbf{y}^0 (suma ponderada de los cuadrados de ambas distancias pesadas por sus respectivas matrices de covarianzas de los errores). Esta función de costo se minimiza para obtener el análisis $\mathbf{x} = \mathbf{x}^a$. El método 4D-Var es una generalización del 3D-Var, aplicado a observaciones que están distribuidas en un intervalo de tiempo o "ventana de asimilación" (Kalnay, 2003).
- Secuenciales (KF, EKF, EnKF): Los métodos secuenciales actualizan la solución del modelo en cada momento en que hay observaciones disponibles (Evensen, 2009). El Filtro de Kalman (KF) es un algoritmo secuencial recursivo que en cada ciclo de asimilación calcula el estado pronosticado por el modelo, \mathbf{x}^f , y el análisis, \mathbf{x}^a , así como sus respectivas matrices de covarianza del error, \mathbf{P}^f y \mathbf{P}^a . El Filtro de Kalman Extendido (EKF) representa una expansión del FK que permite el uso de modelos dinámicos \mathcal{M} y operadores de las observaciones \mathcal{H} no lineales (Carrassi et al., 2018). El filtro de Kalman por ensambles (EnKF) consiste en computar simultáneamente un ensamble de sistemas de asimilación de datos para estimar la matriz \mathbf{P}^f como la matriz de covarianza de los vectores del ensamble $\mathbf{x}^{f,i}$ (con menor costo computacional). La estimación se vuelve más precisa a medida que aumenta el tamaño del conjunto.

- **Híbridos:** Los métodos híbridos hacen uso de las ventajas de los esquemas variacionales y de los secuenciales por ensambles (Hamill & Snyder, 2000). Algunos combinan linealmente las matrices de covarianza de los errores del campo preliminar, mientras que otros combinan las matrices de ganancia del método por ensamble y variacional. Una de sus bondades es que son robustos a pesar de que la cantidad de miembros del ensamble sea pequeña.

Filtros de partículas (PF)

Los filtros de partículas son un tipo de método no gaussiano que aproxima la función de distribución por la distribución de una muestra de “partículas” (estados del sistema) con distintos pesos asignados. Para evitar mantener partículas con pesos insignificantes y otras con pesos muy grandes se introducen las técnicas de muestreo por importancia y remuestreo (resampling). Actualmente se están desarrollando métodos híbridos entre PF y los esquemas variacionales y secuenciales por ensambles (Van Leeuwen et al., 2019).

La elección y el uso de uno u otro método dependerá del problema particular que se quiera abordar y los recursos disponibles.

4.1.2 Asimilación de datos en modelación hidrológica

Si bien la asimilación de datos se desarrolló y utilizó originalmente dentro de las comunidades de ciencias de la atmósfera y el océano, actualmente su uso se extendió a otras ramas de la ciencia, incluida la hidrología. Independientemente del enfoque de modelación considerado, debido al gran impacto de las condiciones iniciales en la habilidad del pronóstico hidrológico, existe un interés cada vez mayor en mejorar la actualización de los estados y/o parámetros del modelo mediante la asimilación de las variables hidrológicas observadas.

Las variables más comúnmente empleadas en la asimilación de datos hidrológicos son el caudal (Piazzi et al., 2021; Li et al., 2015) y la humedad del suelo (Brocca et al., 2010; Musuuza et al., 2020) y, en menor medida, la evapotranspiración (Zhang et al., 2017), el nivel del agua subterránea (Li et al., 2019), el equivalente en agua de nieve (De Lannoy et al., 2010), entre otros.

Se han propuesto y utilizado diversas técnicas para la asimilación de datos en modelos hidrológicos con fines de pronóstico. En Brocca et al. (2010) se evalúa el efecto de la asimilación de un producto satelital de humedad del suelo (ASCAT) en un modelo conceptual de lluvia-escorrentía para la simulación de eventos de inundación. Para ello se emplea una técnica simple de asimilación de datos (“nudging” o relajación), de bajo costo computacional, que demostró ser efectiva para mejorar la habilidad del modelo, especialmente cuando no se conocen las condiciones iniciales de humedad del suelo. Musuuza et al. (2020) aplicaron el

método EnKF para asimilar diversas variables hidro-meteorológicas al modelo E-HYPE: la evapotranspiración real y potencial acumulada de 8 días del satélite MODIS (AET y PET, respectivamente), la capa de nieve fraccionada (FSC) diaria y el equivalente de agua de nieve (SWE) del satélite óptico CRYOLAND, el caudal (Q_{ob}) y los aportes locales a embalses hidroeléctricos (INFLOW), con el objetivo de mejorar la estimación de las dos últimas variables. La clasificación obtenida según el desempeño de los distintos productos asimilados, evaluado en base a la ganancia en la eficiencia de Kling-Gupta (KGE), fue: INFLOW, Q_{ob} , FSC, AET, SWE y PET. Las mediciones en superficie (INFLOW y Q_{ob}) presentaron mejor desempeño que las estimaciones satelitales. En Piazzzi et al. (2021) se compara el desempeño de dos técnicas de asimilación de datos (EnKF y PF), en términos de eficiencia y persistencia temporal, al asimilar datos de caudal observados en un modelo hidrológico conceptual concentrado (modelo GR5J). El análisis aborda el impacto de diferentes fuentes de incertidumbre y la actualización de los diferentes estados y parámetros del modelo GR5J. Ambos esquemas de asimilación mostraron ser de utilidad para mejorar la precisión del pronóstico. Si bien el método EnKF supera al PF en el corto plazo, este último presenta un efecto más duradero a lo largo del horizonte de la previsión. Los resultados muestran que una estimación precisa del nivel inicial del reservorio de tránsito garantiza el mayor beneficio de la asimilación de datos, ya que esta variable de estado es la más correlacionada con las observaciones. En cuanto a las fuentes de incertidumbre, Piazzzi et al. (2021) afirman que una representación integral de la incertidumbre de los forzantes meteorológicos y de los estados del modelo permite una mejora más eficiente de la habilidad del pronóstico. En particular, para representar la incertidumbre de los forzantes meteorológicos (precipitación y evapotranspiración potencial) en cada paso de tiempo se generan pronósticos probabilísticos perturbando las observaciones con ruido estocástico multiplicativo. Un enfoque similar se aborda en Jiménez et al. (2019) para evaluar la habilidad de dos esquemas de asimilación de datos de caudal (empírico y EnKF) en un modelo hidrológico distribuido (modelo MGB-IPH). El ensamble de variables de estado del modelo hidrológico se obtiene, en cada paso de tiempo, a partir de la generación de series sintéticas de precipitación perturbando las observaciones mediante una distribución logarítmica normal. Los parámetros del modelo MGB-IPH se consideraron invariantes en el tiempo, es decir, una vez calibrados se mantienen constantes durante todo el proceso de asimilación y del pronóstico del caudal. Ambos métodos de asimilación presentaron mayor habilidad, medida en términos del indicador NSE, que la simulación sin asimilación. El método EnKF mostró un mejor desempeño (mayor NSE) que el método empírico para mayores horizontes de pronóstico.

4.2 METODOLOGÍA PROPUESTA

4.2.1 Descripción

La representación del campo de precipitaciones observado es siempre imperfecta, constituyendo incluso una de las mayores fuentes de incertidumbre (Bárdossy & Das, 2008; Renard et al., 2010), a la cual se suman los errores introducidos en la modelación hidrológica. En la realización de previsiones hidrológicas operativas es necesario, entonces, implementar un proceso de ajuste que opere como parte de la simulación continua, atenuando estas derivaciones de la simulación respecto de la realidad (Figura 4-2).

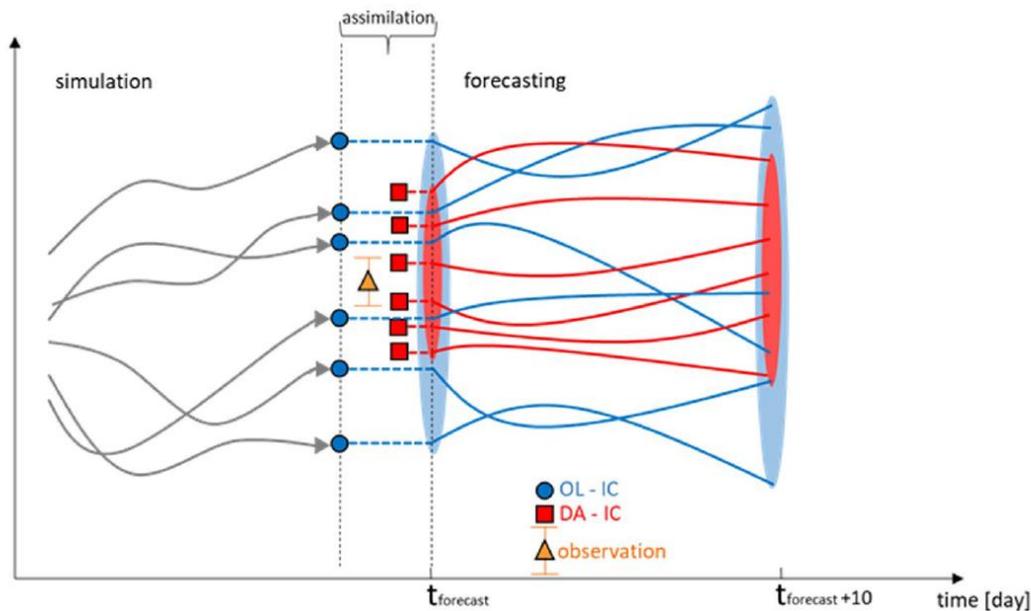


Figura 4-2: Ejemplo esquemático de un sistema de pronóstico por ensemble con y sin asimilación de datos. En azul se representa la evolución temporal del modelo original (OL-IC: "Open Loop-Initial Conditions") y en rojo se muestra la evolución del modelo con la asimilación (DA-IC: "Data Assimilation-Initial Conditions") de la última observación disponible (triángulo naranja) al inicio del pronóstico. Fuente: Piazzini et al. (2021).

En la configuración tradicional de los procesos de relajación o "nudging" (Kalnay, 2003; Brocca et al., 2010; Mazzoleni et al., 2018), la variable observada que se asimila es una variable de estado del sistema de pronóstico, es decir, con ecuaciones pronósticas para las mismas en cuya resolución numérica se instrumenta la asimilación. La teoría subyacente y el diseño del proceso de asimilación afecta el cálculo numérico para que se mantenga cercano a la realización observada del sistema caótico.

En este caso, las variables de estado del modelo hidrológico son los niveles de agua en los reservorios de producción y de tránsito (S y R respectivamente) con que se modelan en el GR4J los procesos hidrológicos, pero por el momento se carece de observaciones de estas variables (la estimación satelital de estos campos

y su posterior asimilación puede ser una línea de desarrollo a futuro). El error, como fue dicho, se origina fundamentalmente en el forzante meteorológico del modelo hidrológico. La variable observada -caudales en puntos de cierre de algunas subcuencas- es una salida del modelo; surge de una ecuación diagnóstica sin inercia propia más allá del tránsito. Si se relajan las variables de estado (S y R) en proporción al error de los caudales simulados, se obtienen resultados satisfactorios en cuanto a la evolución de dichos caudales, a costo de que la relajación altera totalmente la dinámica hidrológica interna del modelo, volviéndolo irrelevante. Los estados S y R resultantes, por su parte, constituyen una pésima condicional inicial para la siguiente etapa de pronóstico del sistema.

Por tanto, la metodología que se instrumentó y que se describe a continuación se aleja conceptualmente de los diseños tradicionales de asimilación de datos observados a sistemas de pronóstico. El ajuste se plantea como una corrección de la precipitación antecedente (P) hasta el día de inicio del pronóstico, proporcional a la amplitud del error relativo del caudal simulado. La corrección del forzante antecedente (precipitación) para minimizar el error del caudal al inicio del pronóstico (tiempo final de la asimilación) produce también estados del sistema (S y R) e hidrogramas (UH1 y UH2) consistentes con dicho ajuste y dicha condición inicial, de manera que toda la inercia del sistema es capturada adecuadamente.

Dicha corrección puede ser implementada solo en aquellas cuencas en donde se cuenta con registro observado de caudales y por tanto se puede estimar el error del sistema de pronóstico. El error relativo del caudal (ε) en una subcuenca particular se puede definir, para cada paso de tiempo, como la diferencia normalizada entre el caudal observado (Q_{obs}) y el caudal simulado (Q_{sim}).

$$\varepsilon(t) = \frac{abs(Q_{sim}(t) - Q_{obs}(t))}{\max(Q_{sim}(t), Q_{obs}(t))}$$

Con esta definición, que toma el valor absoluto del error y lo normaliza por el máximo de los caudales, se garantiza que $0 \leq \varepsilon \leq 1$.

Se propone entonces la corrección iterativa de la precipitación en los N días antecedentes al inicio t del pronóstico según:

$$\text{Si } Q_{sim}(t) < Q_{obs}(t): P^*(t - i) = P(t - i) + \lambda \times \varepsilon(t)$$

$$\text{Si } Q_{sim}(t) > Q_{obs}(t): P^*(t - i) = \max(0, P(t - i) - \lambda \times \varepsilon(t))$$

$$\text{con } 0 \leq \lambda \leq 1 \text{ y } 0 \leq i \leq N$$

Si $\lambda = 0$, no hay ajuste alguno; si $\lambda = 1$, P corrige en cada paso en proporción igual al error relativo del caudal simulado. Interesa encontrar empíricamente el rango de valores de λ para los cuales el proceso iterativo converge.

El valor de N es estimado por consideraciones hidrológicas y ajustado en base a una simulación retrospectiva (ver Sección 4.3), pero deberá validarse en modo operativo.

La magnitud del ajuste es la misma en todas las subcuencas localizadas aguas arriba del punto de registro de caudales. En el caso de cuencas sucesivas de orden creciente, el ajuste operará sobre escurrimientos incrementales.

4.2.1 Implementación

La metodología propuesta para la asimilación al modelo hidrológico de datos observados de caudal en modo operativo, comprende los siguientes pasos.

Para cada día de inicio de un ciclo de pronóstico (t_0):

(1) Modelación hidrológica sin ajuste hasta t_0 . Se realiza una simulación del modelo hidrológico sin ajuste desde enero de 2020 a t_0 , a partir de la estimación RK de la precipitación histórica, el ciclo medio anual de evapotranspiración potencial (ETP) y las condiciones iniciales de S y R ($S_i = x_1/2$ y $R_i = x_3/2$). Como resultado se obtienen el caudal simulado (Q_s) y la evolución de las variables de estado S y R en dicho periodo.

(2) Modelación hidrológica con ajuste hasta t_0 . Se realiza una simulación del modelo hidrológico con ajuste de la precipitación según el error relativo del caudal desde enero de 2020 a t_0 , a partir de la estimación RK de la precipitación histórica, el ciclo medio anual de ETP, las condiciones iniciales de S y R ($S_i = x_1/2$ y $R_i = x_3/2$), la serie de caudales observados y el caudal simulado Q_s obtenido en el paso (1). Como resultado se obtienen la precipitación ajustada P^* , el caudal simulado corregido (Q_s^*) y la evolución de las variables de estado ajustadas S^* y R^* en dicho periodo.

Iteración: Se repite la simulación con ajuste considerando como datos de entrada la precipitación ajustada P^* y el caudal simulado corregido Q_s^* obtenidos anteriormente, hasta que el error relativo del caudal ε converja (para ello se verifica como suficiente del orden de 100 pasos de iteración). Finalmente se obtienen la precipitación ajustada P^{**} , el caudal simulado corregido (Q_s^{**}) y la evolución de las variables de estado ajustadas S^{**} y R^{**} hasta t_0 .

(3) Modelación hidrológica sin ajuste hasta $t_0 + 15$ días. Para cada miembro del ensamble del GEFS (m) se concatena la serie de precipitación $P = (P^{**}, P^m)$ y se realiza una simulación del modelo hidrológico desde enero de 2020 a $t_0 + 15$ días a partir de la precipitación P , el ciclo medio anual de ETP y las condiciones iniciales de S y R ($S_i = x_1/2$ y $R_i = x_3/2$). Como resultado se obtiene la evolución del caudal en los siguientes 15 días, a partir de los estados de S y R ajustados al inicio del pronóstico, los cuales están implícitos en la precipitación previa ajustada (P^{**}) que surge de la iteración anterior.

A modo de síntesis, en la siguiente figura se presenta el diagrama de flujo con los pasos seguidos y la información considerada en cada caso.

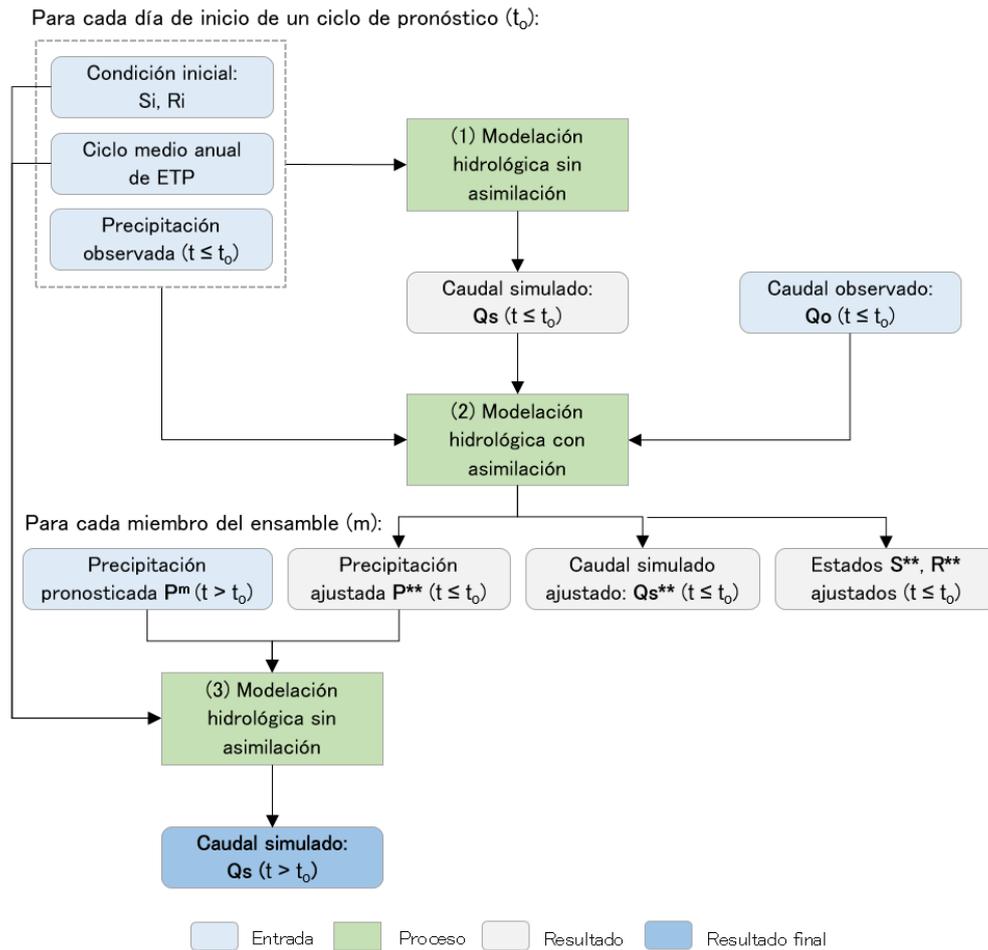


Figura 4-3: Diagrama de flujo con los pasos seguidos y la información considerada para la asimilación al modelo hidrológico de datos observados de caudal.

La metodología de asimilación se implementó en tres subcuencas de aporte al embalse de G. Terra (Figura 4-4):

- Paso Las Piedras: Cuenca alta del Río Negro (14.495 km^2), con registros medidos de caudal (estación automática).
- Paso Laguna II: Cuenca de aporte del río Tacuarembó (16.170 km^2), con registros medidos de caudal (estación automática).
- G. Terra: Cuenca incremental del embalse de G. Terra (8.900 km^2), considerando la serie de aportes teóricos de UTE.

En particular, se evaluaron dos configuraciones de asimilación:

(1) Registros medidos: Asimilando el dato en Paso Las Piedras y Paso Laguna II (sin ajustar la cuenca incremental aguas abajo).

(2) **Registros medidos + Estimación indirecta:** Asimilando el dato en Paso Las Piedras, Paso Laguna II y G. Terra.



Figura 4-4: Subcuencas del Río Negro consideradas para la asimilación de datos de caudal (Paso Las Piedras, Paso Laguna II y G. Terra).

4.3 EVALUACIÓN

En esta sección se presenta la evaluación del desempeño del modelo hidrológico con asimilación de datos de caudal en comparación con el modelo sin retroalimentación.

Los datos históricos de referencia empleados para la evaluación son los registros medidos de caudales diarios en Paso Las Piedras y Paso Laguna II y la serie diaria filtrada de los caudales teóricos en G. Terra mediante el filtro binomial con una ventana centrada de 7 días.

4.3.1 Evaluación retrospectiva

En primer lugar, se realizó una evaluación retrospectiva de la metodología propuesta mediante la simulación continua del modelo hidrológico con asimilación para el periodo completo, de enero de 2018 a enero de 2023, a partir

de la cual se seleccionó el valor de N (número de días antecedentes) y del coeficiente λ .

Para cada simulación con (N, λ) se calculó el porcentaje de sesgo (PBIAS), el coeficiente de eficiencia de Nash-Sutcliffe (NSE) y la raíz del error cuadrático medio (RMSE).

El PBIAS y el NSE se introdujeron en la sección 3.2.2. El RMSE da una idea de la magnitud promedio de los errores del caudal simulado, sin indicar la dirección de dichas desviaciones. Adopta valores en el intervalo $[0, +\infty]$, con un puntaje perfecto de 0.

Se incluye también el indicador PBIAS calculado a partir de la precipitación ajustada (precipitación media areal en cada cuenca considerada), tomando como referencia la estimación RK (“PBIAS Lluvia”).

Adicionalmente, para evaluar la eficiencia del procedimiento de asimilación se calculó un “índice de eficiencia” (Aubert et al., 2003; Brocca et al., 2010) según:

$$DA\ Eff = 100 \times \left(1 - \frac{\sum_{t=1} (Q_{ass}(t) - Q_{obs}(t))^2}{\sum_{t=1} (Q_{sim}(t) - Q_{obs}(t))^2} \right)$$

donde Q_{ass} es el caudal simulado con asimilación.

Si $DA\ Eff > 0$, la metodología de asimilación produce una mejora en la simulación de los caudales.

En las siguientes tablas se presenta un resumen de las simulaciones e indicadores de desempeño obtenidos en cada caso para Paso Las Piedras y Paso Laguna II, variando el número de días antecedentes (N) entre 1 y 6 días (considerando los tiempos de concentración de las cuencas de aporte) y el coeficiente λ entre 0,10 y 0,95. En la primera fila (en negrita) se incluyen los indicadores obtenidos para la simulación sin asimilación (simulación de referencia).

Tabla 4-1: Resumen de las simulaciones e indicadores de desempeño obtenidos en Paso Las Piedras variando el número de días antecedentes N y el coeficiente λ .

Simulación	N (días)	RMSE (m ³ /s)	NSE	PBIAS		DA Eff
				Caudal	Lluvia	
Sin asimilación		213	0,49	8,0%		
$\lambda = 0,10$	4	57	0,96	9,7%	3,3%	92,9
$\lambda = 0,50$	4	45	0,98	9,0%	1,3%	95,5
$\lambda = 0,85$	2	49	0,97	12,0%	2,5%	94,7
$\lambda = 0,85$	3	46	0,98	10,4%	1,4%	95,3
$\lambda = 0,85$	4	46	0,98	9,3%	0,4%	95,4
$\lambda = 0,85$	5	44	0,98	7,9%	-0,3%	95,7
$\lambda = 0,85$	6	46	0,98	7,0%	-1,0%	95,3
$\lambda = 0,95$	4	46	0,98	9,4%	0,1%	95,4

Tabla 4-2: Resumen de las simulaciones e indicadores de desempeño obtenidos en Paso Laguna II variando el número de días antecedentes N y el coeficiente λ .

Simulación	N (días)	RMSE (m ³ /s)	NSE	PBIAS		DA Eff
				Caudal	Lluvia	
Sin asimilación		144	0,74	13,5%		
$\lambda = 0,10$	4	66	0,95	11,6%	7,8%	78,9
$\lambda = 0,50$	4	51	0,97	10,1%	6,4%	87,7
$\lambda = 0,85$	2	76	0,93	17,9%	7,1%	72,6
$\lambda = 0,85$	3	56	0,96	13,0%	6,4%	84,9
$\lambda = 0,85$	4	50	0,97	10,2%	5,8%	87,9
$\lambda = 0,85$	5	49	0,97	8,5%	4,5%	88,5
$\lambda = 0,85$	6	49	0,97	7,1%	3,4%	88,7
$\lambda = 0,95$	4	50	0,97	10,2%	5,9%	88,0

En la Tabla 4-3 se presentan los resultados obtenidos para G. Terra en la configuración 1 para cada una de las combinaciones (N , λ) consideradas anteriormente. Se recuerda que en esta configuración sólo se asimilan los registros medidos en Paso Las Piedras y Paso Laguna II y no se ajusta la cuenca incremental aguas abajo.

Tabla 4-3: Resumen de las simulaciones e indicadores de desempeño obtenidos en G. Terra en la configuración 1 (sin asimilar el caudal teórico en G. Terra).

Simulación	N (días)	RMSE (m ³ /s)	NSE	PBIAS		DA Eff
				Caudal	Lluvia	
Sin asimilación		385	0,74	-2,5%		
$\lambda = 0,10$	4	296	0,85	-3,0%	4,5%	39,8
$\lambda = 0,50$	4	296	0,85	-3,7%	3,2%	39,7
$\lambda = 0,85$	2	302	0,84	0,0%	3,9%	37,2
$\lambda = 0,85$	3	299	0,84	-2,2%	3,2%	38,7
$\lambda = 0,85$	4	297	0,85	-3,6%	2,6%	39,4
$\lambda = 0,85$	5	296	0,85	-4,6%	1,8%	40,0
$\lambda = 0,85$	6	295	0,85	-5,4%	1,1%	40,3
$\lambda = 0,95$	4	297	0,85	-3,5%	2,5%	39,4

De los resultados obtenidos se desprende que, con la metodología de asimilación propuesta operando en modo continuo, se obtiene una mejora en el desempeño del modelo hidrológico. En general no se identifican grandes diferencias en el desempeño del modelo al variar los parámetros N y λ (dentro de rangos razonables). En las tres subcuencas se observa que la dependencia de los resultados al coeficiente λ es despreciable dentro del rango considerado en que las iteraciones convergen. Los indicadores de desempeño mejoran levemente al aumentar el número de días antecedentes (N), salvo en G. Terra que el PBIAS en el caudal aumenta en valor absoluto.

Si bien los ajustes en la precipitación media areal en la cuenca de G. Terra varían entre +1% y +4,5% (leve aumento relativo en el acumulado en todo el periodo simulado), esto no siempre se traduce en una disminución (en valor absoluto) del PBIAS en el caudal (en algunos casos la subestimación aumenta hasta un 3%). Esto puede deberse a que el leve aumento de la precipitación en las simulaciones con asimilación se destina a satisfacer la ETP (que tal vez en la simulación original no se llegara a cubrir totalmente) y/o a llenar el reservorio de producción del suelo (ver la evolución de la variable de estado S en las Figuras 4-12, 4-13 y 4-14, presentadas más adelante).

A modo de ejemplo, en la Figura 4-5 se presenta la evolución del error relativo de los caudales diarios en G. Terra para las simulaciones con $\lambda = 0,85$ y $N = 2, 3, 4$ y 6 días para la configuración 1. En cada caso, para cada paso de iteración, se presenta el error promedio en todo el periodo simulado (1857 días). Se observa que al disminuir N “empeora” la convergencia.

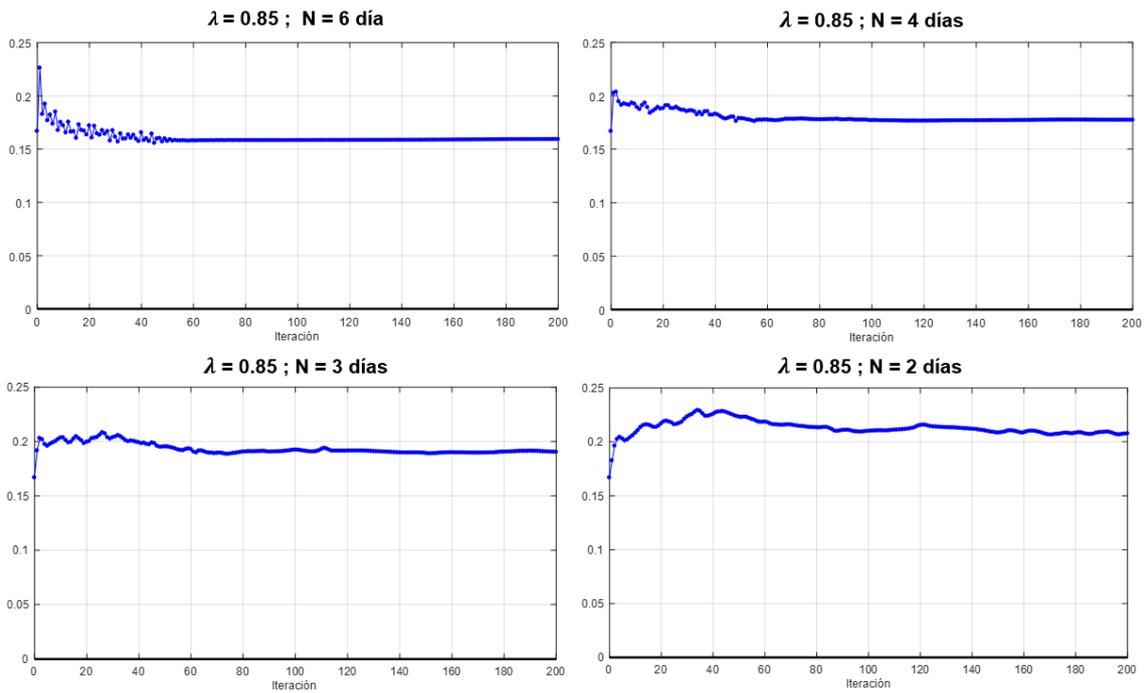


Figura 4-5: Evolución del error relativo de los caudales diarios en G. Terra para las simulaciones con $\lambda = 0,85$ y $N = 2, 3, 4$ y 6 días en la configuración 1.

En función de los resultados obtenidos se seleccionó $\lambda = 0,85$ y $N = 4$ días para la configuración 1 (simulación resaltada en negrita en la Tabla 4-3). En dicha simulación se tiene un compromiso entre el PBIAS en el caudal y los demás indicadores de desempeño, a la vez que se alcanza una buena convergencia del error con un PBIAS en la precipitación menor al 3% y un índice de eficiencia de la asimilación cercano a 40.

En las siguientes figuras se compara la evolución de los caudales diarios entre el caudal observado/teórico con filtro binomial (puntos grises) y el simulado sin asimilación (línea azul) y el simulado con asimilación (línea roja) para Paso Las Piedras, Paso Laguna II y G. Terra.

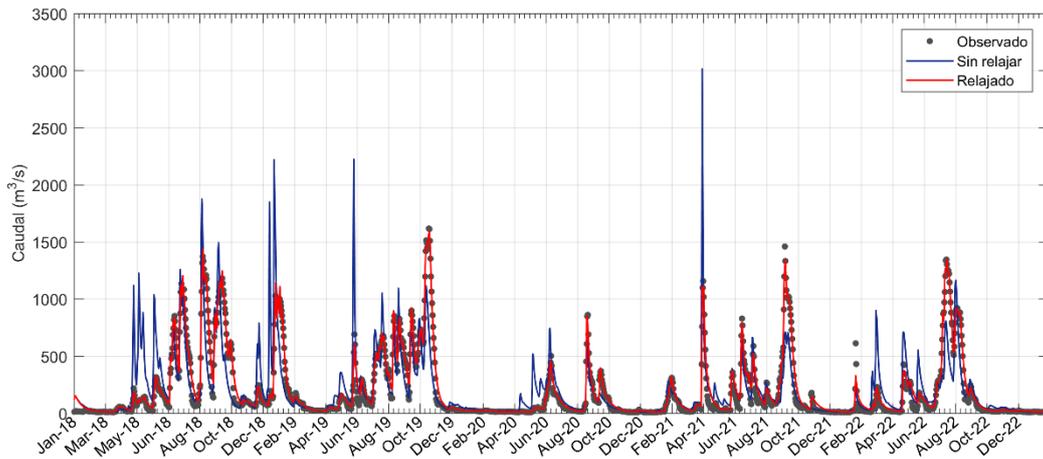


Figura 4-6: Comparación de la evolución de los caudales diarios en Paso Las Piedras en todo el periodo simulado: observado (puntos grises), simulado sin asimilación (línea azul) y simulado con asimilación (línea roja).

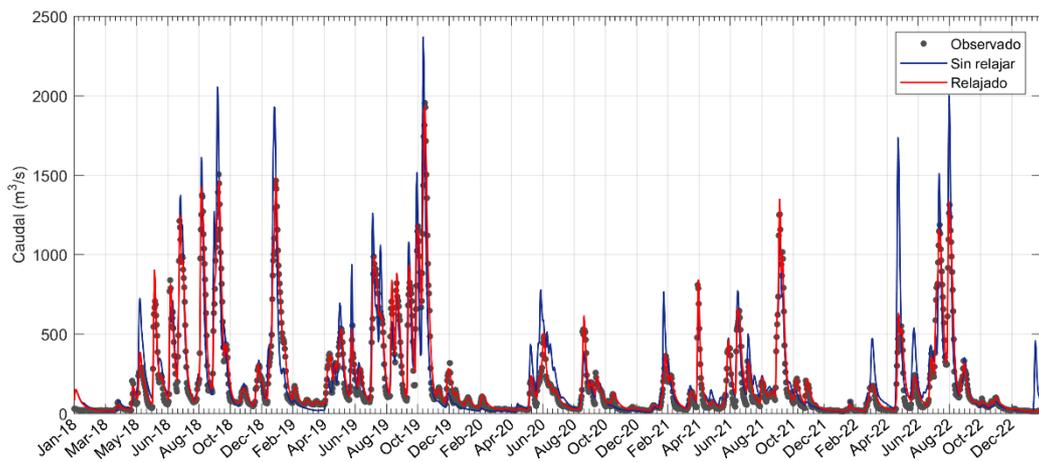


Figura 4-7: Comparación de la evolución de los caudales diarios en Paso Laguna II en todo el periodo simulado: observado (puntos grises), simulado sin asimilación (línea azul) y simulado con asimilación (línea roja).

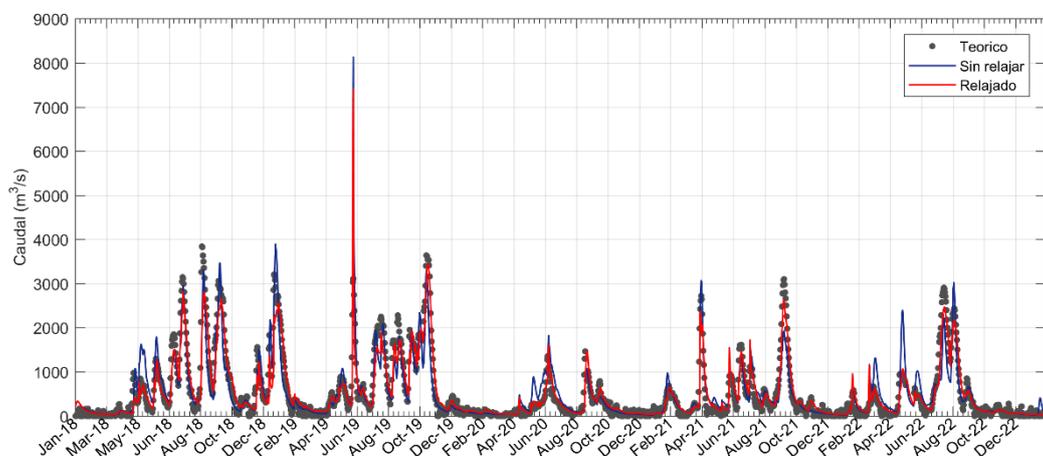


Figura 4-8: Comparación de la evolución de los caudales diarios de aporte al embalse de G. Terra en todo el periodo simulado: teórico con filtro binomial (puntos grises), simulado sin asimilación (línea azul) y simulado con asimilación (línea roja).

En la Tabla 4-4 se presentan los resultados obtenidos para G. Terra en la configuración 2 adoptando un valor de $\lambda = 0,85$ y variando el número de días antecedentes (N) para la corrección de la precipitación. Se recuerda que en esta configuración se asimilan tanto los registros medidos en Paso Las Piedras y Paso Laguna II, como el caudal teórico de aporte a G. Terra. En este caso, la serie a asimilar consiste en la serie teórica con el filtro binomial "continuo", la misma que se usa para la evaluación del desempeño. Por lo tanto, en esta modalidad se están usando valores futuros del caudal en G. Terra -que en modo operativo aún no se conocen- para ajustar la precipitación antecedente. A modo de referencia, en las primeras filas (en negrita) se incluyen los indicadores obtenidos para la simulación sin asimilación (simulación de referencia) y la simulación seleccionada en la configuración 1 ($\lambda = 0,85$ y $N = 4$ días).

Tabla 4-4: Resumen de los indicadores de desempeño obtenidos en G. Terra para $\lambda = 0,85$ variando el número de días antecedentes N en la configuración 2 (asimilando los registros medidos en Paso Las Piedras y Paso Laguna II y la estimación indirecta en G. Terra).

Simulación	Paso Las Piedras	Paso Laguna II	Gabriel Terra	RMSE (m ³ /s)	NSE	PBIAS		DA Eff
						Caudal	Lluvia	
Sin asimilación				385	0,74	-2,5%		
Conf. 1	N = 4	N = 4		297	0,85	-3,6%	2,6%	39,4
Conf. 2	N = 4	N = 4	N = 2	132	0,97	11,9%	12,0%	86,0
Conf. 2	N = 4	N = 4	N = 3	130	0,97	11,2%	10,8%	86,4
Conf. 2	N = 4	N = 4	N = 4	136	0,97	10,6%	10,0%	85,5
Conf. 2	N = 5	N = 5	N = 4	130	0,97	9,9%	9,5%	86,6
Conf. 2	N = 6	N = 6	N = 3	120	0,97	9,9%	9,9%	88,2
Conf. 2	N = 6	N = 6	N = 4	126	0,97	9,3%	8,9%	87,4

Nuevamente se observa una mejora del desempeño del modelo hidrológico al incorporar la metodología de asimilación de datos operando en modo continuo, alcanzando incluso mejores indicadores que en la configuración 1 (salvo el PBIAS). No se identifican grandes diferencias en el desempeño del modelo al variar el parámetro N dentro de rangos razonables (el coeficiente λ se fijó en 0,85).

En función de los resultados obtenidos para la configuración 2 se seleccionó $\lambda = 0,85$ y $N = (6, 6, 3)$ días para Paso Las Piedras, Paso Laguna II y G. Terra respectivamente (simulación resaltada en negrita en la Tabla 4-4). En dicha simulación se obtienen los valores óptimos para los indicadores de desempeño, a la vez que se alcanza una buena convergencia del error (Figura 4-9) con un PBIAS en la precipitación menor al 10% y un índice de eficiencia de la asimilación cercano a 90.

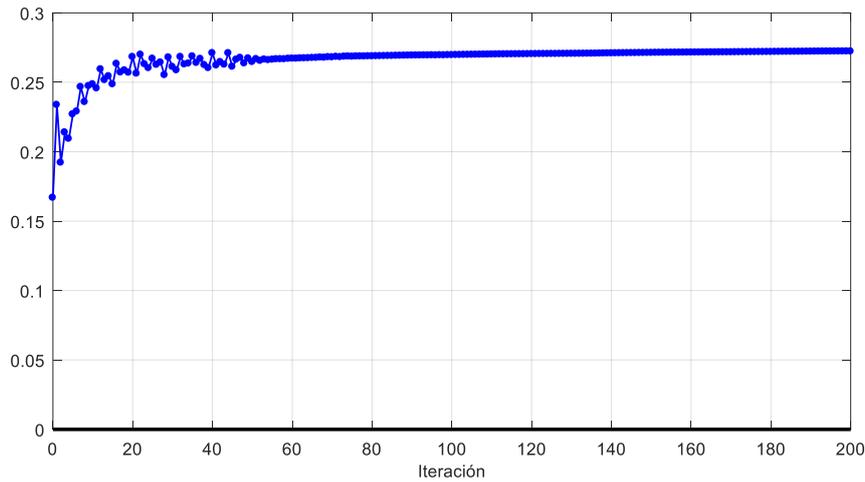


Figura 4-9: Evolución del error relativo de los caudales diarios en G. Terra para $\lambda = 0,85$ y $N = (6, 6, 3)$ días en la configuración 2.

Cabe destacar que, en este caso, se evaluó también el impacto de aplicar o no el filtro binomial a la serie teórica de aportes previo a la asimilación. Si bien los resultados obtenidos en la evaluación retrospectiva con y sin filtro binomial son muy similares, sí difieren en la evaluación de los pronósticos. En el caso de la simulación sin filtro binomial, los caudales resultantes al inicio del pronóstico son muy sensibles a los “saltos” de la serie teórica, aumentando significativamente el error inicial. Adicionalmente, buscando minimizar el impacto de los “saltos” de la serie teórica, se evaluó la posibilidad de considerar caudales promediados en distintos periodos (de 1 a 5 días), llegando a resultados muy similares en la evaluación retrospectiva. Sin embargo, en modo pronóstico el error inicial crece al aumentar el periodo de integración del caudal.

En la Figura 4-10 se presenta la comparación de la evolución de los caudales diarios de aporte al embalse G. Terra entre el caudal teórico con filtro binomial (puntos grises), el simulado sin asimilación (línea azul), el simulado con asimilación en la configuración 1 seleccionada (línea roja) y el simulado con asimilación en la configuración 2 seleccionada (línea verde).

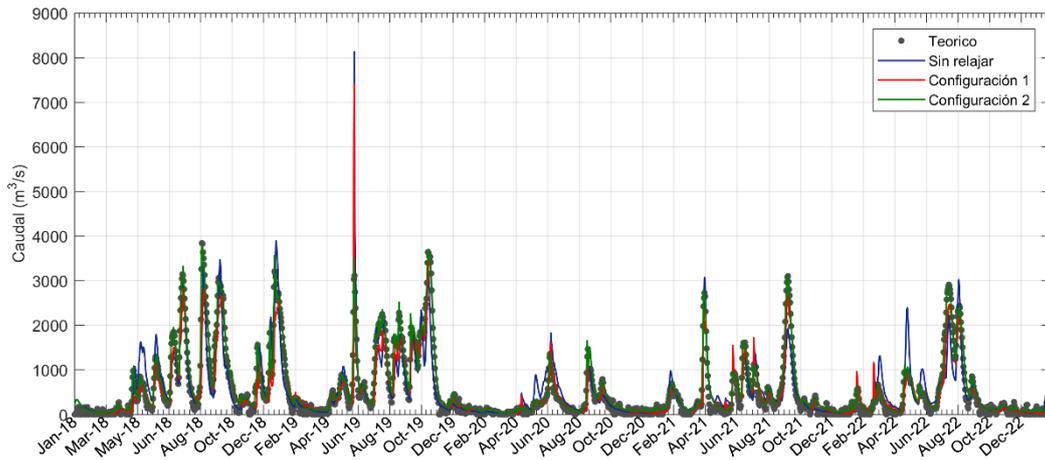


Figura 4-10: Comparación de la evolución de los caudales diarios de aporte al embalse de G. Terra en todo el periodo simulado: teórico con filtro binomial (puntos grises), simulado sin asimilación (línea azul), simulado con asimilación en la configuración 1 (línea roja) y simulado con asimilación en la configuración 2 (línea verde).

Luego, con el propósito de evaluar el impacto de la corrección en la precipitación, a modo de ejemplo en los paneles superiores de la Figura 4-11 se presenta la comparación de la evolución en el periodo enero a diciembre de 2018 de la estimación RK (barras azules) y la precipitación ajustada para las dos configuraciones de asimilación consideradas (barras rojas y verdes). En el panel inferior se presenta la comparación para los caudales diarios correspondientes.

Si bien no se observan grandes diferencias entre sí en la precipitación media areal resultante bajo las dos configuraciones consideradas, se identifica una leve tendencia a mayores montos en la configuración 2, que se traduce en una mejor representación de la evolución de los caudales teóricos filtrados. Esto es consistente con los resultados presentados en la Tabla 4-4, donde la configuración 2 presenta mejores indicadores RMSE, NSE y DA Eff, a costo de un mayor PBIAS.

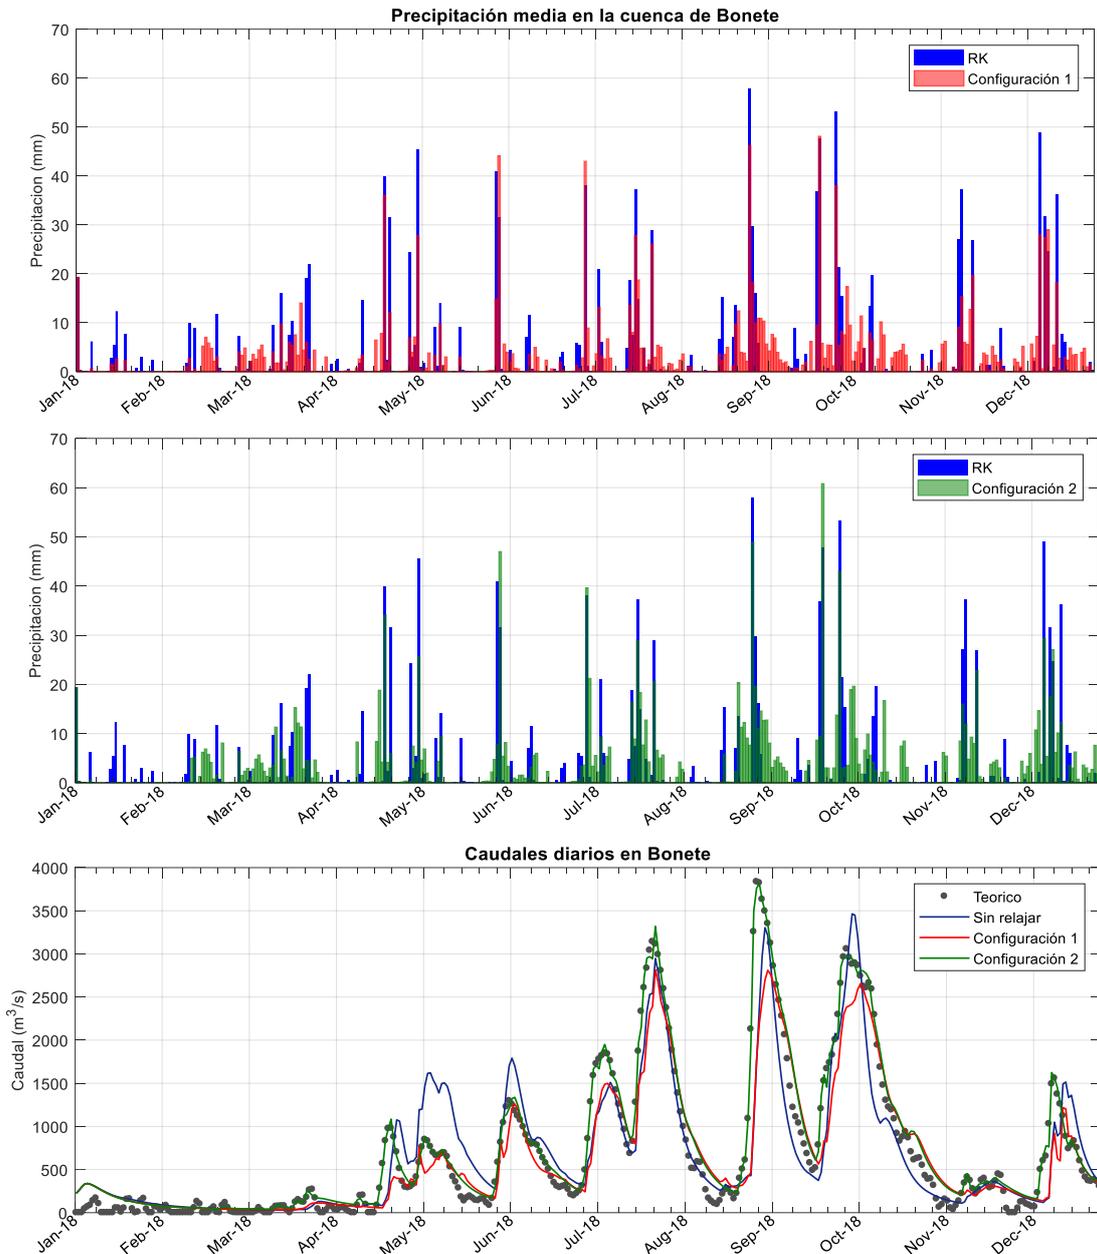


Figura 4-11: Evaluación del impacto de la asimilación en la precipitación media areal en la cuenca (panel superior: estimación RK vs precipitación ajustada en la configuración 1, panel medio: estimación RK vs precipitación ajustada en la configuración 2) y en los caudales diarios de aporte al embalse de G. Terra (panel inferior: caudal teórico con filtro binomial, simulado sin y con asimilación en ambas configuraciones) para el año 2018.

Finalmente, en las siguientes figuras se presenta la comparación, entre las simulaciones con y sin asimilación, de la evolución de las variables de estado del modelo hidrológico (niveles S y R) en las subcuencas de Paso Las Piedras, Paso Laguna II y G. Terra durante todo el periodo simulado. Cabe destacar que, en la Figura 4-14 (subcuenca G. Terra) no se presenta la evolución para la configuración 1, ya que en ese caso no hay ajuste en las subcuencas aguas abajo de Paso Las Piedras y Paso Laguna II.

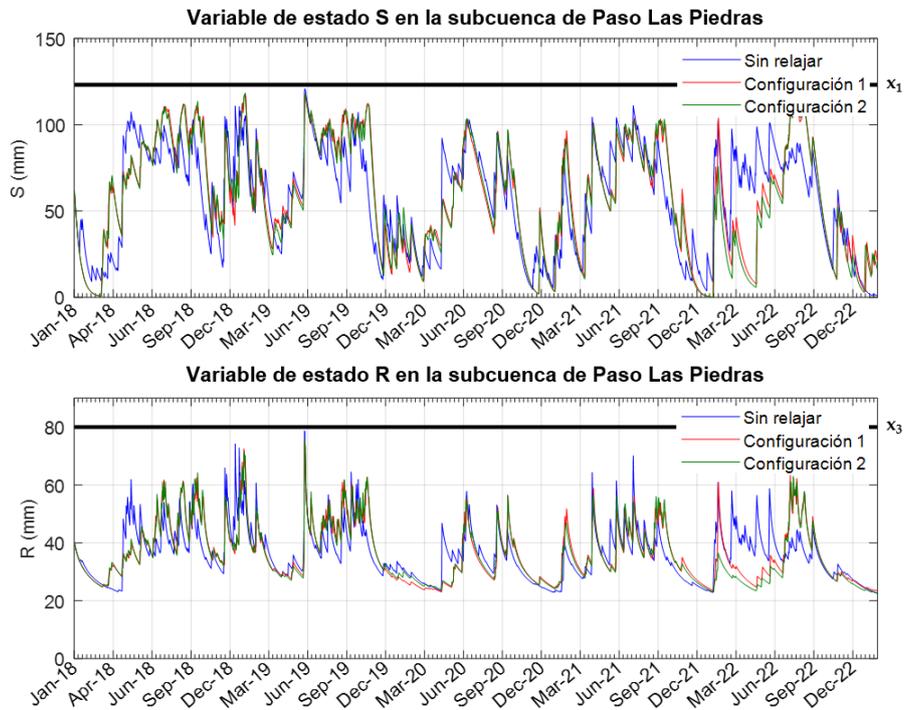


Figura 4-12: Comparación de la evolución de las variables de estado del modelo hidrológico (niveles S y R) en la subcuenca de Paso Las Piedras: simulación sin asimilación (azul), simulación con asimilación en la configuración 1 (rojo) y configuración 2 (verde).

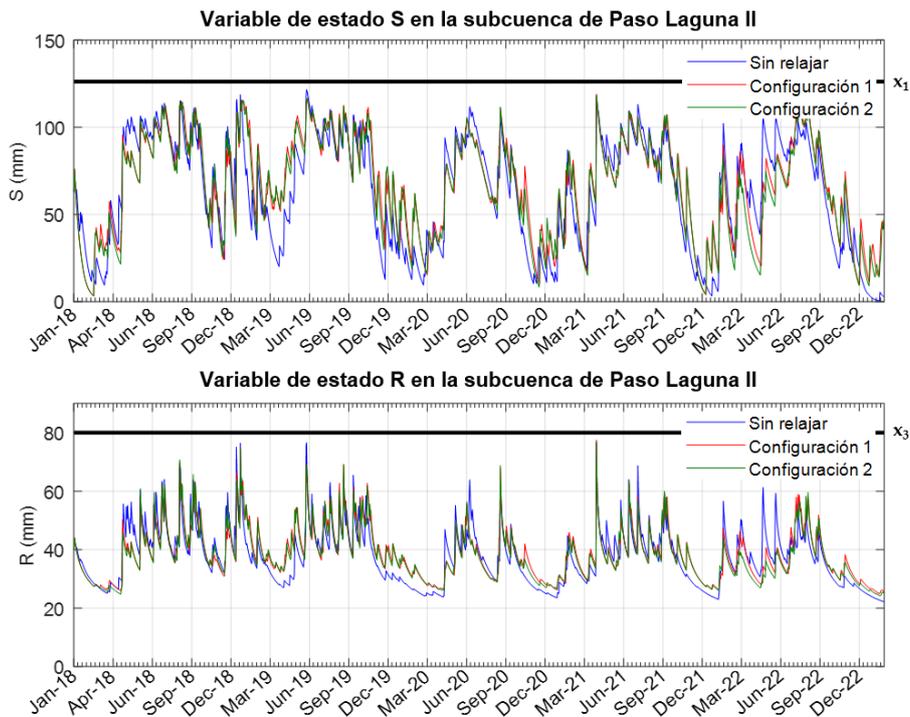


Figura 4-13: Comparación de la evolución de las variables de estado del modelo hidrológico (niveles S y R) en la subcuenca de Paso Laguna II: simulación sin asimilación (azul), simulación con asimilación en la configuración 1 (rojo) y la configuración 2 (verde).

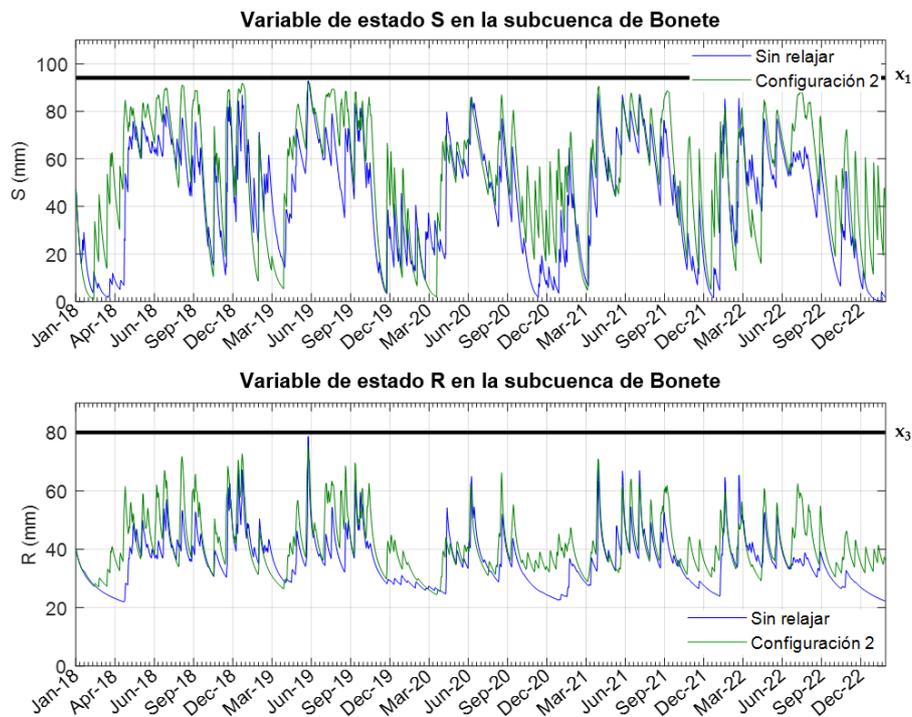


Figura 4-14: Comparación de la evolución de las variables de estado del modelo hidrológico (niveles S y R) en la subcuenca de G. Terra: simulación sin asimilación (azul), simulación con asimilación en la configuración 1 (rojo) y configuración 2 (verde).

De los resultados obtenidos anteriormente se desprende que, con la corrección propuesta en proporción al error de los caudales simulados operando en modo continuo, se obtiene una representación satisfactoria de la evolución de dichos caudales sin alterar la dinámica interna del modelo hidrológico.

En esta modalidad, sin embargo, se están usando valores futuros del caudal -que en modo operativo aún no se conocen- para ajustar la precipitación antecedente y, por ende, los estados S y R. Esta dificultad se abordará al presentar la evaluación de los pronósticos (sección 4.3.2).

4.3.2 Evaluación en modo pronóstico

En esta sección se presenta la evaluación del desempeño de los ensambles de pronósticos de caudal obtenidos con el modelo hidrológico con asimilación de datos, en comparación con el desempeño del modelo actualmente en funcionamiento en ADME (sin retroalimentación).

La metodología seguida para la evaluación de los ensambles de pronósticos de caudales es análoga a la desarrollada en el capítulo 3:

- Cálculo del error en el caudal al inicio del pronóstico. Dado que lo que se busca con la metodología de asimilación propuesta es ajustar los estados iniciales de S y R para cada ciclo de pronóstico mediante la corrección de

la precipitación antecedente según el error relativo del caudal simulado, aquí se evalúa explícitamente el error al inicio de cada simulación.

- Inspección visual de la evolución de los pronósticos de caudales a lo largo del horizonte de pronóstico.
- Caracterización del error del ensamble a lo largo del horizonte de pronóstico (considerando la media del ensamble y el ensamble completo).
- Cálculo de indicadores de desempeño (PBIAS y NSE).

En todos los casos se incluye la comparación con los resultados obtenidos con el modelo sin asimilación.

A continuación, se presentan los principales resultados obtenidos para la cuenca de aporte al embalse de G. Terra con las dos configuraciones de asimilación consideradas: (1) Registros medidos en Paso Las Piedras y Paso Laguna II, (2) Registros medidos en Paso Las Piedras y Paso Laguna II y estimación indirecta de los aportes al embalse.

Cabe destacar que, para la asimilación del caudal teórico de aporte al embalse de G. Terra (configuración 2), la serie a asimilar consiste en la serie teórica con el filtro binomial hasta el día del inicio del pronóstico (sin utilizar valores futuros del caudal que en modo operativo aún no se conocen).

Error al inicio del pronóstico

Con el propósito de cuantificar el impacto de la asimilación de datos de caudal observados en el modelo hidrológico, se calculó el error al inicio de cada ciclo de pronóstico. En particular, se compara el valor del caudal teórico filtrado en el "día 0" con el obtenido con el modelo hidrológico alimentado por la estimación RK (sin asimilación) y la precipitación ajustada (con asimilación). Cabe destacar que dicho error inicial es el mismo para todos los miembros del ensamble, ya que únicamente depende de la representación de la precipitación histórica y de su transformación a caudal (es independiente de los pronósticos del GEFS).

En la Figura 4-15 se presenta el diagrama de dispersión del caudal simulado (eje y) con el modelo con y sin asimilación versus el caudal teórico filtrado (eje x) correspondiente al día de inicio de cada uno de los 777 ciclos de pronósticos analizados. En los paneles de la derecha se presentan nuevamente los diagramas de dispersión, pero en escala logarítmica.

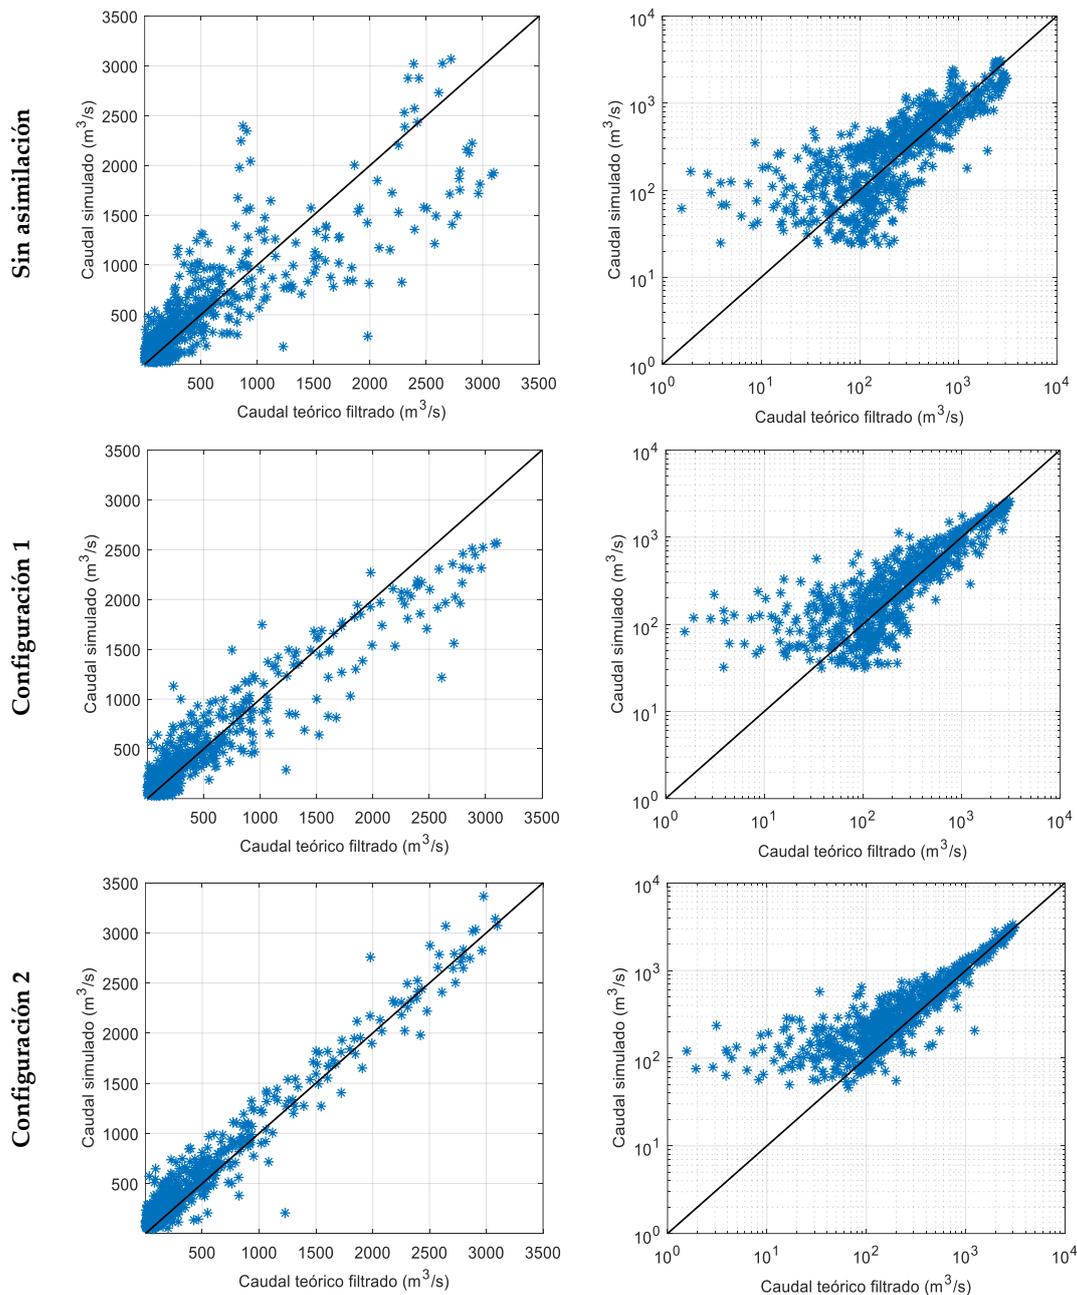


Figura 4-15: Diagrama de dispersión del caudal simulado (eje y) versus el caudal teórico filtrado (eje x) al inicio de cada ciclo de pronóstico para la cuenca G. Terra. En los paneles de la derecha se presentan los diagramas en escala logarítmica.

Se observa que la asimilación en la configuración 2 reduce significativamente la dispersión de la nube de puntos, aunque para caudales bajos no logra corregir el marcado sesgo positivo (sobrestimación) existente en el modelo sin asimilación. En la configuración 1 la reducción de la dispersión no es tan notoria, a la vez que se identifica también una subestimación de los caudales altos.

Inspección visual

A modo ilustrativo, en las siguientes figuras se presentan algunos ejemplos de los pronósticos emitidos para la precipitación media en la cuenca (panel superior) y los correspondientes caudales de aporte (panel inferior). En el panel superior, el gráfico de barras en azul representa la evolución de la precipitación observada (estimación RK), el gráfico de barras en rojo corresponde a la precipitación ajustada luego de la asimilación (P^{**}), las líneas continuas grises representan la evolución de cada uno de los miembros del ensamble del GEFS (P^m) y en trazo gris discontinuo se muestra la evolución de la media del ensamble. En el panel inferior, la línea azul representa la evolución de los caudales teóricos (en trazo grueso se incluye también la serie con el filtro binomial continuo), en trazo gris continuo se presenta la evolución de cada uno de los miembros del ensamble y, en trazo gris discontinuo, la evolución de la media del ensamble. En rojo se incluye la evolución del caudal modelado en base a la precipitación ajustada P^{**} hasta el día del inicio del pronóstico, y en naranja se incluye la evolución del caudal modelado en base a la estimación RK (línea continua) y la correspondiente evolución de la media del ensamble (trazo discontinuo). La serie naranja corresponde a la simulación “original” sin asimilación. Se incluye también, en trazo azul discontinuo, la evolución del caudal teórico filtrado hasta el día del inicio del pronóstico (serie asimilada en la configuración 2).

Para cada uno de los ejemplos seleccionados se presentan los resultados obtenidos en las dos configuraciones de asimilación.

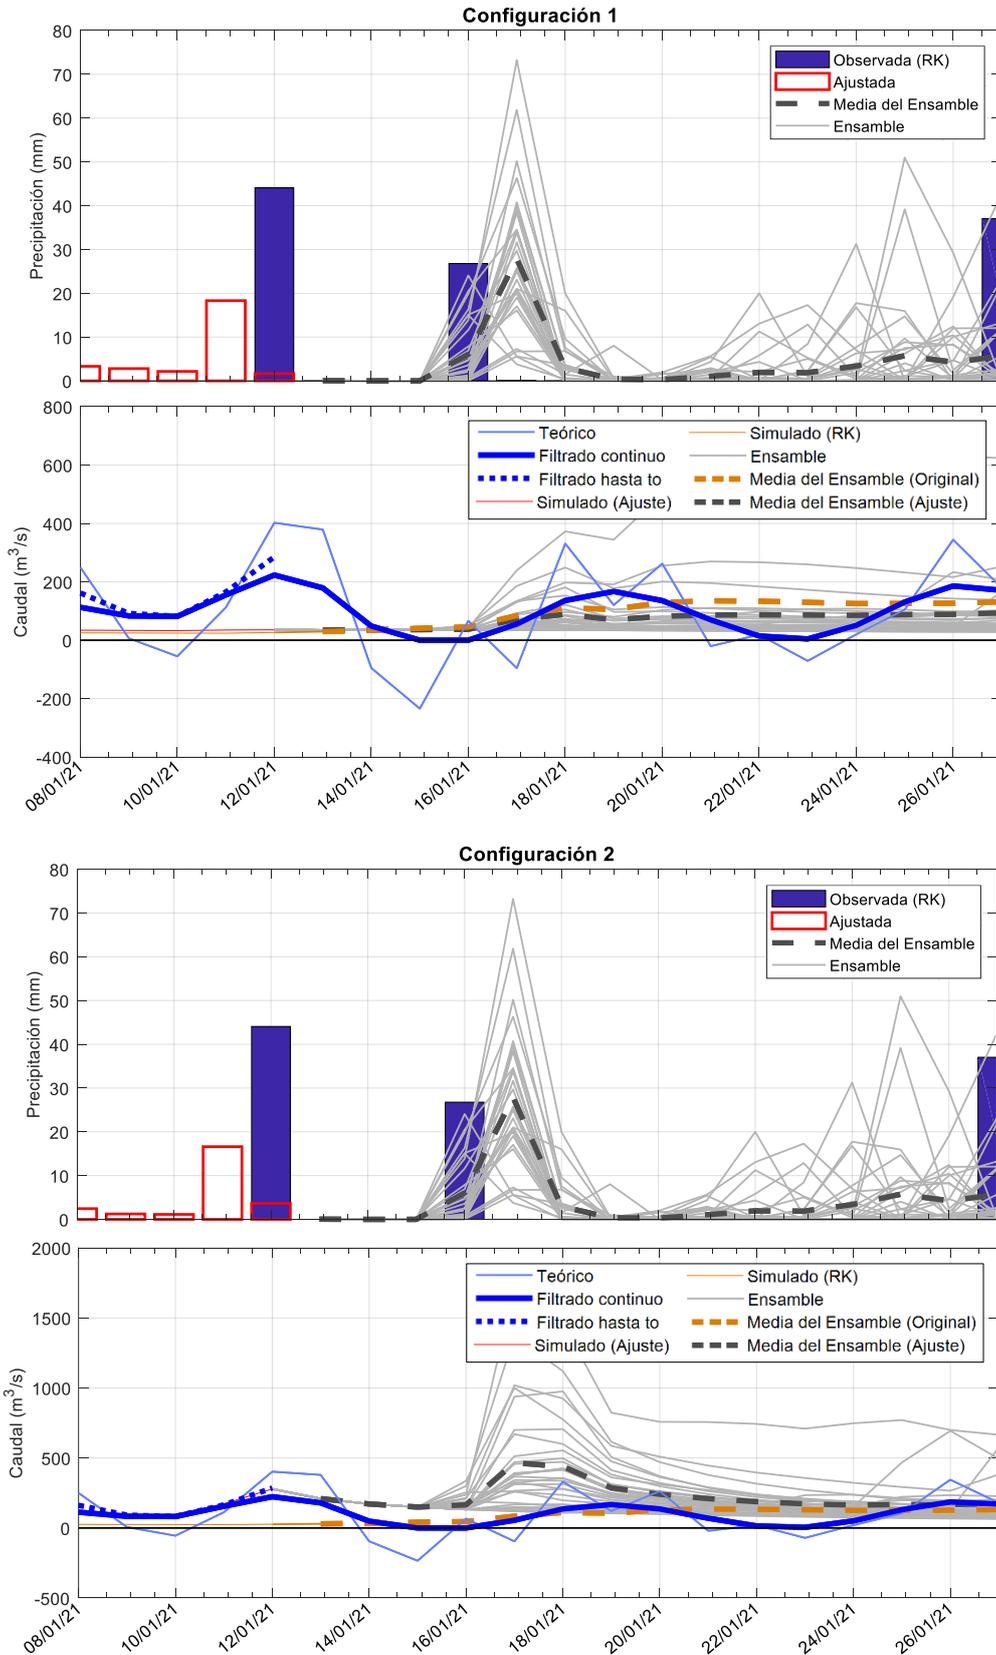


Figura 4-16: Ejemplos de pronósticos para el ciclo inicializado el 12/01/2021 para la cuenca G. Terra (paneles superiores: Configuración 1, paneles inferiores: Configuración 2).

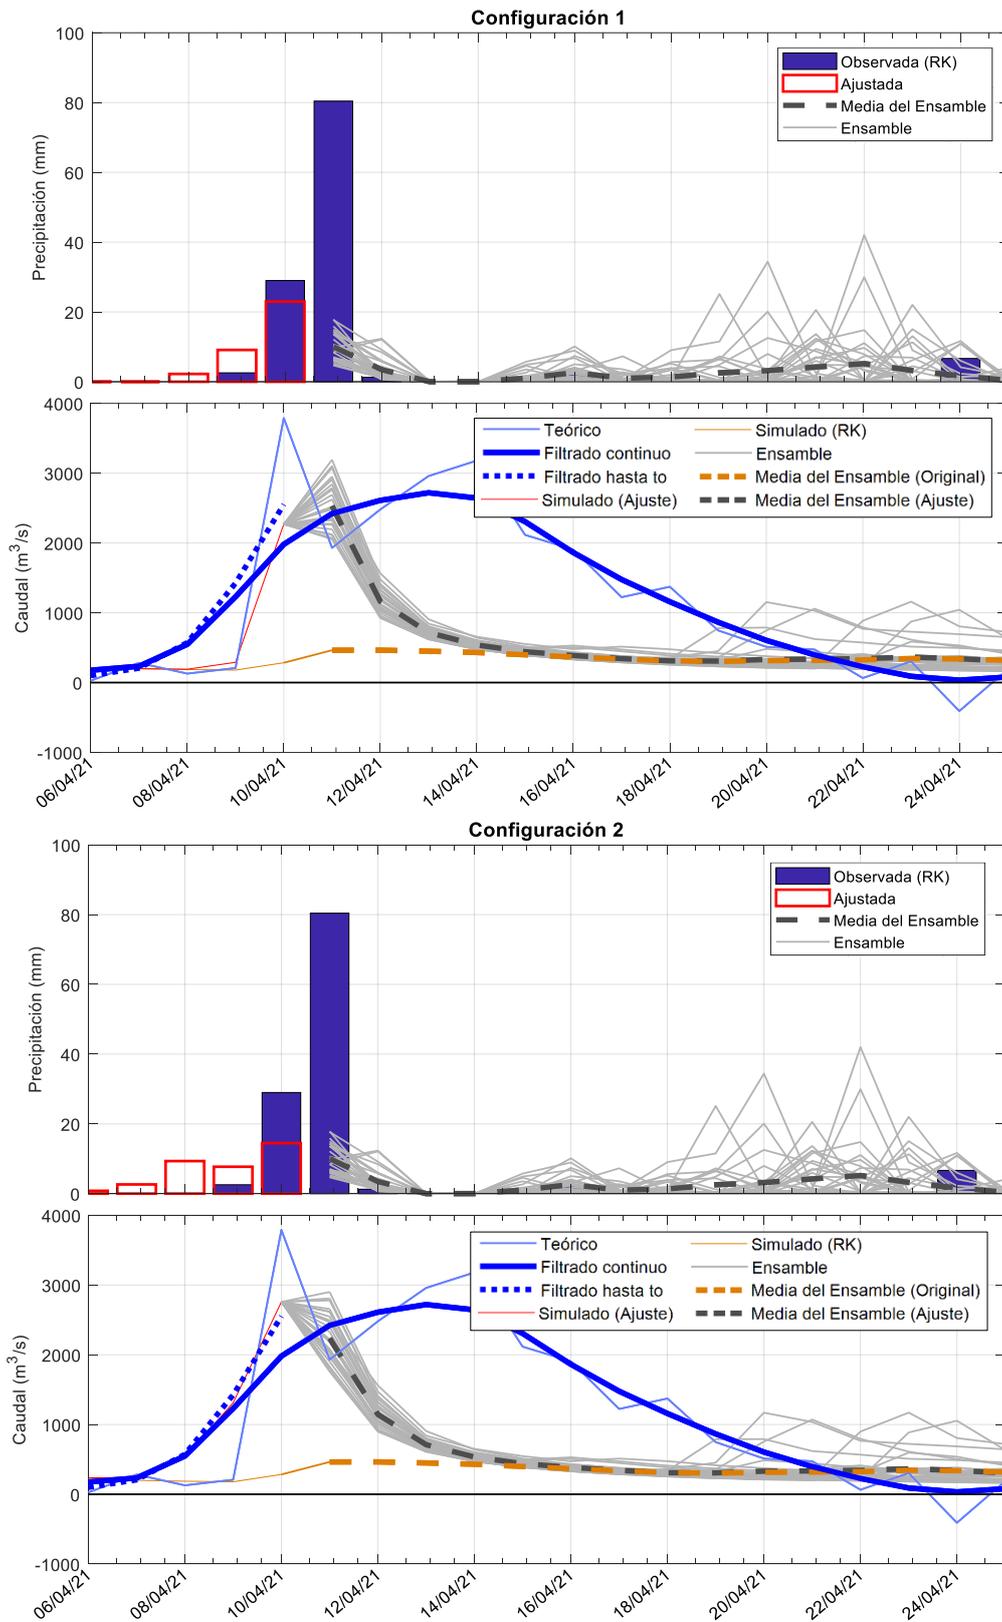


Figura 4-17: Ejemplos de pronósticos para el ciclo inicializado el 10/04/2021 para la cuenca G. Terra (paneles superiores: Configuración 1, paneles inferiores: Configuración 2).

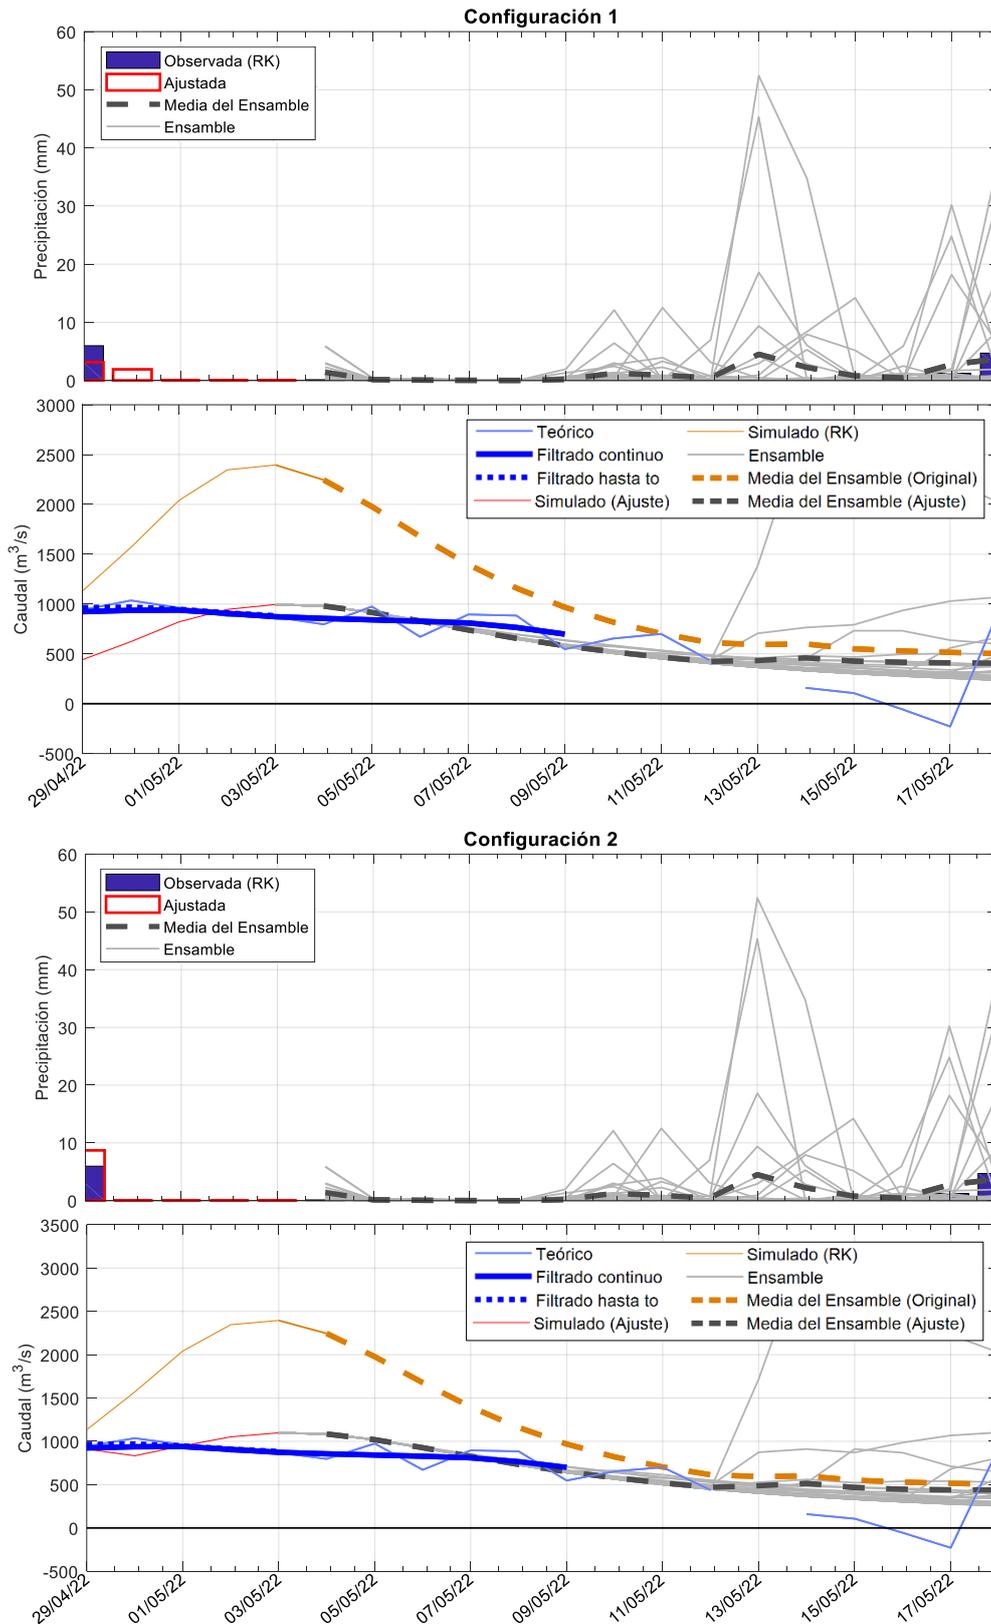


Figura 4-18: Ejemplos de pronósticos para el ciclo inicializado el 3/05/2022 para la cuenca G. Terra (paneles superiores: Configuración 1, paneles inferiores: Configuración 2).

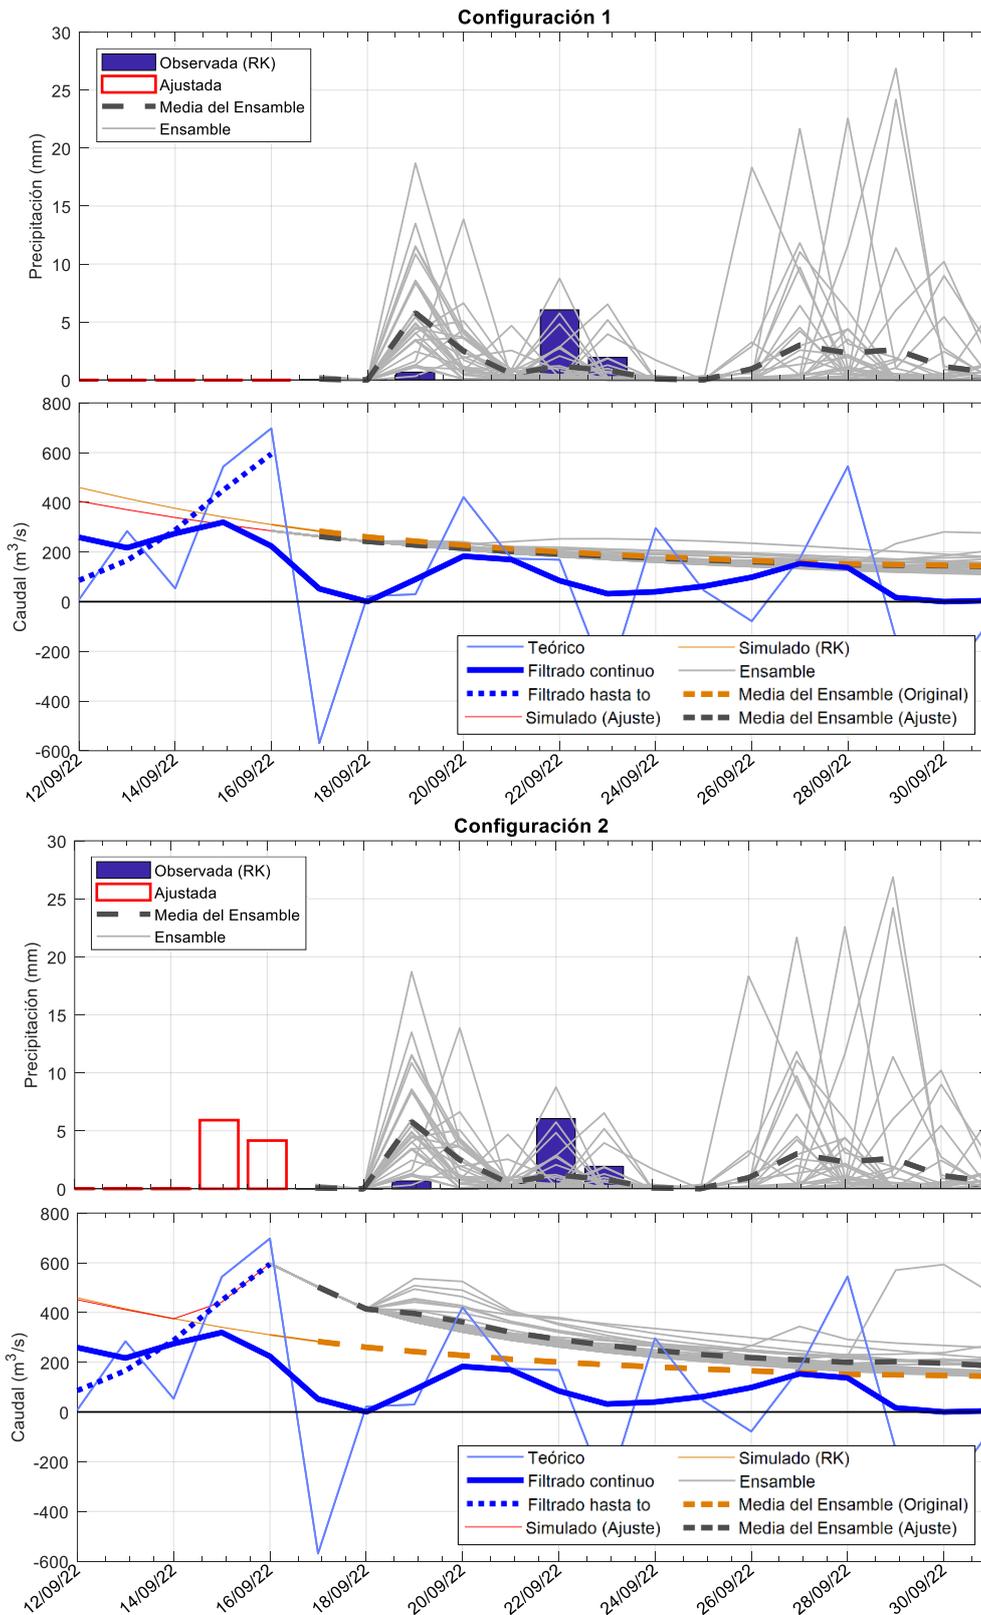


Figura 4-19: Ejemplos de pronósticos para el ciclo inicializado el 16/09/2022 para la cuenca G. Terra (paneles superiores: Configuración 1, paneles inferiores: Configuración 2).

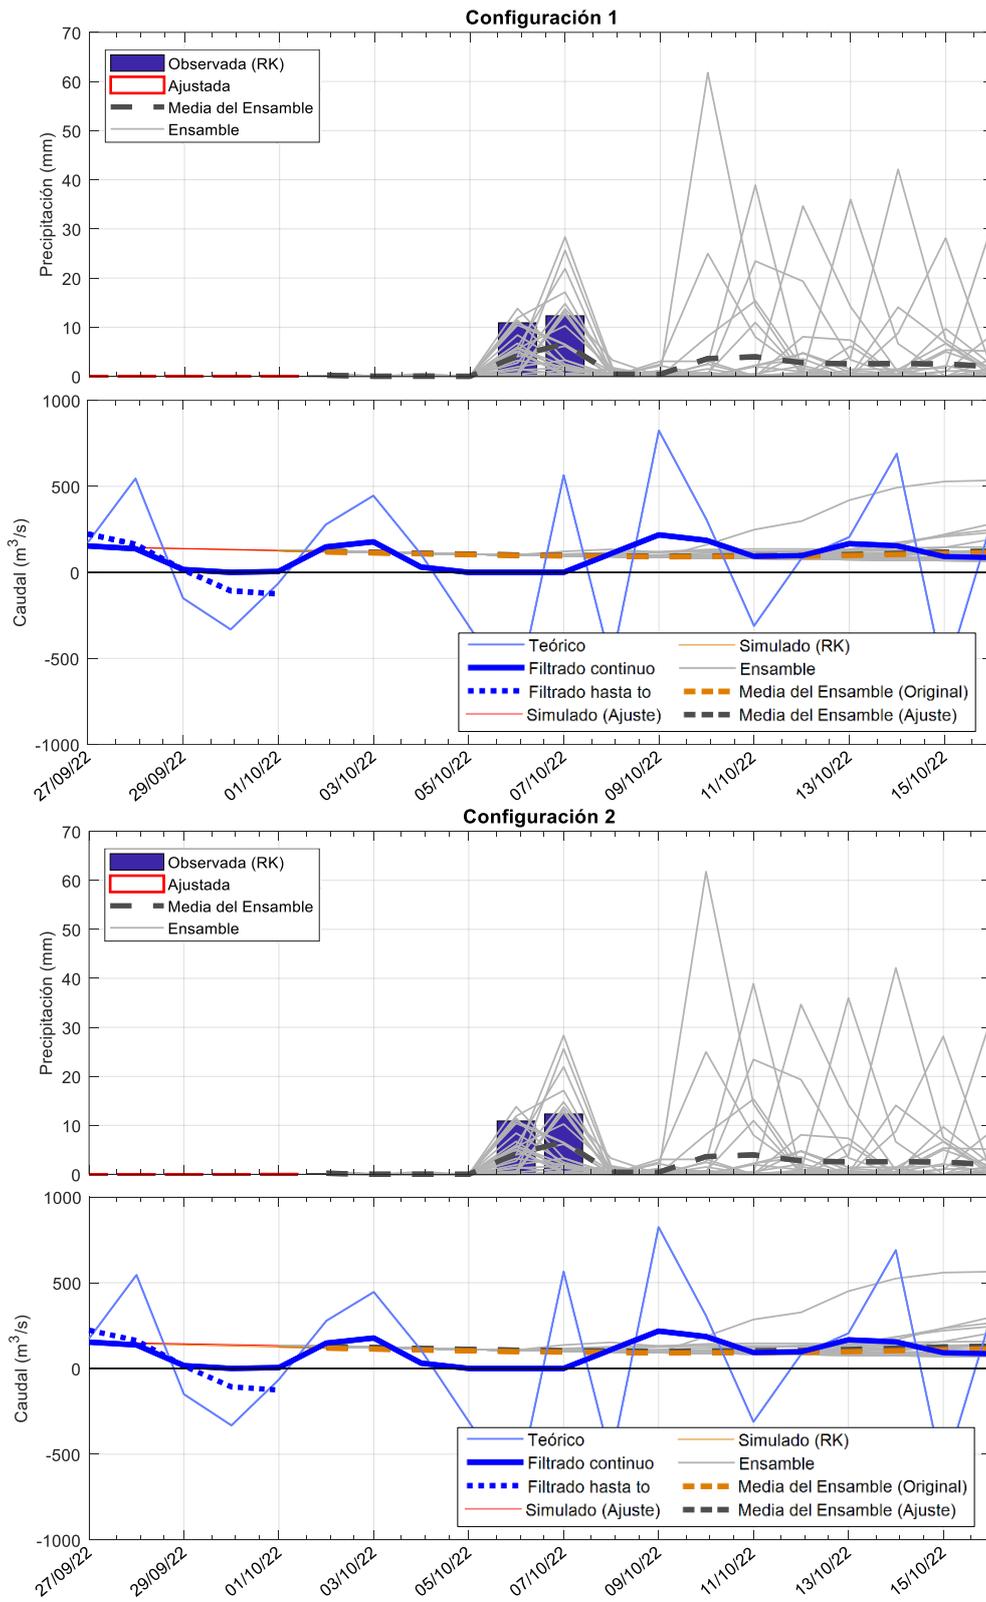


Figura 4-20: Ejemplos de pronósticos para el ciclo inicializado el 1/10/2022 para la cuenca G. Terra (paneles superiores: Configuración 1, paneles inferiores: Configuración 2).

De los ejemplos anteriores se desprende que:

- En general, con la metodología de asimilación propuesta, se obtiene un ajuste (en el sentido deseado) del estado inicial del sistema.
- Con la configuración 1, asimilando solamente los registros medidos en Paso Las Piedras y Paso Laguna II, no siempre se logra dicho ajuste (Figura 4-16).
- Los caudales resultantes al inicio del pronóstico en la configuración 2, asimilando la serie teórica con el filtro binomial hasta dicho día, son muy sensibles a los saltos/oscilaciones de la serie, particularmente en periodos de sequía como el analizado (Figura 4-19).
- En los casos en que el modelo sin asimilación sobrestima el caudal teórico y la precipitación antecedente acumulada es nula, por construcción, la metodología propuesta no es capaz de corregir dicha diferencia (Figura 4-20).

Caracterización de la evolución del error del ensamble

En la Figura 4-21 se presenta un gráfico de caja (boxplot) con la evolución del error de la media del ensamble (calculado como la distancia entre la media y el valor teórico filtrado) a lo largo del horizonte de pronóstico, para el modelo original (serie gris) y el modelo con asimilación (serie celeste: configuración 1, serie verde: configuración 2). Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes) en los ciclos de pronóstico. Cabe destacar que, para facilitar la visualización, se presenta la evolución para los primeros 10 días del horizonte de pronóstico.

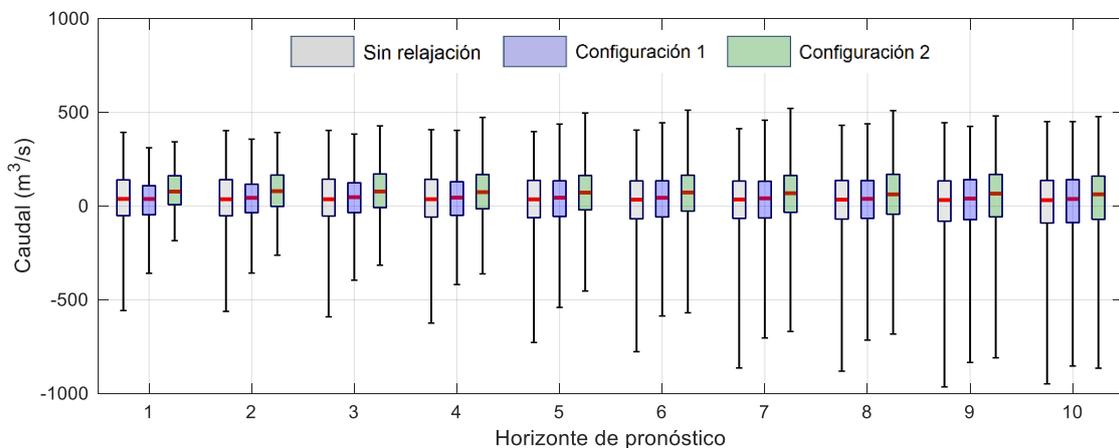


Figura 4-21: Evolución del error de la media del ensamble para el modelo original (serie gris) y el modelo con asimilación (serie celeste: configuración 1, serie verde: configuración 2) en la cuenca G. Terra. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes).

En la Figura 4-22 se presenta la evolución a lo largo del horizonte de pronóstico de la raíz del error cuadrático medio (RMSE) de los miembros del ensamble, para

el modelo original (serie gris) y el modelo con asimilación (serie celeste: configuración 1, serie verde: configuración 2). Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes). El RMSE del ensamble para cada ciclo de pronóstico se calcula como la raíz de la suma del error cuadrático de cada miembro del ensamble dividida el número total de miembros.

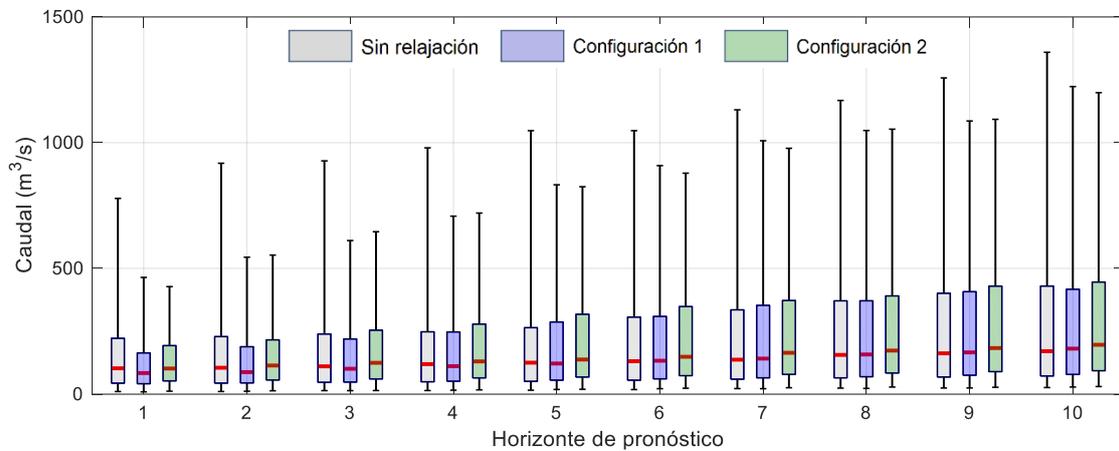


Figura 4-22: Evolución del RMSE del ensamble para el modelo original (serie gris) y el modelo con asimilación (serie celeste: configuración 1, serie verde: configuración 2) en la cuenca G. Terra. Se incluyen los percentiles 25, 50, 75 (cajas) y 5 y 95 (bigotes).

Se observa que en la configuración 1 (serie azul), tanto para el error de la media como el RMSE del ensamble, la asimilación reduce el error en los tres primeros días del horizonte de pronóstico. En la configuración 2 (serie verde), la distribución de los errores se encuentra levemente desplazada hacia valores mayores (sobre todo en el caso del error de la media del ensamble).

Indicadores de desempeño

En la Figura 4-23 se presenta la comparación de la evolución a lo largo del horizonte de pronóstico del indicador PBIAS de la media del ensamble de caudales para el modelo sin asimilación (serie azul) y el modelo con asimilación (serie roja: configuración 1, serie verde: configuración 2). A modo de referencia, se incluyen las calificaciones generales para dicho estadístico reportadas por Moriasi et al. 2015.

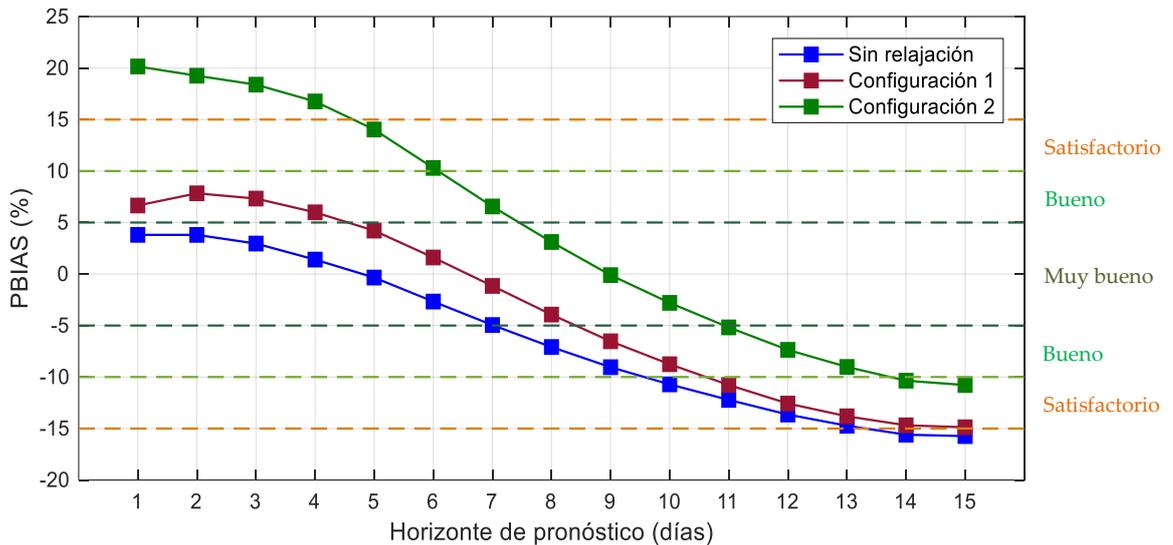


Figura 4-23: Evolución del indicador PBIAS de la media del ensamble de caudales para el modelo sin asimilación (serie azul) y el modelo con asimilación (serie roja: configuración 1, serie verde: configuración 2) en la cuenca G. Terra.

Para ambas configuraciones se observa que la asimilación aumenta el PBIAS. El desempeño del modelo en la configuración 1 está entre bueno y muy bueno ($PBIAS < \pm 10\%$) hasta el día 10 de pronóstico (igual que el modelo sin ajuste), mientras que la configuración 2 presenta un desempeño no satisfactorio durante los primeros 4 días de pronóstico.

Como se identificó anteriormente en la Figura 4-15, los modelos con y sin asimilación presentan un marcado sesgo positivo (sobrestimación) para los caudales bajos (muy frecuentes en el periodo analizado). En la configuración 1, además de la sobrestimación de los caudales bajos, se identificó una subestimación de los caudales altos, lo cual seguramente esté influenciando el valor de este estadístico: al calcular el acumulado en todo el periodo ambos sesgos (con signo contrario) pueden compensarse y reducir el valor del PBIAS resultante (no siendo así en la configuración 2).

Análogamente, en la Figura 4-24 se presenta la evolución del NSE de la media del ensamble para las simulaciones con y sin asimilación. Nuevamente, a modo de referencia, se incluyen las calificaciones generales para dicho estadístico reportadas por Moriasi et al. 2015.

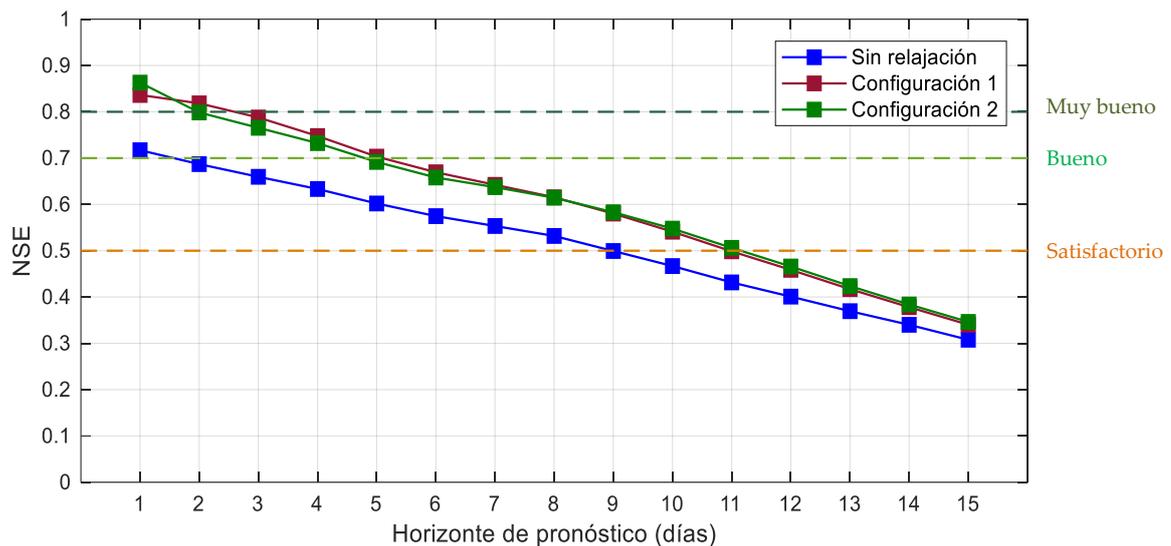


Figura 4-24: Evolución del indicador NSE de la media del ensamble de caudales para el modelo sin asimilación (serie azul) y el modelo con asimilación (serie roja: configuración 1, serie verde: configuración 2) en la cuenca G. Terra.

En el caso del NSE, los modelos con asimilación presentan un mejor desempeño que el modelo original a lo largo de todo el horizonte de pronóstico. No se observan diferencias significativas entre las dos configuraciones de asimilación implementadas, en ambos casos el desempeño es entre muy bueno y bueno ($NSE > 0.7$) hasta el día 5 de pronóstico y satisfactorio hasta el día 11 ($NSE > 0.5$).

4.4 SÍNTESIS

En el presente capítulo se desarrolló una metodología para la asimilación al modelo hidrológico de datos observados de caudal en la cuenca del Río Negro, la cual puede ser implementada de manera operativa con la información disponible. Dicha metodología se aleja conceptualmente de los diseños tradicionales de relajación o “nudging” de datos observados a sistemas de pronóstico (Kalnay, 2003; Brocca et al., 2010; Mazzoleni et al., 2018), en los cuales la variable observada que se asimila es una variable de estado del sistema de pronóstico. En el caso de estudio, la variable observada disponible es una salida del modelo, caudales en puntos de cierre de algunas subcuencas, por lo que no puede ser ajustada directamente. Si se relajan las variables de estado del modelo hidrológico GR4J (niveles de agua en los reservorios de producción y de tránsito, S y R respectivamente), se altera totalmente la dinámica hidrológica interna del modelo, volviéndolo irrelevante. Los estados S y R resultantes, por su parte, constituyen una pésima condicional inicial para la siguiente etapa de pronóstico del sistema. Por tanto, en la asimilación que se instrumentó el ajuste se plantea como una corrección de la precipitación antecedente (forzante que representa la mayor fuente de incertidumbre del proceso de modelación) hasta el día de inicio del pronóstico, proporcional a la amplitud del error relativo del caudal simulado.

Dicha corrección produce estados del sistema (S y R), hidrogramas (UH1 y UH2) y caudales hidrológicamente consistentes. La misma puede ser implementada solo en aquellas cuencas en donde se cuenta con registro observado de caudales y por tanto se puede estimar el error del sistema de pronóstico.

En particular, la metodología propuesta se implementó en tres subcuencas de aporte al embalse de G. Terra: (i) la cuenca alta del Río Negro (14.495 km²), con registros medidos de caudal en la estación Paso Las Piedras; (ii) la cuenca de aporte del río Tacuarembó (16.170 km²), con registros medidos de caudal en la estación Paso Laguna II; (iii) la cuenca incremental de aporte al embalse de G. Terra (8.900 km²), considerando la serie de aportes teóricos de UTE (estimación indirecta a partir de un balance de masa al embalse).

En primer lugar, se realizó una evaluación retrospectiva de la metodología mediante la simulación continua del modelo hidrológico con asimilación para el periodo enero de 2020 a enero de 2023, a partir de la cual se ajustó el valor de los parámetros (número de días antecedentes N y coeficiente λ) para cada subcuenca considerada. De los resultados obtenidos se desprende que, con la corrección propuesta se obtiene una buena representación de la evolución de dichos caudales sin alterar la dinámica interna del modelo hidrológico, con un desempeño superior al del modelo sin asimilación. En esta modalidad, sin embargo, se están usando valores futuros del caudal -que en modo operativo aún no se conocen- para ajustar la precipitación antecedente y por ende los estados S y R.

Posteriormente, se evaluó el desempeño de los ensambles de pronósticos de caudal obtenidos con el modelo hidrológico con asimilación de datos en Paso Las Piedras, Paso Laguna II y G. Terra hasta el día en que se inicia el pronóstico, en comparación con el desempeño del modelo actualmente en funcionamiento en ADME (sin asimilación alguna). La metodología de evaluación seguida es análoga a la desarrollada en el capítulo 3: cálculo del error en el caudal al inicio del pronóstico, inspección visual de la evolución de los pronósticos de caudales a lo largo del horizonte de pronóstico, caracterización del error del ensamble a lo largo del horizonte de pronóstico, cálculo de indicadores de desempeño (PBIAS y NSE).

De los resultados obtenidos en la evaluación de los pronósticos por ensambles se concluye que la metodología de asimilación propuesta logra reducir significativamente el error al inicio del pronóstico. Sin embargo, para caudales bajos (muy frecuentes en el periodo analizado), el ajuste no logra corregir el marcado sesgo positivo (sobrestimación) existente en el modelo original. En particular el desempeño de la configuración 2, asimilando en G. Terra la serie teórica con el filtro binomial hasta el día de inicio del pronóstico, es muy sensible a los “saltos” y limitaciones particulares identificadas en la serie teórica de

aportes. La mejora en el desempeño se atenúa a medida que se avanza en el horizonte de pronóstico.

CAPÍTULO 5

DESARROLLO DE METODOLOGÍAS DE PONDERACIÓN DE MIEMBROS EN EL MODELO LORENZ 63

5. Desarrollo de metodologías de ponderación de miembros en el modelo Lorenz 63

A los efectos de explorar metodologías de construcción de ensambles ponderados en un modelo más simple que los atmosféricos, en el presente capítulo se recurre al modelo Lorenz 63 con asimilación de datos mediante el método EnKF. Allí se aplican y evalúan técnicas simples de ponderación de los miembros del ensamble según su desempeño reciente, en busca de una mejora de la habilidad de predicción del sistema.

Dicho modelo ha sido ampliamente utilizado en la literatura sobre predictibilidad de la atmósfera y asimilación de datos (Palmer, 1993; Yang et al., 2006; Daron & Stainforth, 2015; Tandeo et al., 2015; Miyoshi & Sun, 2022), ya que resulta de particular interés por su simplicidad, en términos de dimensionalidad y costo computacional, y su comportamiento caótico.

5.1 DESCRIPCIÓN DEL MODELO LORENZ 63

El modelo Lorenz 63 se trata de un modelo simplificado de un sistema dinámico determinista tridimensional no lineal que, para ciertos valores de sus parámetros, exhibe un comportamiento caótico como el de la atmósfera (Lorenz, 1963). El mismo deriva del modelo de Saltzman (1962) para la convección atmosférica, que consiste en un modelo simplificado del movimiento de un fluido en una capa bidimensional calentada uniformemente desde abajo.

Las ecuaciones del modelo son:

$$\frac{dx}{dt} = \sigma(y - x)$$

$$\frac{dy}{dt} = x(r - z) - y$$

$$\frac{dz}{dt} = xy - bz$$

donde $X = (x, y, z)$ es el vector estado del sistema y σ , r y b son los parámetros del modelo (que se asumen constantes).

Los valores particulares de los parámetros elegidos por Lorenz (1963), presentados en la Tabla 5-1, dan como resultado *soluciones caóticas*, es decir, sensiblemente dependientes de las condiciones iniciales (diferencias muy pequeñas se magnifican con el paso del tiempo, alcanzando resultados muy distintos), y desde dicha publicación se han utilizado ampliamente en diversos estudios (Kalnay, 2003).

Tabla 5-1: Valores adoptados para los parámetros del modelo Lorenz 63.

Parámetro	Valor
σ	10
r	28
b	8/3

La solución de una integración en el tiempo del sistema de ecuaciones a partir de una condición inicial dada define una *trayectoria u órbita en el espacio de fase*. Las coordenadas de un punto en el espacio de fase están definidas por los valores simultáneos de las variables independientes del modelo, $x(t), y(t), z(t)$. La dimensión del espacio de fase es igual al número de variables independientes (en este caso tres).

Si se grafican los resultados obtenidos a lo largo del tiempo en el espacio (x,y,z) , se obtiene la siguiente figura (Figura 5-1), que posee una forma de “mariposa” con dos lóbulos (“alas”) bien diferenciados que permiten visualizar el denominado “*atractor de Lorenz*”. Una solución puede comenzar desde un punto alejado, pero eventualmente luego de un tiempo transitorio inicial, permanecerá en una región acotada del espacio de fase, convergiendo hacia el atractor (conjunto de puntos hacia los que tienden una y otra vez las trayectorias del sistema, una vez que el periodo transitorio ha terminado).

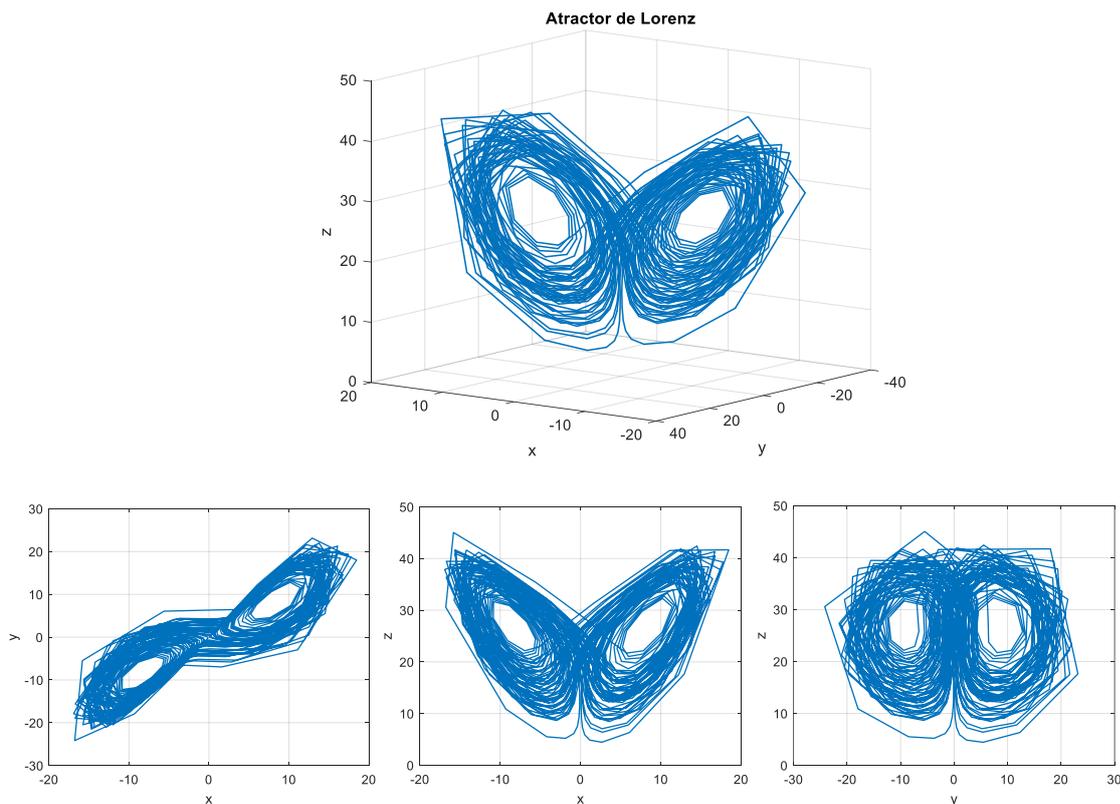


Figura 5-1: Ejemplo de trayectorias en el atractor de Lorenz.

5.1.1 Configuración del experimento

Para las simulaciones se empleó la implementación en Python del modelo de Lorenz 63 de tres dimensiones con asimilación de datos mediante el método de Filtro de Kalman por ensambles determinístico transformado ETKF (Hunt et al., 2007), desarrollada por Juan Ruiz y disponible en https://github.com/gustfrontar/DABA/tree/master/Lorenz_63 (repositorio del “Curso Intensivo de Asimilación de Datos y Teoría de Filtrado” dictado por la Universidad de Buenos Aires en 2019). Dicha implementación integra el modelo con un paso de tiempo de 0,01 utilizando el método de Runge Kutta de cuarto orden.

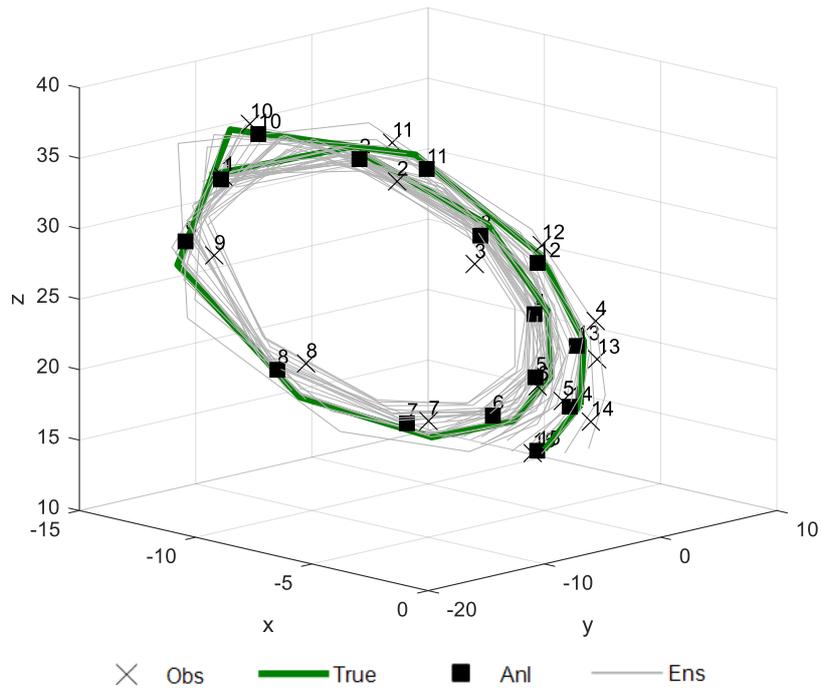
En primer lugar, se integró el modelo de Lorenz partiendo de una condición inicial arbitraria hasta que la solución convergiera al atractor (600 pasos de tiempo). Una vez en esta región, se realizó una simulación por un periodo de 8000 pasos de integración, la cual es empleada como la *evolución real del sistema*. Paralelamente, se inicia un ciclo de asimilación de datos que opera cada 8 pasos de tiempo incorporando *pseudo-observaciones* que se generan como perturbaciones aleatorias de la simulación que se utiliza como verdad (adicionando ruido blanco gaussiano con media nula y varianza 2) y que dan lugar a un *conjunto de análisis*. Se asume que los errores en diferentes observaciones tienen las mismas características y no están correlacionados entre sí. Luego, para generar los *miembros del ensamble*, se introducen pequeñas perturbaciones aleatorias a la condición inicial, adicionando ruido blanco gaussiano. El método de asimilación utilizado es el de ETKF con 20 miembros. La matriz de covarianza de los errores del modelo se asume constante a lo largo de los ciclos de asimilación realizados ($Q = 0,01$). Se adoptó una inflación multiplicativa de 1,01 para la amplitud de las perturbaciones del ensamble. En cada ciclo se genera un ensamble de pronósticos para los siguientes 120 pasos de integración (equivalentes a 15 pasos de asimilación) y se asimilan observaciones para las tres variables del modelo. En total se realizaron 1000 ciclos de asimilación. Considerando la analogía entre las escalas de tiempo del modelo Lorenz 63 y la atmósfera, se señala que un paso temporal de 0,08 es equivalente a una variabilidad de 6 horas en la atmósfera (Kalnay et al., 2007; Tandeo et al., 2015).

En la Tabla 5-2 se resumen las principales características de la configuración adoptada para el experimento y en la Figura 5-2 se presenta, a modo de ejemplo, la evolución a lo largo del horizonte de pronóstico de la simulación que se utiliza como verdad (línea verde), las pseudo-observaciones (cruz negra), el análisis (cuadrado negro) y cada uno de los miembros del ensamble (línea gris) para un ciclo de asimilación en particular ($t_{ini} = 800$).

Tabla 5-2: Configuración del experimento ETKF.

Parámetro	Valor
Paso de tiempo	0,01
Número de ciclos de asimilación	1000
Pasos de spin-up	600
Frecuencia de asimilación	8
Número de miembros del ensamble	20
Horizonte de pronóstico	15
Covarianza del error de las observaciones (R)	2,0
Covarianza del error del modelo (Q)	0,01
Inflación multiplicativa	1,01

(a) Evolución temporal en el espacio de fase 3D ($t_{ini} = 800$)



(b) Evolución temporal 1D ($t_{ini} = 800$)

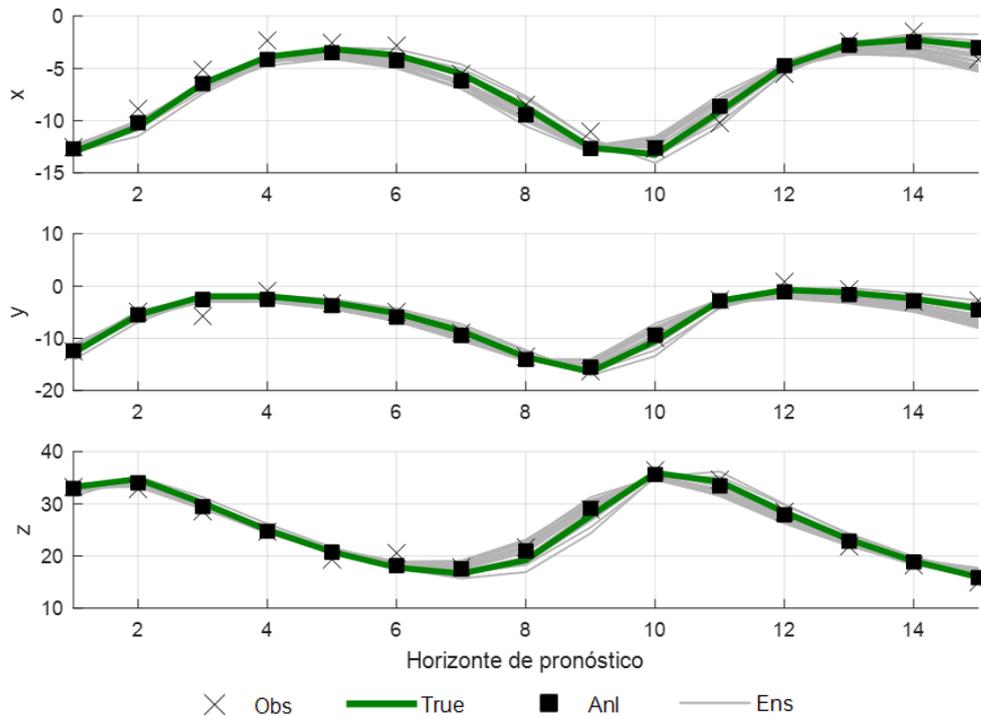


Figura 5-2: Evolución a lo largo del horizonte de pronóstico de la simulación que se utiliza como verdad (línea verde), las pseudo-observaciones (cruz negra), el análisis (cuadrado negro) y cada uno de los miembros del ensemble (línea gris) para un ciclo de asimilación en particular ($t_{ini} = 800$).

5.2 METODOLOGÍA GENERAL

Notación:

En primer lugar, se introduce la notación que será referida a lo largo del presente capítulo:

$X_k^{m,t_{ini}}(t) = (x_k^{m,t_{ini}}, y_k^{m,t_{ini}}, z_k^{m,t_{ini}})$ corresponde al pronóstico en tres dimensiones del miembro m del ensamble ($1 \leq m \leq 20$) para el paso k dentro del horizonte de pronóstico ($1 \leq k \leq 15$) en la simulación iniciada en el tiempo t_{ini} ($1 \leq t_{ini} \leq 1000$), t refiere al paso de tiempo absoluto al que corresponde el pronóstico ($1 \leq t \leq 1000$).

$X_a^m(t)$ corresponde al Análisis perturbado en tres dimensiones del miembro m del ensamble ($1 \leq m \leq 20$) en el tiempo t ($1 \leq t \leq 1000$).

$X^a(t)$ corresponde al Análisis en tres dimensiones en el tiempo t ($1 \leq t \leq 1000$).

En la Figura 5-3 se muestra un ejemplo de trayectorias (1D) para distintos ciclos de pronóstico con la notación correspondiente. En azul, rojo y verde se representan las simulaciones iniciadas en $t-2$, $t-1$ y t respectivamente (asumiendo $t = 500$) y en negro se incluye al Análisis para cada t .

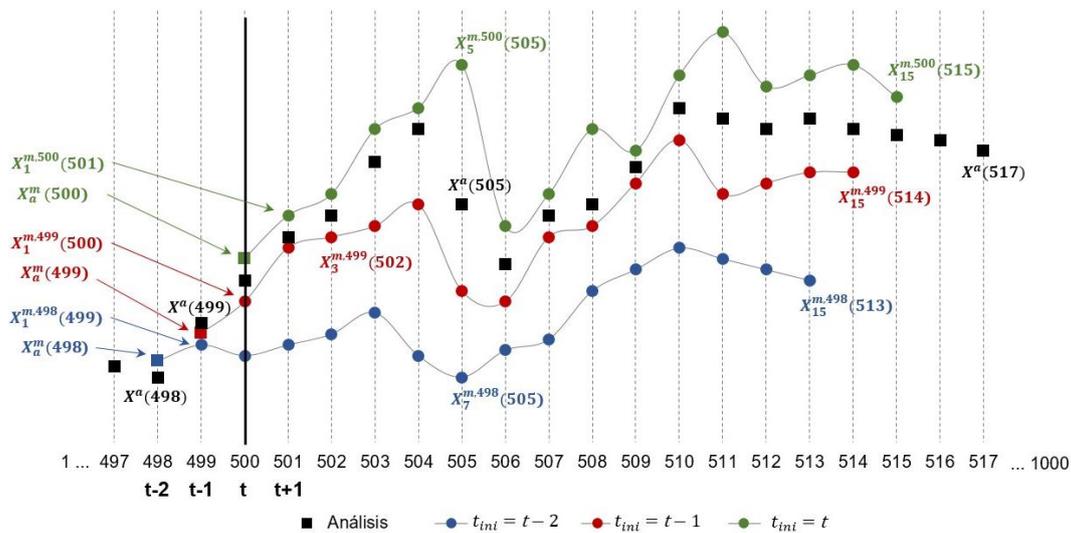


Figura 5-3: Ejemplo de trayectorias (1D) de los distintos ciclos de pronóstico. En azul, rojo y verde se representan las simulaciones inicializadas en $t-2$, $t-1$ y t respectivamente ($t = 500$) y en negro se incluye al Análisis para cada t .

La metodología seguida se divide en cuatro grandes etapas:

1. Caracterización de la evolución del error y la dispersión del ensamble a medida que avanza el horizonte de pronóstico.
2. Desarrollo de metodologías de ponderación de miembros
 - Ponderación de miembros según su habilidad reciente.
 - Aplicación de las metodologías de ponderación a distintos ciclos de pronóstico.

3. Evaluación de las metodologías desarrolladas en comparación a la habilidad de predicción del ensamble completo de la última inicialización disponible (considerado como el “conjunto de referencia”).
4. Análisis de la habilidad de predicción en función de la posición en el atractor de Lorenz.
 - Definición de “momentos clave” en función de la serie temporal de la distancia entre centroides de los sub-ensambles.
 - Valoración de la mejora en la habilidad en función del horizonte de pronóstico y de la posición en el ciclo del atractor de Lorenz.

En todos los casos, la habilidad de los miembros del ensamble se mide respecto del Análisis y no de la verdadera trayectoria del sistema o de las observaciones, ya que en la atmósfera el Análisis es la mejor estimación disponible del estado del sistema en cada paso de tiempo (Peña & Toth, 2014).

5.3 CARACTERIZACIÓN DE LA EVOLUCIÓN DEL ERROR Y LA DISPERSIÓN DEL ENSAMBLE

En primer lugar, se realizó una caracterización de la evolución del error y la dispersión del ensamble a medida que avanza el horizonte de pronóstico, considerando tres dimensiones (x, y, z).

Para cada paso (k) dentro del horizonte de pronóstico, el error (d) se calcula como la distancia euclidiana en tres dimensiones entre el pronóstico ($X_k^f(t)$) y el Análisis correspondiente ($X^a(t)$).

$$d(k) = \sqrt{(X_k^f(t) - X^a(t))^2}$$

Según el caso, el pronóstico puede corresponder a la media del ensamble ($X_k^f = \bar{X}_k^f = \frac{1}{N} \sum_{m=1}^N X_k^{m,tini}$ con $N = 20$ miembros) y representa la “distancia al centroide”; o también puede corresponder a cada uno de los miembros ($X_k^f = X_k^{m,tini}$) y se tienen entonces tantos errores como miembros tiene el ensamble.

La dispersión (σ_{xyz}) se representa como la desviación estándar del ensamble en las tres dimensiones consideradas.

$$\sigma_{xyz}(k) = \sqrt{(\sigma_x^2 + \sigma_y^2 + \sigma_z^2)_k}$$

donde $(\sigma_x^2)_k = \frac{1}{N-1} \sum_{i=1}^N (x_k^{m,tini} - \bar{x}_k^f)^2$, análogamente para $(\sigma_y^2)_k$ y $(\sigma_z^2)_k$.

En la Figura 5-4 se presenta un gráfico de caja (boxplot) con la evolución a lo largo del horizonte de pronóstico para: (a) el error de la media del ensamble, (b) la dispersión del ensamble y (c) la media del error de los miembros del ensamble (valor medio de los 20 miembros). En cada caso, se incluyen los percentiles 25,

50, 75 (cajas) y 10 y 90 (bigotes) en los 1000 ciclos de asimilación. Adicionalmente, en la Figura 5-5 se presentan los diagramas de dispersión (scatterplots) del error de la media del ensamble (eje y) versus la dispersión del ensamble (eje x) en función del horizonte de pronóstico.

En dichas figuras se observa que, como era de esperar, a medida que se avanza en el horizonte de pronóstico, aumenta el error y la dispersión de los miembros del ensamble, es decir que disminuye la habilidad de predicción del sistema.

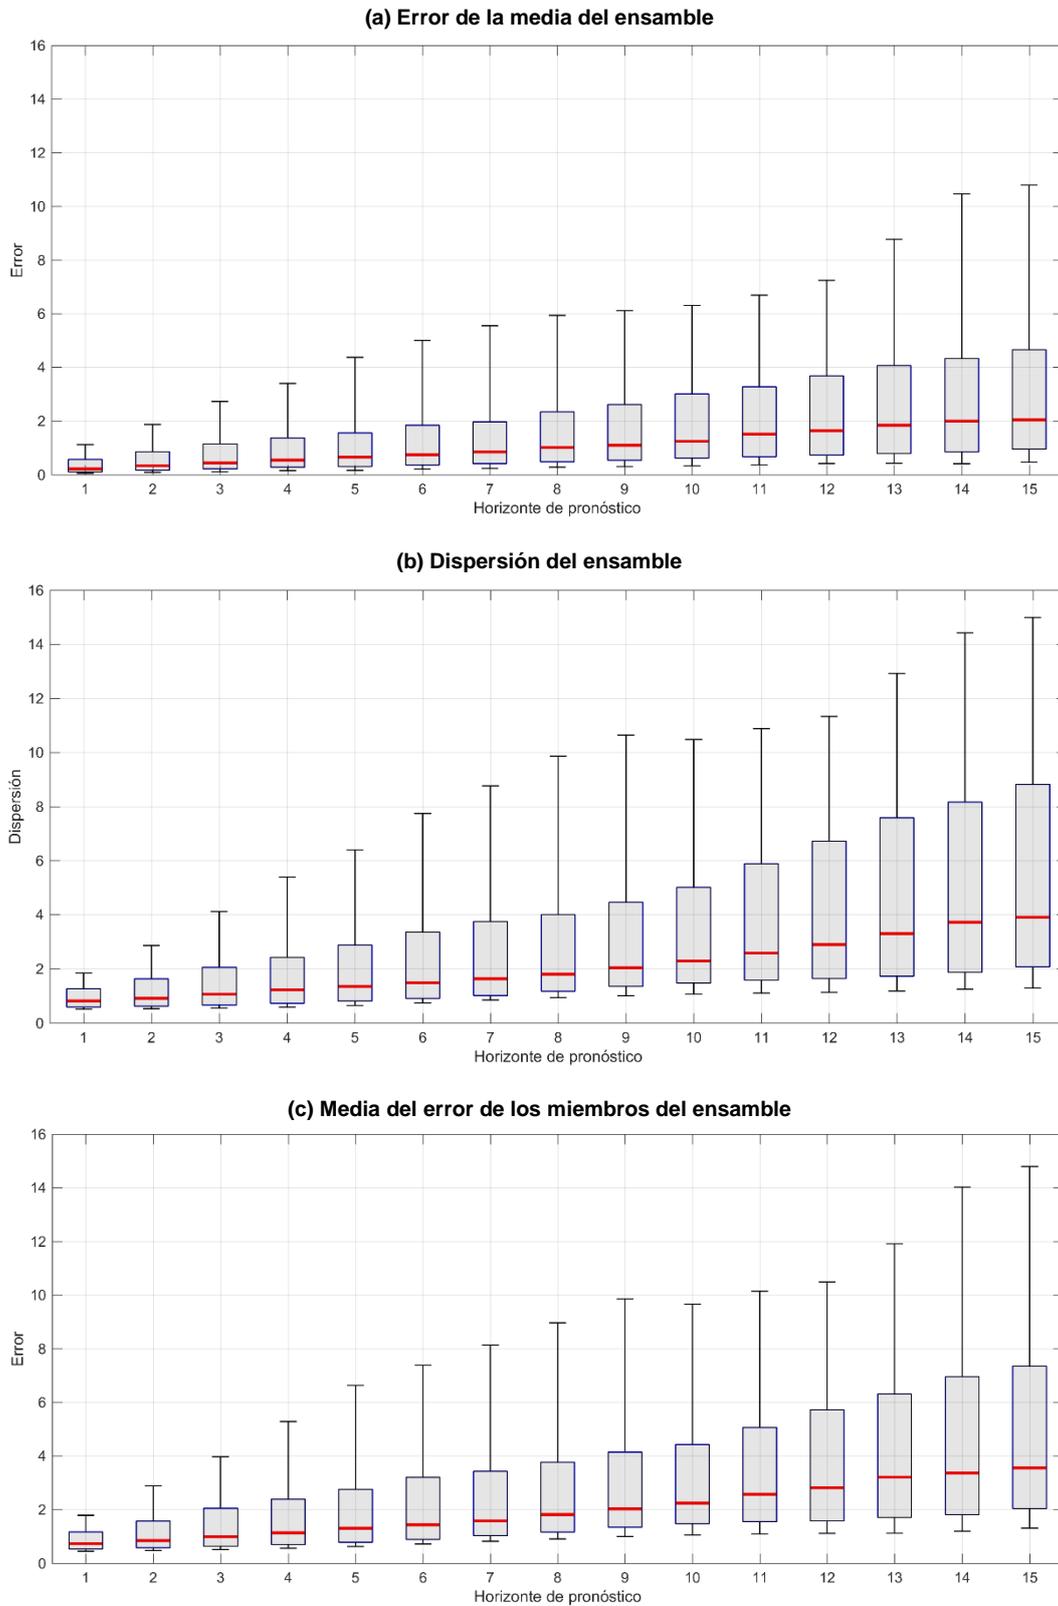


Figura 5-4: Evolución del (a) error de la media del ensemble, (b) dispersión del ensemble, (c) media del error del ensemble a lo largo del horizonte de pronóstico en el modelo Lorenz 63. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

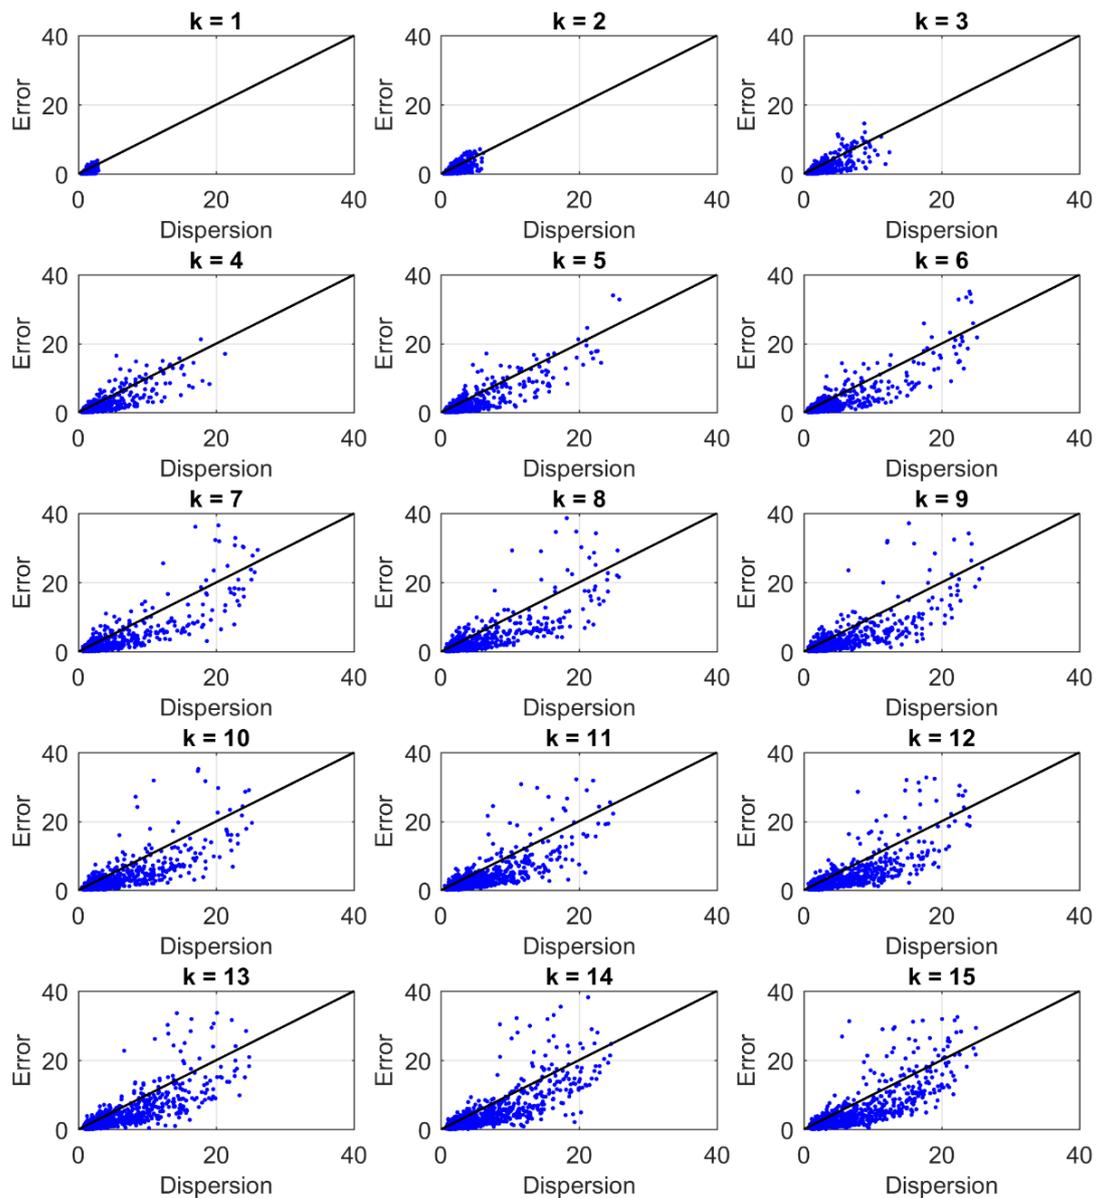


Figura 5-5: Error de la media del ensamble (eje y) versus la dispersión del ensamble (eje x) en función del horizonte de pronóstico para el modelo Lorenz 63.

Luego, con el propósito de analizar la distribución del ensamble desde un enfoque probabilístico, se construyó el histograma de análisis de rangos o diagrama de Talagrand (Talagrand et al., 1997) para cada paso dentro del horizonte de pronóstico. El mismo es un tipo de histograma en el cual las frecuencias mostradas por las barras representan el porcentaje de veces que la observación o el análisis (el dato empleado para la verificación) cae en los rangos o las clases definidas por los miembros del pronóstico por ensambles. La primera clase representa el rango hasta el miembro del ensamble de la clase más baja, mientras que la última clase representa el rango por encima del miembro del ensamble en la clase más alta. Esto significa que hay $N+1$ clases en el diagrama donde N es el número de miembros del ensamble (en este caso, $N = 20$).

La forma del diagrama, permite extraer conclusiones sobre los sesgos del sistema de pronóstico y el alcance de su dispersión. Adicionalmente, puede incluirse en el diagrama la curva (línea horizontal) que representa la frecuencia teórica en cada categoría para un sistema de pronóstico por ensamble perfectamente confiable. Esta frecuencia es $1/(N+1)$. Esto supone que, si el sistema de pronóstico está bien construido, en una muestra grande cada miembro tiene la misma probabilidad de verificarse, es decir, que el esquema de generación crea un rango de miembros igualmente válidos. Cabe destacar que un histograma de rango “plano” no necesariamente indica que el pronóstico tenga habilidad. Sólo mide si la distribución de probabilidad observada está bien representada por el ensamble.

En la Figura 5-6 se presentan los resultados obtenidos para los horizontes de pronóstico $k = 1, 5$ y 10 para cada una de las dimensiones del modelo de Lorenz (x, y, z). Se observa que durante los primeros pasos (paneles superiores) el diagrama tiene “forma de pirámide”, por lo que el ensamble tiene una dispersión excesivamente alta, la observación está demasiado a menudo dentro del rango medio del ensamble. Luego, a medida que avanza el horizonte de pronóstico (paneles inferiores) el ensamble tiende a estar mejor distribuido.

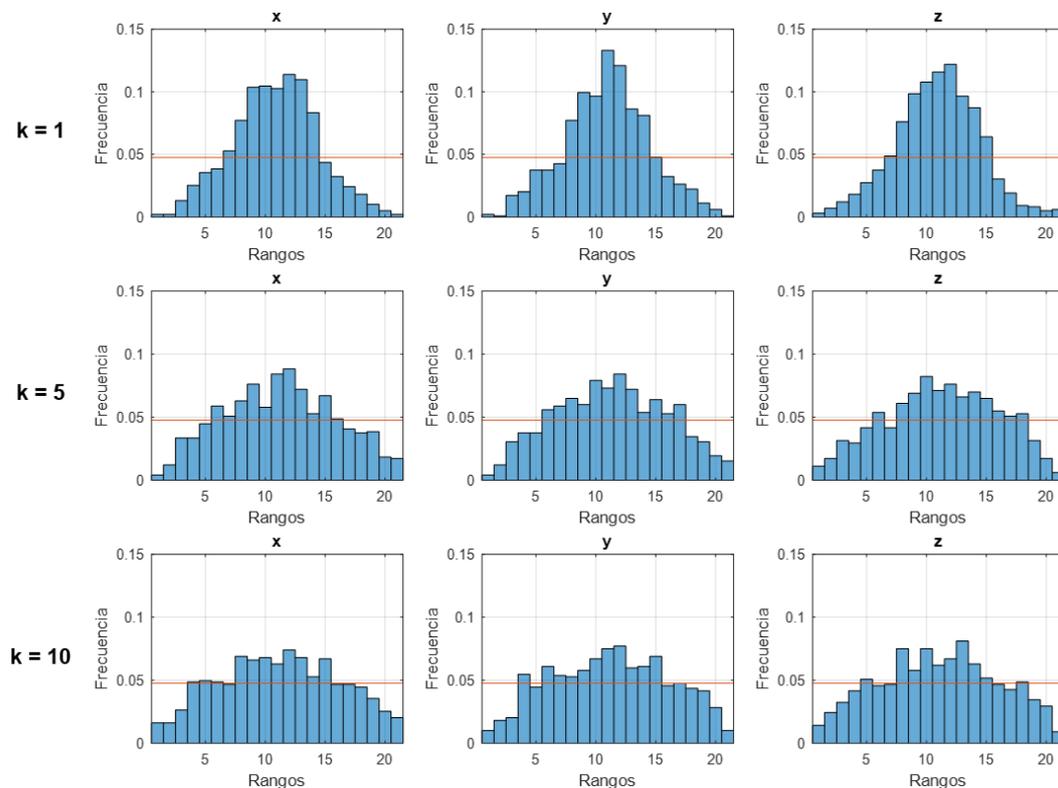


Figura 5-6: Histogramas de análisis de rangos para los horizontes de pronóstico $k = 1, 5$ y 10 en el modelo Lorenz 63. Se presenta un histograma para cada dimensión (x, y, z).

5.4 METODOLOGÍAS DE PONDERACIÓN DE MIEMBROS

5.4.1 Ponderación de miembros

A continuación, se describen las dos metodologías propuestas para la ponderación de los miembros del ensamble según su habilidad reciente, buscando emplear toda la información disponible para mejorar la descripción de la incertidumbre enfrentada.

- Agrupamiento de los distintos miembros del ensamble en dos sub-ensambles mediante la técnica de Cluster Analysis al inicio de cada ciclo de asimilación y determinación del “Mejor”/“Peor” sub-ensamble.
- Construcción de un ensamble no equiprobable asignando la probabilidad o peso de cada miembro según el inverso de la distancia al Análisis (“ensamble pesado”).

5.4.1.1 *Agrupamiento de los miembros: “Mejor” sub-ensamble*

Para cada ciclo de asimilación (t), los distintos miembros del ensamble se agrupan en dos sub-ensambles mediante el método de k-means (Wilks, 2011) con distancia euclidiana en tres dimensiones, considerando el primer paso de pronóstico ($k = 1$) de la simulación iniciada en $t-1$ ($X_1^{m,t-1}(t)$).

Para ello, se incluye al Análisis ($X_a(t)$) como un “miembro” más del ensamble ($N = 20+1$) y se lo agrupa en dos clusters ($K = 2$, $D = 3$). Al cluster que contiene al Análisis se lo clasifica como el “mejor” sub-ensamble. Una vez conformados los dos subconjuntos, se calcula la distancia entre sus centroides (dC).

Para el agrupamiento se considera la penúltima inicialización ($t_{ini} = t-1$) pues en un escenario operativo se supone que el Análisis en $t+1$ no está aún disponible.

En la Figura 5-7 se muestra una representación esquemática del procedimiento de cálculo.

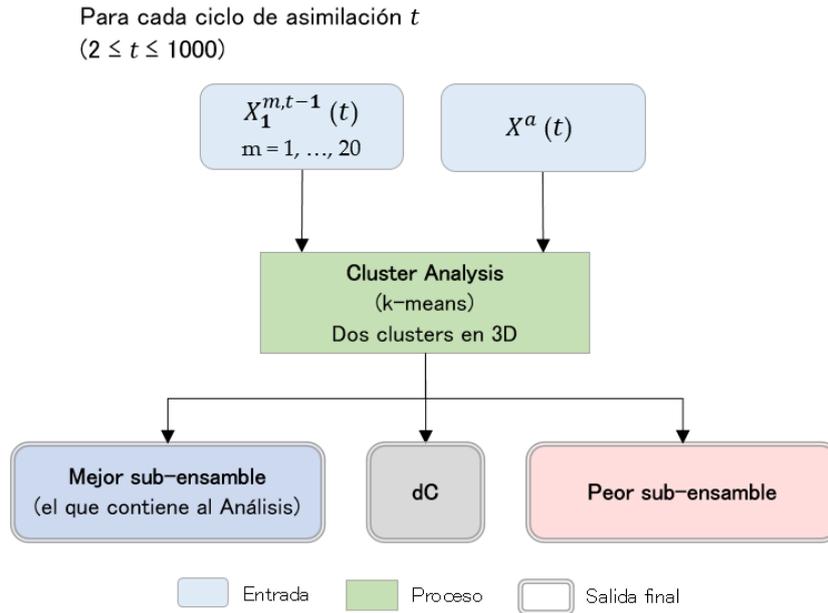


Figura 5-7: Representación esquemática del análisis de clusters en 3D según el primer paso ($k = 1$) de cada ciclo de pronóstico considerando la penúltima inicialización disponible ($t_{ini} = t - 1$).

Como una primera exploración de la conformación de los sub-ensambles, en la Figura 5-8 se presenta la distribución del número de miembros del cluster más grande (con mayor cantidad de miembros) para todos los ciclos de pronóstico disponibles.

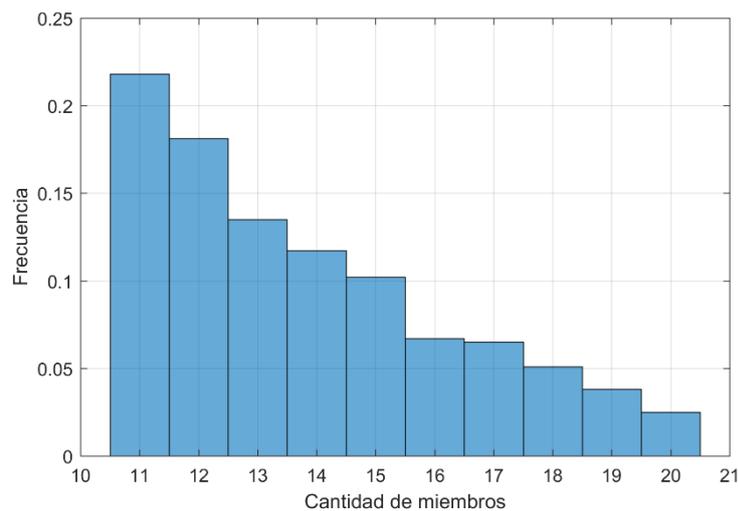


Figura 5-8: Distribución del número de miembros del cluster más grande (con mayor cantidad de miembros) para todos los ciclos de pronóstico disponibles.

Se observa que en más del 50% de los ciclos el sub-ensamble más grande tiene entre 11 y 13 miembros (la distribución de los miembros en los dos subconjuntos es equilibrada); solamente en el 11% de los casos se tienen clusters con 18 o más miembros. En particular, interesa destacar que en ningún caso el “mejor” sub-

ensamble está conformado únicamente por el Análisis, dicho cluster tiene como mínimo tres miembros (2 miembros + Análisis).

En la Figura 5-9 se presenta la serie temporal resultante de la distancia entre el par de centroides para cada inicio de ciclo de pronóstico, una medida particular de la dispersión inicial del ensamble en cada ciclo. El aspecto más notorio de dicha serie temporal es su periodicidad que, como se verá más adelante, está relacionado con la posición relativa de la condición inicial para dicho ciclo de pronóstico respecto al atractor de Lorenz.

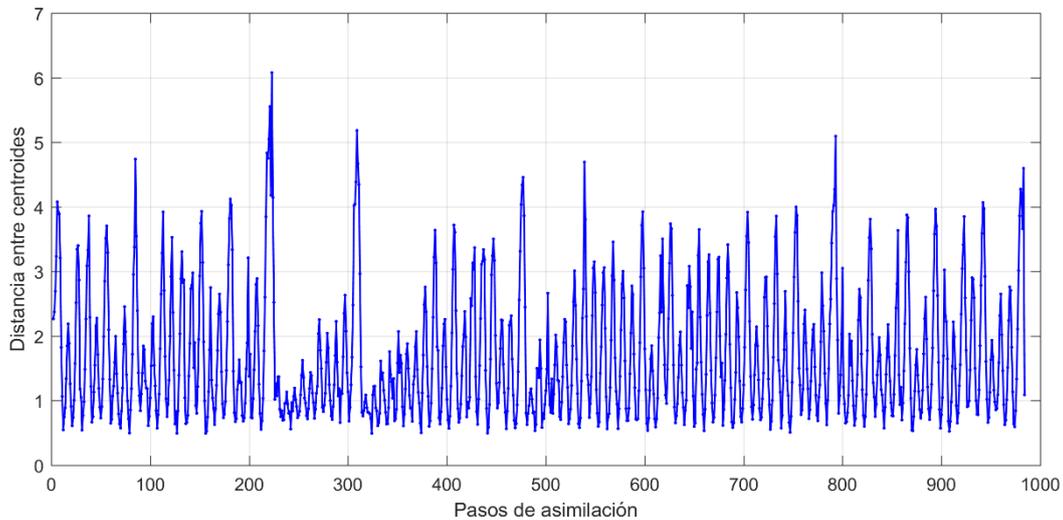


Figura 5-9: Serie temporal de la distancia entre centroides de los dos sub-ensambles obtenidos al inicio de cada paso de asimilación mediante el método de k-means para el modelo de Lorenz 63.

5.4.1.2 *Ensamble no equiprobable*

La segunda metodología propuesta consiste en la construcción de un ensamble no equiprobable (“pesado”) asignando probabilidades o pesos diferenciales a los distintos miembros del ensamble según su habilidad reciente. Esta metodología está inspirada en el trabajo propuesto por Raftery et al. (2005), basado en el “Bayesian Model Averaging (BMA)”.

En particular, para cada ciclo de asimilación (t), el peso de cada miembro ($w^m(t)$) se define como el inverso de su distancia al Análisis en tres dimensiones, considerando el primer paso de pronóstico de la simulación iniciada en $t-1$.

$$w^m(t) = \left(\sqrt{(X_1^{m,t-1}(t) - X^a(t))^2} \right)^{-1}$$

Una vez determinado el peso de cada miembro del ensamble, se lo normaliza ($w_{norm}^m(t)$) dividiendo entre la sumatoria del peso de todos los miembros para dicho ciclo (t).

$$w_{norm}^m(t) = \frac{w^m(t)}{\frac{1}{N} \sum_{m=1}^N w^m(t)}$$

Los pesos así definidos pueden interpretarse como probabilidades, en el sentido de que se entiende que el miembro más cercano al Análisis es más representativo de la trayectoria del sistema y, por tanto, se la asocia una mayor probabilidad (los miembros del ensamble dejan de ser equiprobables).

En este caso, tanto la media del ensamble como el error y la dispersión del mismo, se calculan como el promedio ponderado de los miembros o el valor esperado del ensamble no equiprobable.

5.4.2 Aplicación a distintos ciclos de pronóstico

Las metodologías de selección de sub-ensambles desarrolladas previamente se aplican a distintos ciclos de pronóstico bajo dos esquemas, que dependen de las características del sistema de asimilación:

- Esquema de “time lagged-ensemble”
- Esquema con cambio de ciclo

En sistemas de asimilación que “pierden la memoria” entre distintas inicializaciones (por ejemplo: vectores singulares, EnKF estocásticos) es válido únicamente el esquema de “time lagged-ensemble”.

5.4.2.1 “Time lagged-ensemble”

Bajo el esquema de “time lagged-ensemble” (Hoffman & Kalnay, 1983; Du et al., 2018) se considera, para cada inicialización t , el pronóstico inicializado en el ciclo anterior ($t-1$), para el cual se definieron los clusters y pesos según su primer paso ($k = 1$). Si bien se comparan pronósticos inicializados en diferentes momentos ($X_{k+1}^{m,t-1}(t+k)$ versus $X_k^{m,t}(t+k)$), en ambos casos se usa el Análisis más reciente ($X_a(t)$): para la selección de clusters o pesos en el primer caso, y para una nueva inicialización en el segundo.

5.4.2.2 Cambio de ciclo de asimilación

Cuando el sistema de asimilación conserva la “memoria/familiaridad” entre los miembros del ensamble de un ciclo al siguiente (por ejemplo: vectores criados, EnKF determinísticos), es válido considerar los clusters y pesos definidos según el primer paso del penúltimo pronóstico (inicializado en $t-1$), pero aplicados al último pronóstico disponible (inicializado en t).

En este caso es pertinente analizar la evolución de los miembros en cada sub-ensamble entre los distintos ciclos de pronóstico. Para ello, se definió un *indicador global de la medida de la persistencia* entre ciclos de asimilación. El mismo surge de comparar uno contra uno todos los miembros del ensamble al inicio de cada ciclo

y evaluar si entre dos ciclos consecutivos permanecen en el mismo cluster. Si dos miembros están en el mismo cluster en el tiempo t_1 y t_2 , el indicador vale 1, en caso contrario vale -1. Luego, en cada ciclo de asimilación, se promedian los valores obtenidos para todos los pares de miembros. De esta manera, el indicador varía entre -1 y 1 (persistencia perfecta).

En la Figura 5-10 se presenta la serie temporal para el indicador así obtenido, junto con su distribución (boxplot) incluyendo los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes). Se observa que, si bien se tiene un indicador promedio de 0.56, la persistencia de los sub-ensambles entre ciclos consecutivos es muy variable alcanzando incluso valores negativos (con un mínimo de -0.05), ya que depende del estado del sistema en cada ciclo particular de pronóstico.

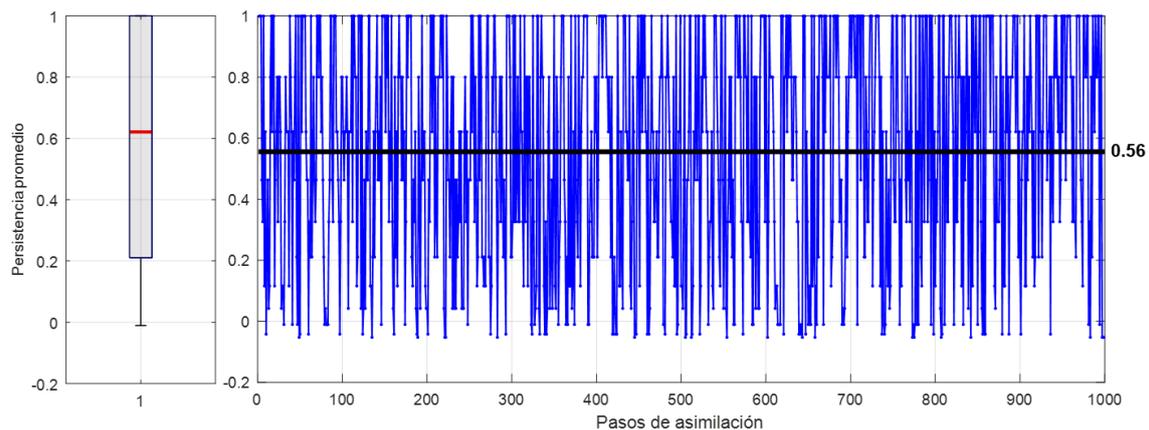


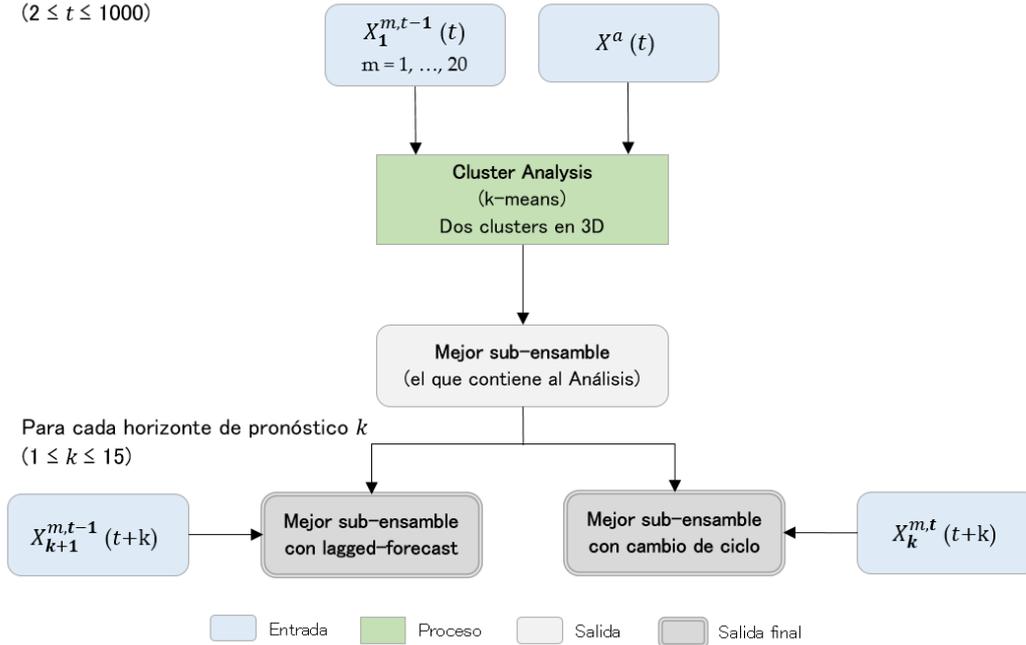
Figura 5-10: Distribución y serie temporal del indicador de la medida de la persistencia de los sub-ensambles entre ciclos consecutivos de asimilación para el modelo Lorenz 63. En el gráfico de cajas se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

5.4.3 Síntesis

A modo de síntesis, en la siguiente figura se presentan los diagramas de flujo con los pasos seguidos y la información considerada en cada metodología para la selección/ponderación de los miembros del ensamble según su habilidad reciente.

Selección de miembros: "Mejor" sub-ensamble

Para cada ciclo de asimilación t
($2 \leq t \leq 1000$)



Selección de miembros: Ensamble pesado

Para cada ciclo de asimilación t
($2 \leq t \leq 1000$)

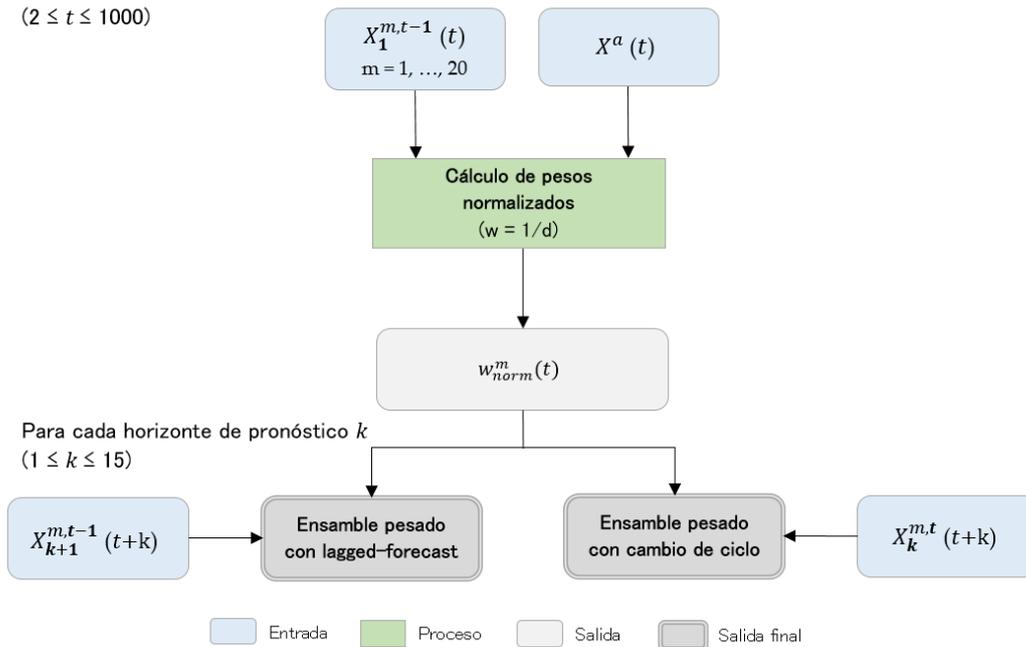


Figura 5-11: Diagramas de flujo con los pasos seguidos y la información considerada en cada metodología para la selección/ponderación de los miembros del ensamble según su habilidad reciente.

5.5 EVALUACIÓN DE LAS METODOLOGÍAS DESARROLLADAS

En esta sección se presenta la evaluación de las metodologías desarrolladas en comparación a la habilidad de predicción del ensamble completo de la última inicialización disponible (considerado como el “conjunto de referencia”).

En la Figura 5-12 se presenta un gráfico de caja con la evolución a lo largo del horizonte de pronóstico de (a) el error de la media del conjunto, (b) la dispersión del conjunto y (c) la media del error de los miembros del conjunto para: todo el ensamble (gris), el “mejor” sub-ensamble con cambio de ciclo (celeste), el “mejor” sub-ensamble con lagged-forecast (azul), el ensamble pesado con cambio de ciclo (verde claro) y el ensamble pesado con lagged-forecast (verde oscuro). Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes). Cabe destacar que se presenta la evolución a lo largo del horizonte de pronóstico hasta el paso de tiempo $t+10$ ($k = 10$), dado que en general en el modelo de Lorenz 63 y con el paso temporal considerado (0.01), en 10 pasos se completa un ciclo en el “ala” del atractor.

Adicionalmente, para facilitar la comparación entre las metodologías y el conjunto de referencia, en la Figura 5-13 se presenta la evolución de la mediana de los 1000 ciclos (línea roja en los boxplots anteriores) para (a) el error de la media y (b) la dispersión de cada conjunto.

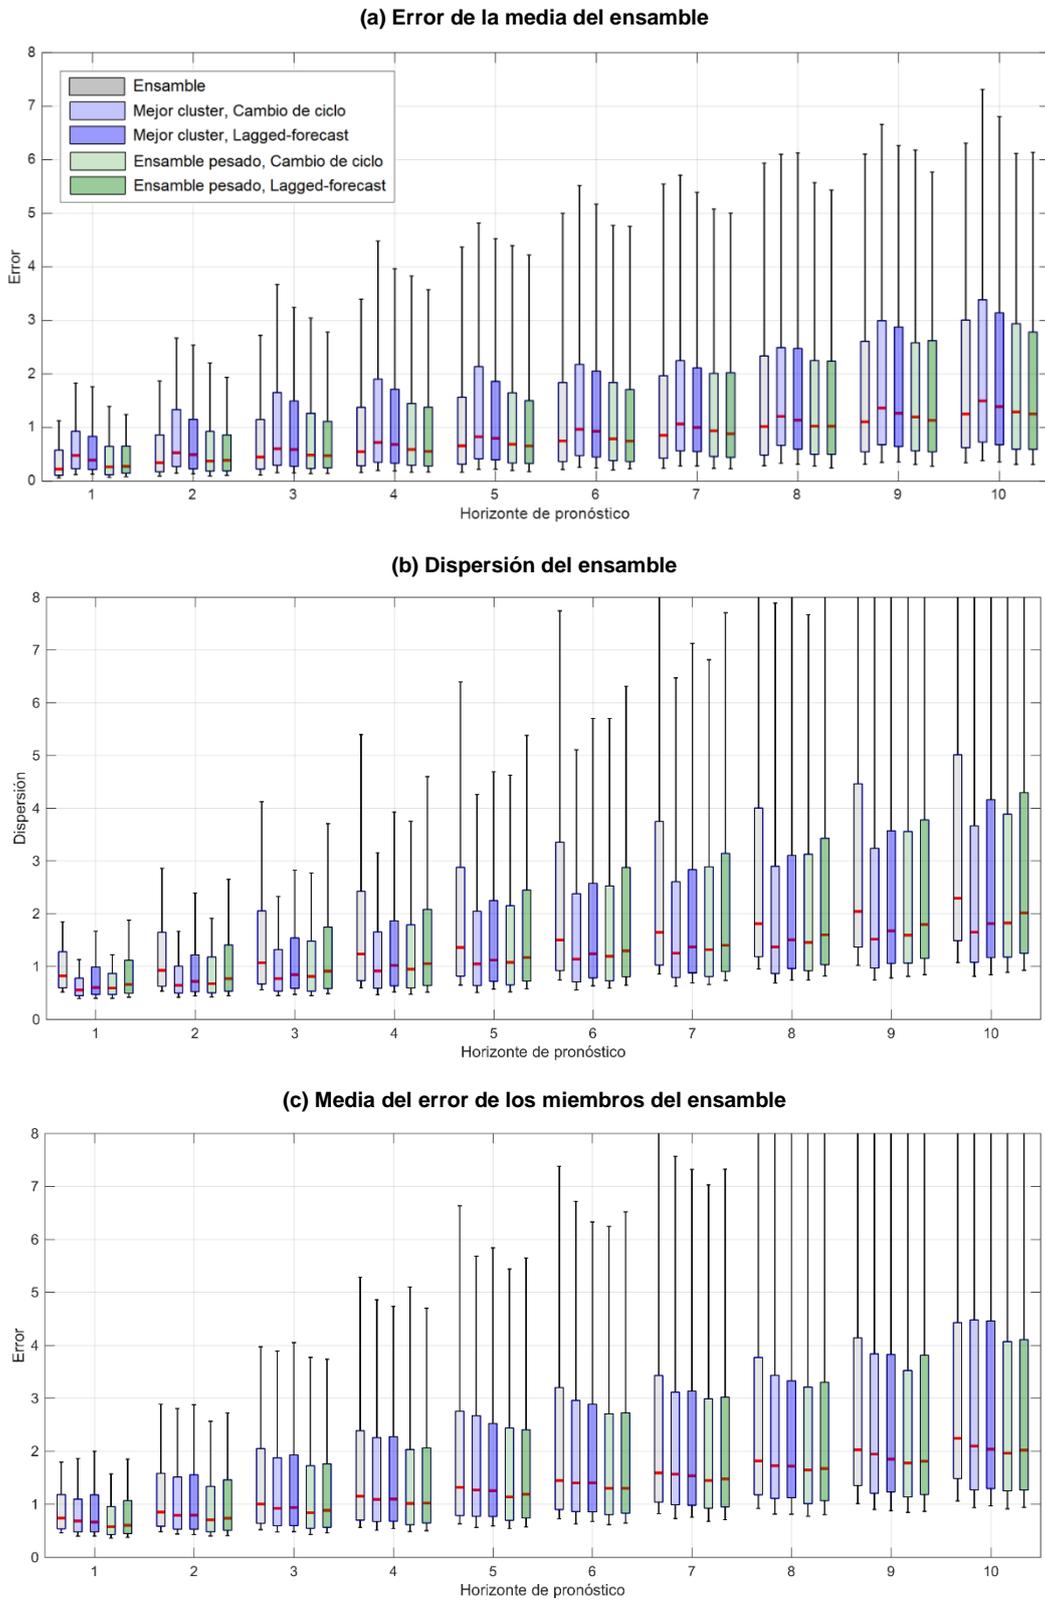


Figura 5-12: Evolución a lo largo del horizonte de pronóstico de (a) el error de la media, (b) la dispersión y (c) la media del error de cada conjunto (ensemble, “mejor” sub-ensemble con cambio de ciclo, “mejor” sub-ensemble con lagged-forecast, ensemble pesado con cambio de ciclo y ensemble pesado con lagged-forecast) para el modelo Lorenz 63. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

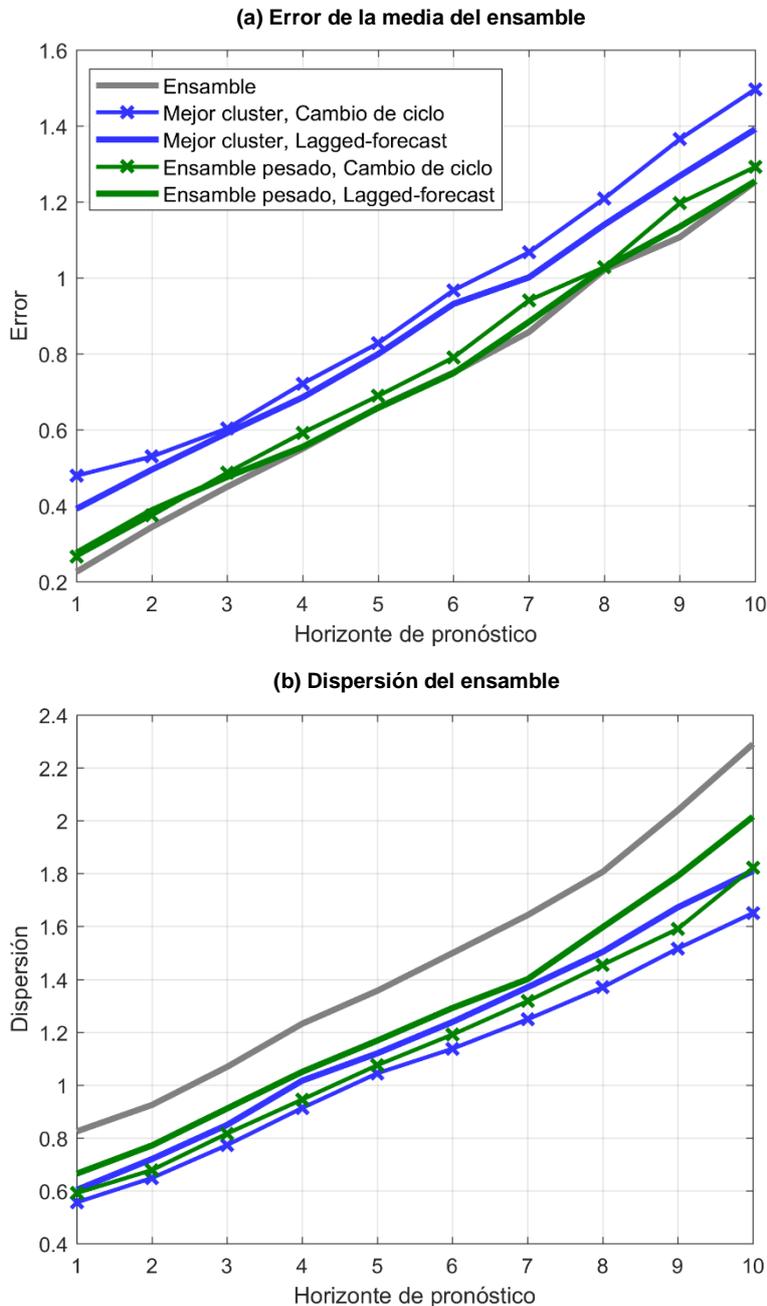


Figura 5-13: Evolución a lo largo del horizonte de pronóstico de la mediana de (a) el error de la media y (b) la dispersión de cada conjunto (ensamble, “mejor” sub-ensamble con cambio de ciclo, “mejor” sub-ensamble con lagged-forecast, ensamble pesado con cambio de ciclo y ensamble pesado con lagged-forecast) para el modelo Lorenz 63.

Se observa que, para todos los horizontes considerados, el error de la media de los ensambles modificados según las metodologías propuestas es mayor o igual al de la media de todo el ensamble (conjunto de referencia). Sin embargo, sí se verifica que la dispersión de los primeros es siempre menor que la del conjunto de referencia. Esto se refleja en la media del error de los miembros del ensamble, que se reduce al considerar los ensambles modificados. En particular, la metodología de selección/ponderación de miembros mediante la construcción de

un ensemble pesado presenta un mejor desempeño que la del agrupamiento en el “mejor” sub-ensemble.

En la siguiente figura se presentan los histogramas de análisis de rangos para todo el ensemble y el “mejor” sub-ensemble con cambio de ciclo y lagged-forecast para los horizontes de pronóstico $k = 1, 5$ y 10 para la dimensión x del modelo de Lorenz (los resultados obtenidos para las otras dos dimensiones son equivalentes). Dado que los ensambles evaluados están conformados por un número diferente de miembros (que conducen a un número diferente de rangos), para la comparación entre metodologías se remuestraron todos los rangos considerando un total de 10 intervalos en cada caso.

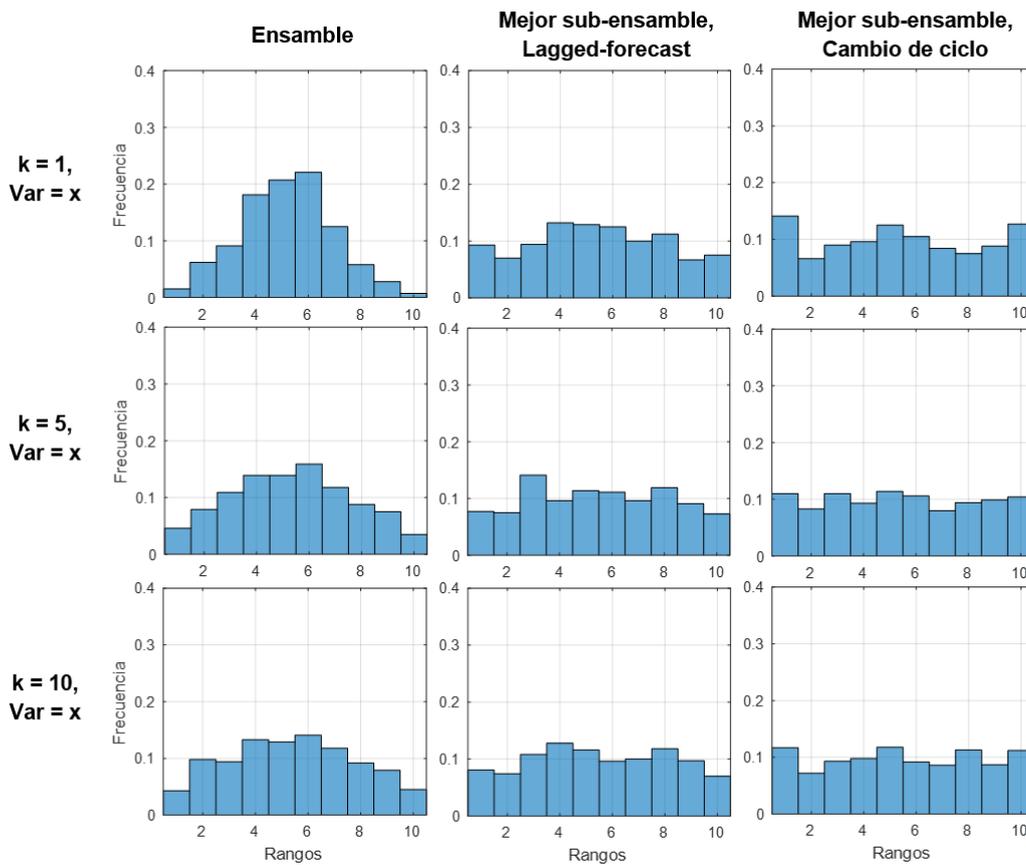


Figura 5-14: Histogramas de análisis de rangos para todo el ensemble y el “mejor” sub-ensemble con cambio de ciclo y lagged-forecast para los horizontes de pronóstico $k = 1, 5$ y 10 para la dimensión x del modelo de Lorenz.

Análogamente, en la Figura 5-15 se presentan los resultados obtenidos para el ensemble pesado con cambio de ciclo y lagged-forecast. En este caso, dado que los miembros del ensemble no son equiprobables, en lugar de los rangos se grafican los deciles de probabilidad.

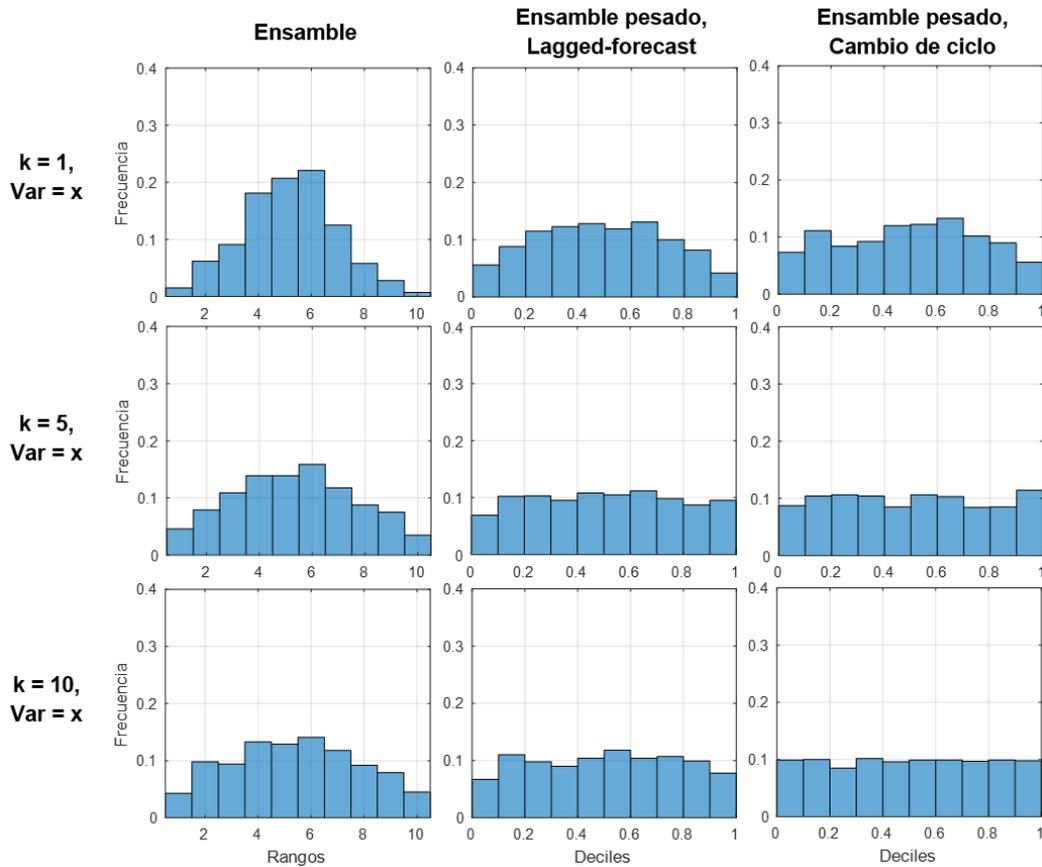


Figura 5-15: Histogramas de análisis de rangos para todo el ensamble y el ensamble pesado con cambio de ciclo y lagged-forecast para los horizontes de pronóstico $k = 1, 5$ y 10 para la dimensión x del modelo de Lorenz.

En ambos casos se observa que, con las metodologías desarrolladas para la selección/ponderación de miembros en base al desempeño en el período inmediato anterior, se reduce la dispersión excesivamente alta identificada previamente para el ensamble de referencia (Sección 5.3), sobre todo en los primeros horizontes de pronóstico (paneles superiores).

5.6 ANÁLISIS EN FUNCIÓN DE LA POSICIÓN EN EL ATRACTOR DE LORENZ

Teniendo en cuenta que la persistencia de los sub-ensambles y la predictibilidad del sistema dependen del estado inicial del mismo en cada paso de pronóstico (en este caso, la posición inicial), se realizó un análisis de la habilidad condicionado a la posición en el espacio (x,y,z) .

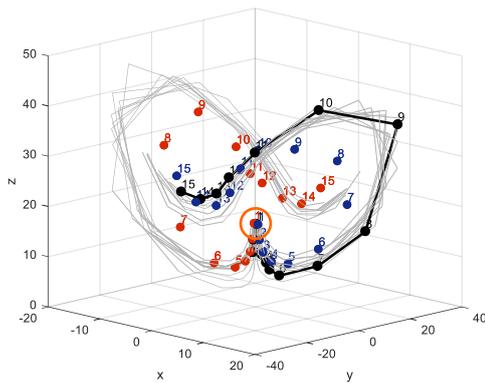
Para ello, se definieron cuatro “*momentos clave*”, en función de las derivadas primera y segunda de la serie de la distancia entre centroides de los sub-ensambles (Figura 5-9), para luego estudiar cómo es la habilidad de predicción en esos subconjuntos de casos.

- **Momentos A:** Corresponden a los puntos siguientes a los mínimos relativos, se definen como las posiciones con derivada primera en $t-1$ negativa y en t positiva.
- **Momentos B:** Corresponden a los puntos de inflexión en el sector creciente de la distancia entre clusters, se definen como las posiciones con derivada segunda en $t-1$ positiva y en t negativa y derivada primera en t positiva.
- **Momentos C:** Corresponden a los puntos siguientes a los máximos relativos, se definen como las posiciones con derivada primera en $t-1$ positiva y en t negativa.
- **Momentos D:** Corresponden a los puntos de inflexión en el sector decreciente de la distancia entre clusters, se definen como las posiciones con derivada segunda en $t-1$ negativa y en t positiva y derivada primera en t negativa.

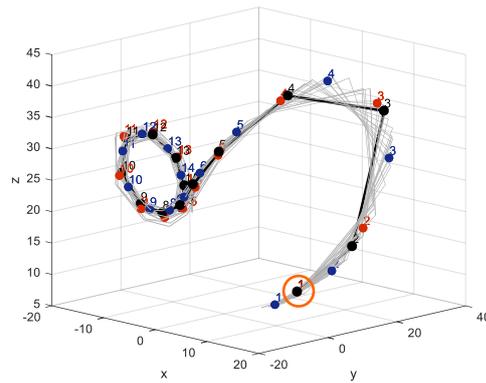
En todos los casos se buscó que la definición de estos “momentos” no requiera información del futuro y por tanto se pueda implementar operativamente, para lo cual en el cálculo de las derivadas se empleó una aproximación no centrada de primer orden BDS (“Backward Difference Scheme”).

A modo de ejemplo, en la Figura 5-16 se presentan las trayectorias (x , y , z) en el modelo de Lorenz 63 iniciadas en cada uno de los momentos clave definidos anteriormente para el Análisis (negro), cada uno de los miembros del ensamble (gris), el centroide del mejor (azul) y peor (rojo) sub-ensamble. Para cada momento del ejemplo seleccionado se indica a qué ciclo de asimilación (t_{ini}) pertenece. Se observa que el “momento A” corresponde a una posición en el cuerpo de la mariposa del atractor de Lorenz (luego de la convergencia), el “momento B” a una posición entrando a una de las alas (luego de la divergencia), el “momento C” se encuentra en una de las alas del atractor y el “momento D” corresponde a una posición saliendo de una de las alas (previa a la convergencia).

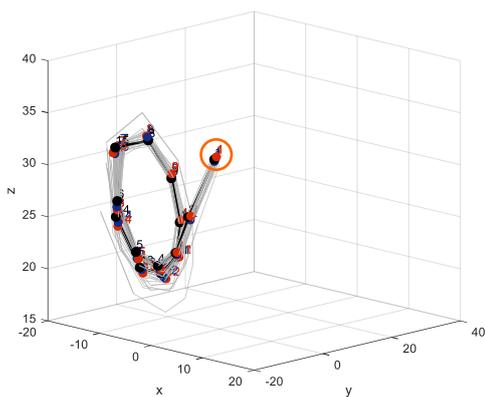
Momento A ($t_{ini} = 470$)



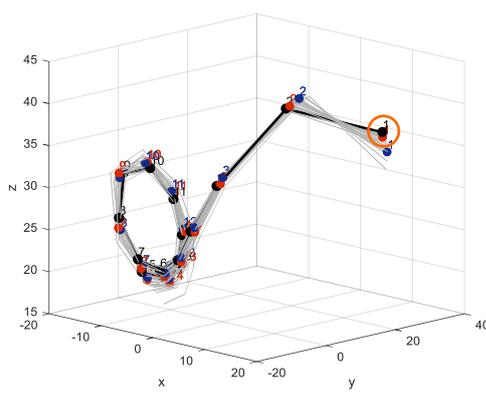
Momento B ($t_{ini} = 476$)



Momento D ($t_{ini} = 480$)



Momento C ($t_{ini} = 478$)



—●— Analysis ● Best Cluster ● Worst Cluster

Figura 5-16: Ejemplos de trayectorias (x, y, z) en el modelo de Lorenz 63 iniciadas en cada uno de los “momentos clave” definidos (A, B, C, D) para el Análisis (negro), cada uno de los miembros del ensamble (gris), el centroide del mejor (azul) y peor (rojo) sub-ensamble.

Según Slingo & Palmer (2011) y Evans et al. (2004), es de esperar que una vez que el sistema entra en una de las alas se vuelva más predecible. En cambio, cuando el sistema se encuentra en el cuerpo de la mariposa (previo a la divergencia), la predictibilidad de las trayectorias decae (ver Figura 5-17).

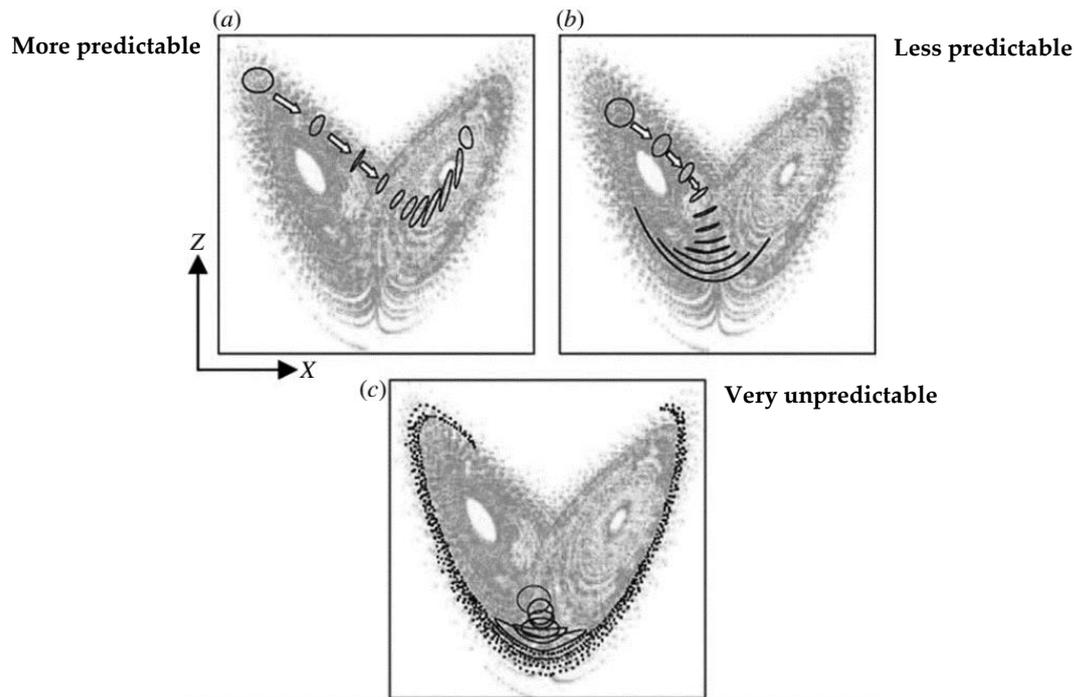


Figure 1. Examples of finite-time error growth on the Lorenz attractor for three probabilistic predictions starting from different points on the attractor. (a) High predictability and therefore a high level of confidence in the transition to a different ‘weather’ regime. (b) A high level of predictability in the near term but then increasing uncertainty later in the forecast with a modest probability of a transition to a different ‘weather’ regime. (c) A forecast starting near the transition point between regimes is highly uncertain.

Figura 5-17: Ejemplo de posiciones en el atractor de Lorenz con distinta predictibilidad.
Fuente: Slingo and Palmer (2011).

Se procedió entonces a la evaluación de la habilidad de predicción de las metodologías desarrolladas teniendo en consideración el estado inicial (posición) del sistema en cada ciclo. Para ello, únicamente se consideró a la metodología del ensamble no equiprobable o “pesado” por haber presentado un mejor desempeño que la de selección del “mejor” sub-ensamble.

En este sentido, en la Figura 5-18 se presenta un gráfico de caja para cada “momento clave” (A, B, C, D) con la comparación en el error de la media entre todo el ensamble (en gris, igual en todos los paneles), el ensamble pesado con cambio de ciclo (en color claro) y con lagged-forecast (en color oscuro) submuestreando los momentos. Se incluyen los percentiles 25, 50, 75 (cajas) y 10 y 90 (bigotes).

Análogamente, en las Figura 5-19 y 4-20 se presentan los gráficos de caja con la evolución a lo largo del horizonte de pronóstico de la dispersión y la media del error del ensamble respectivamente, submuestreando cada “momento clave”.

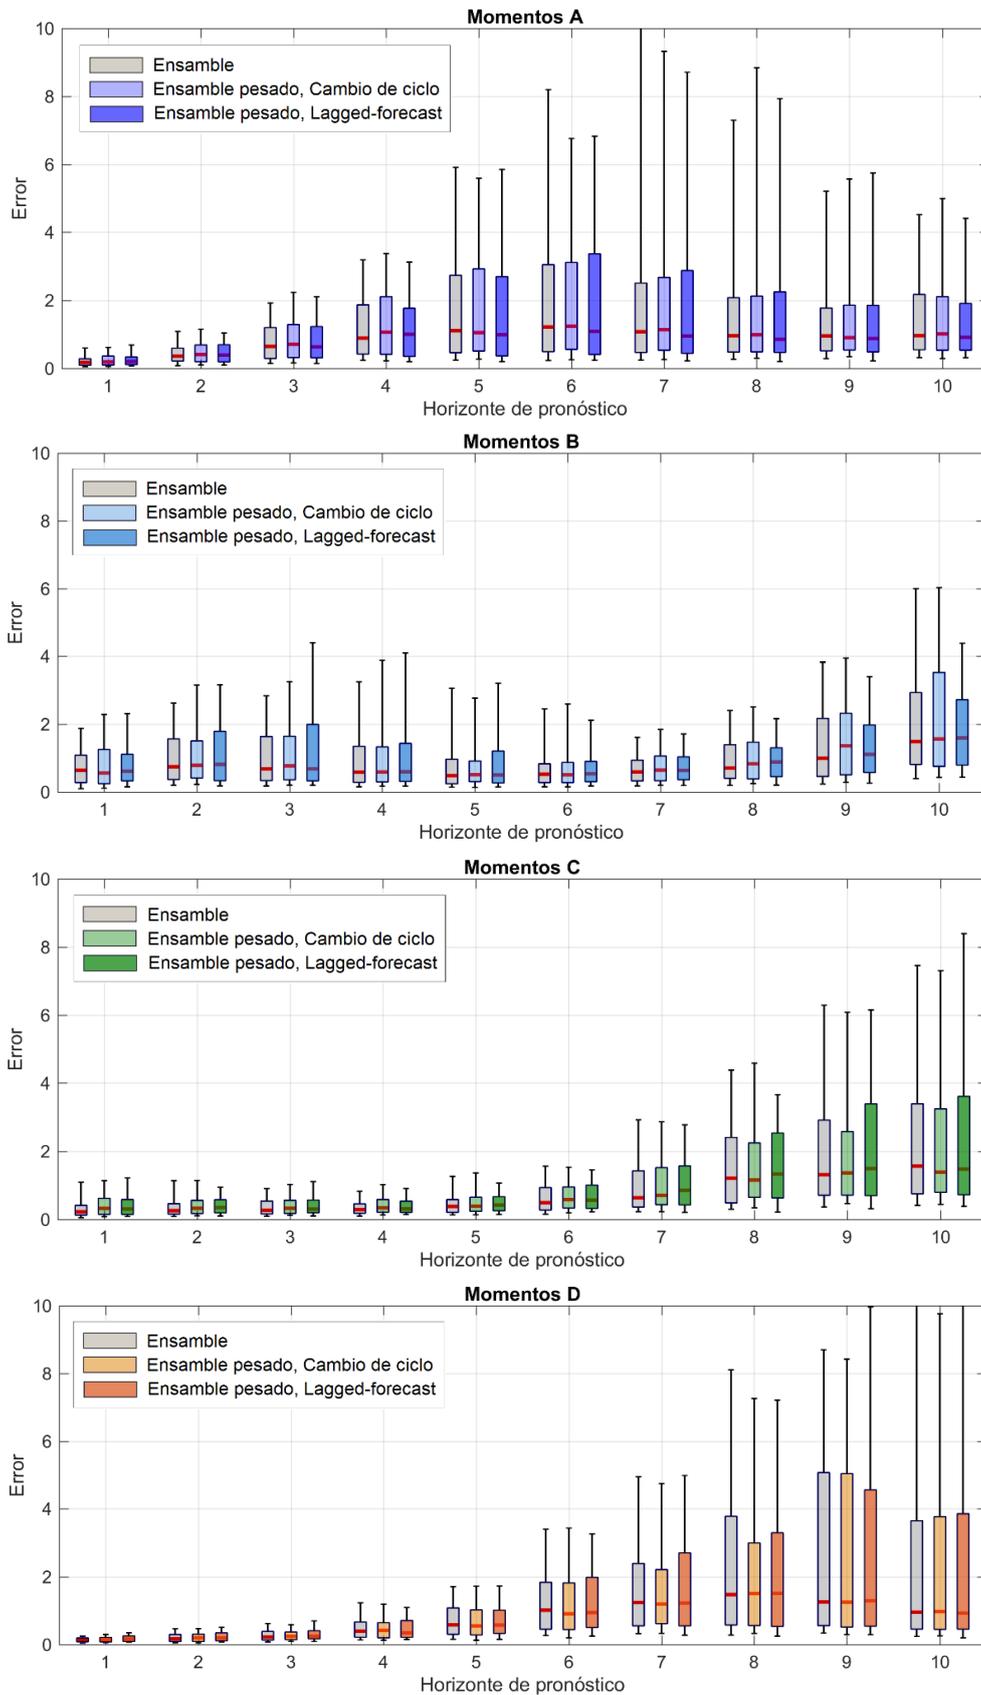


Figura 5-18: Comparación de la evolución a lo largo del horizonte de pronóstico del error de la media entre todo el ensamble, el ensamble pesado con cambio de ciclo y con lagged-forecast submuestreando los “momentos clave”.

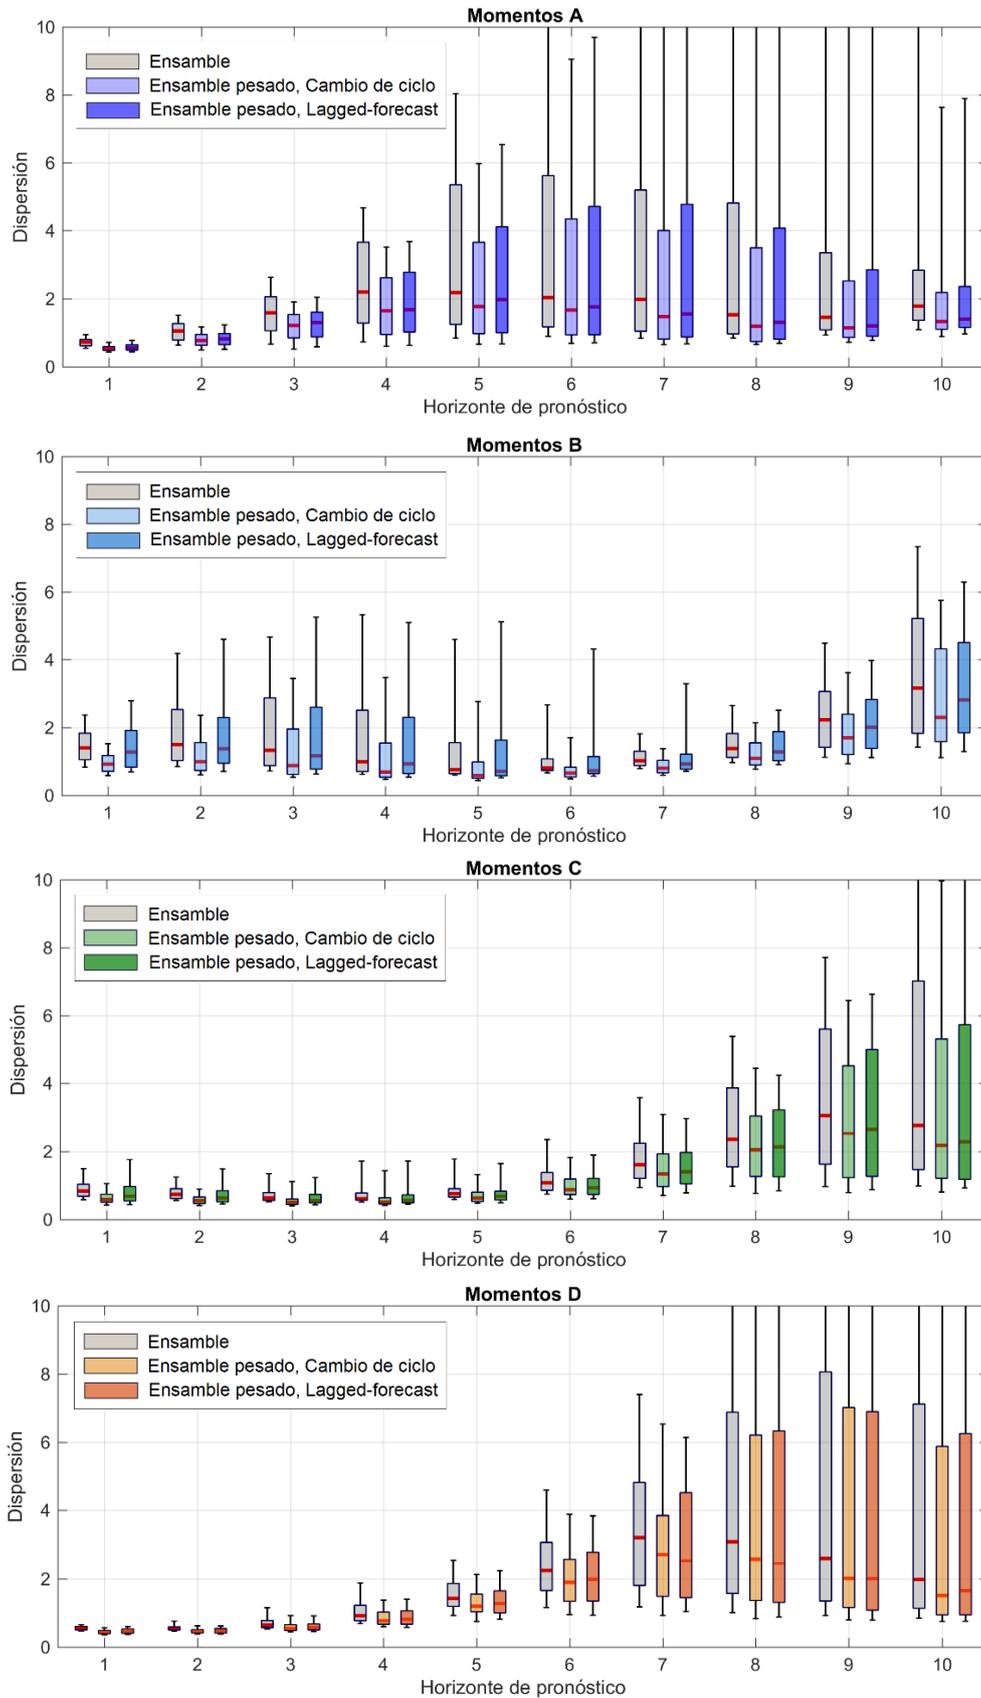


Figura 5-19: Comparación de la evolución a lo largo del horizonte de pronóstico de la dispersión entre todo el ensamble, el ensamble pesado con cambio de ciclo y con lagged-forecast submuestreando los “momentos clave”.

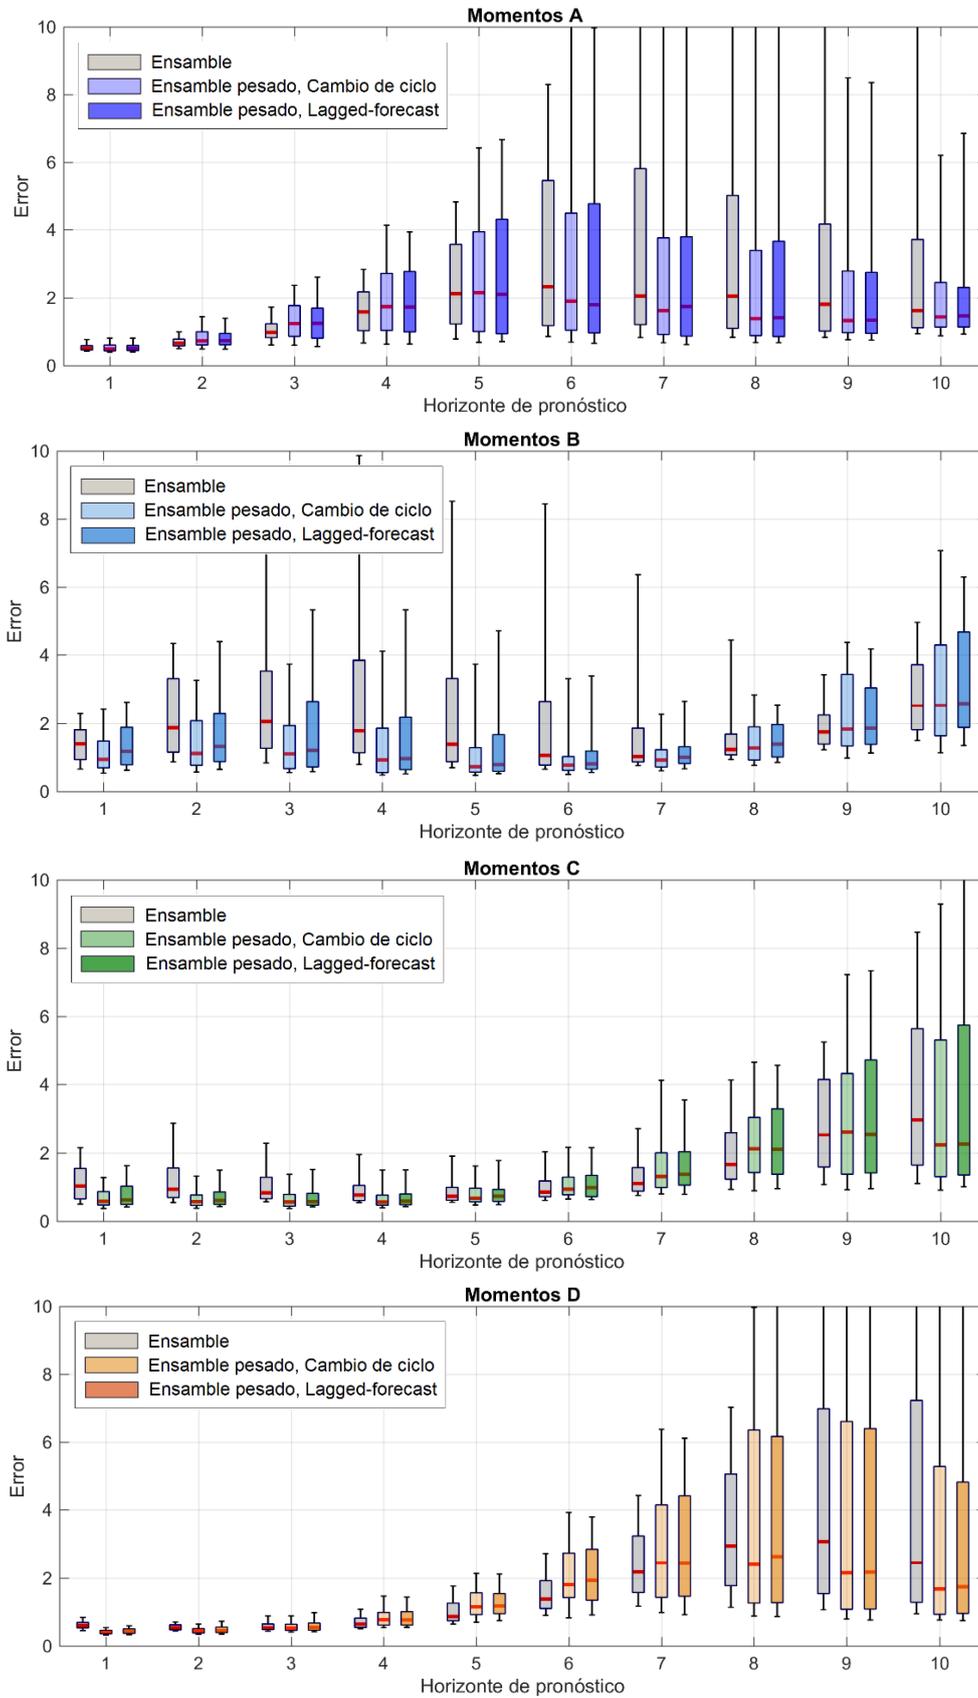


Figura 5-20: Comparación de la evolución a lo largo del horizonte de pronóstico de la media del error entre todo el ensamble, el ensamble pesado con cambio de ciclo y con lagged-forecast submuestreando los “momentos clave”.

Se observa que, como era de esperar, el comportamiento depende de la posición inicial del sistema (representada a través de los “momentos clave”), con lo cual es fundamental distinguirla previo al análisis de habilidad.

En general, es muy difícil mejorar el error de la media de todo el ensamble, aun ponderando los miembros según su desempeño en el período inmediato anterior. Sin embargo, sí se verifica que la dispersión de los ensambles pesados es siempre menor que la de todo el ensamble. En lo que respecta a la evolución de la media del error de cada conjunto, los mayores incrementos de habilidad se obtienen cuando el sistema se encuentra en una de las alas del atractor (entre los momentos B y D).

En aquellos casos en que el error de la media de los ensambles pesados es marginalmente mayor al del ensamble completo y la dispersión es menor (por ejemplo, en los momentos B y C), cabe la posibilidad de que los ensambles pesados ofrezcan información más útil a sistemas de decisión sensibles no sólo a la media del pronóstico, sino también a la dispersión del mismo a través de estadísticos como el error medio u otros.

5.6.1 Síntesis

Finalmente, se buscó generalizar los resultados obtenidos sobre el incremento en la habilidad de predicción a cualquier posición en el ciclo del atractor de Lorenz, manteniendo la idea de “operatividad” (es decir que sólo se requiera información hasta t). Para ello, se renombraron los momentos A ($m+1$) y C ($M+1$) y se completaron los puntos intermedios con $m+2, m+3, \dots, m+X$ y $M+2, M+3, \dots, M+X$ (cuanto mayor sea X , menor será el muestreo de casos disponible). Los puntos de inflexión B y D se corresponden con alguno de los puntos $m+X$ ($M+X$) en cada ciclo del modelo.

Luego, se calculó la evolución a lo largo del horizonte de pronóstico del error de la media, la media del error y la dispersión de los ensambles pesados y el ensamble de referencia submuestreando cada conjunto de puntos $m+X$ ($M+X$). En todos los casos el error se define como la distancia (3D) al Análisis correspondiente en el espacio (x, y, z).

En la Tabla 5-3 se presenta una valoración de la mejora en la habilidad de predicción, que contempla tanto al error como a la dispersión de cada conjunto. En la misma se presenta el promedio de los cocientes entre (a) los errores de las medias, (b) las dispersiones y (c) las medias de los errores del ensamble pesado con cambio de ciclo y de todo el ensamble (conjunto de referencia). Dichos cocientes se calcularon para cada paso de tiempo dentro del horizonte de pronóstico y en función de la posición de la condición inicial en el atractor de Lorenz (determinada por la evolución de la distancia entre los clusters). En la última fila se indica el número de ciclos considerados en cada caso. Se incluyó también una última columna con el cociente para cada paso de tiempo dentro del

horizonte de pronóstico considerando todos los ciclos de asimilación (sin distinguir entre las distintas posiciones iniciales). Se empleó una escala gradual de colores (cociente < 1 : verde, cociente $= 1$: blanco, cociente > 1 : rojo) de manera de facilitar la visualización: cuanto menor sea el valor del cociente, mayor será la mejora en la habilidad de predicción del sistema.

Análogamente, en la Tabla 5-4 se presentan los resultados obtenidos para el cociente de las medias de los errores del ensamble pesado con lagged-forecast y de todo el ensamble. Esta metodología es válida aun en sistemas de asimilación que “pierdan la memoria” entre distintas inicializaciones.

En ambos casos se observa que, para todas las posiciones iniciales en el ciclo del atractor de Lorenz se tiene una mejora (reducción de la media del error), aunque sea marginal, para algún horizonte de pronóstico.

Tabla 5-3: Valoración de la mejora en la habilidad en función del horizonte de pronóstico y la posición en el ciclo del atractor de Lorenz para el ensamble pesado con cambio de ciclo.

(a) Promedio de los cocientes de los errores de las medias de los ensambles

Horizonte	A			B			C			D		Todos
	m+1	m+2	m+3	m+4	m+5	m+6	M+1	M+2	M+3	M+4	M+5	
1	1,27	1,59	1,75	2,01	1,69	1,61	1,89	1,40	1,48	1,38	1,27	1,59
2	1,25	1,33	1,44	1,30	1,24	2,20	1,59	1,40	1,12	1,17	1,37	1,36
3	1,26	1,57	1,30	1,35	1,30	1,59	1,36	1,19	1,27	1,23	1,62	1,34
4	1,14	1,28	1,19	1,29	1,35	1,22	1,30	1,18	1,06	1,22	1,06	1,21
5	1,25	1,23	1,19	1,36	1,28	1,14	1,19	1,18	1,26	1,14	1,34	1,23
6	1,12	1,17	1,20	1,18	1,20	1,14	1,27	1,09	1,19	1,04	0,98	1,16
7	1,07	1,14	1,17	1,21	1,16	1,26	1,40	1,21	1,20	1,02	0,97	1,18
8	1,10	1,27	1,28	1,20	1,19	1,22	1,38	1,11	1,13	0,99	0,94	1,18
9	1,13	1,22	1,28	1,23	1,66	1,21	1,22	0,98	1,08	0,99	0,96	1,17
10	1,15	1,24	1,18	1,23	1,13	1,21	1,11	0,95	1,07	1,00	1,12	1,13
# Ciclos	134	104	99	90	62	28	135	107	91	76	40	984

(b) Promedio de los cocientes de las dispersiones de los ensambles

Horizonte	A			B			C			D		Todos
	m+1	m+2	m+3	m+4	m+5	m+6	M+1	M+2	M+3	M+4	M+5	
1	0,76	0,72	0,72	0,66	0,66	0,62	0,73	0,77	0,79	0,81	0,81	0,74
2	0,76	0,72	0,72	0,67	0,67	0,63	0,75	0,80	0,83	0,83	0,81	0,75
3	0,76	0,73	0,73	0,68	0,68	0,64	0,78	0,83	0,84	0,82	0,80	0,76
4	0,77	0,73	0,73	0,69	0,71	0,68	0,81	0,85	0,84	0,82	0,80	0,77
5	0,77	0,74	0,75	0,71	0,74	0,74	0,82	0,85	0,84	0,82	0,80	0,78
6	0,77	0,74	0,76	0,73	0,78	0,79	0,83	0,85	0,84	0,82	0,80	0,79
7	0,78	0,76	0,78	0,76	0,80	0,81	0,83	0,84	0,84	0,82	0,80	0,80
8	0,79	0,77	0,78	0,77	0,82	0,82	0,83	0,84	0,84	0,83	0,82	0,81
9	0,79	0,78	0,79	0,79	0,84	0,81	0,83	0,84	0,84	0,83	0,82	0,81
10	0,80	0,78	0,79	0,80	0,84	0,80	0,83	0,85	0,84	0,84	0,83	0,82
# Ciclos	134	104	99	90	62	28	135	107	91	76	40	984

(c) Promedio de los cocientes de las medias de los errores de los ensambles

Horizonte	A			B			C			D		Todos
	m+1	m+2	m+3	m+4	m+5	m+6	M+1	M+2	M+3	M+4	M+5	
1	1,00	1,24	1,09	1,07	0,82	0,69	0,68	0,62	0,68	0,78	0,93	0,88
2	1,17	1,38	1,04	0,97	0,66	0,61	0,67	0,69	0,82	1,05	1,10	0,94
3	1,26	1,28	0,94	0,81	0,57	0,51	0,72	0,80	1,07	1,25	1,35	0,98
4	1,20	1,09	0,79	0,68	0,52	0,45	0,82	1,05	1,26	1,50	1,38	1,00
5	1,09	0,90	0,68	0,67	0,55	0,53	0,99	1,24	1,46	1,48	1,13	1,01
6	0,96	0,78	0,65	0,75	0,67	0,72	1,17	1,34	1,42	1,28	1,01	1,00
7	0,86	0,74	0,74	0,89	0,88	0,87	1,28	1,33	1,20	1,07	0,84	1,00
8	0,83	0,81	0,85	1,07	1,11	1,10	1,28	1,12	1,04	0,91	0,72	0,99
9	0,85	0,93	1,01	1,21	1,20	1,22	1,11	0,98	0,87	0,80	0,71	0,99
10	0,93	1,07	1,11	1,19	1,18	1,03	0,96	0,84	0,79	0,78	0,86	0,97
# Ciclos	134	104	99	90	62	28	135	107	91	76	40	984

Tabla 5-4: Valoración de la mejora en la habilidad en función del horizonte de pronóstico y la posición en el ciclo del atractor de Lorenz para el ensamble pesado con lagged-forecast.

Promedio de los cocientes de las medias de los errores de los ensambles

Horizonte	A			B			C			D		Todos
	m+1	m+2	m+3	m+4	m+5	m+6	M+1	M+2	M+3	M+4	M+5	
1	1,01	1,20	1,19	1,08	0,98	0,87	0,75	0,66	0,70	0,80	0,97	0,93
2	1,17	1,31	1,11	0,95	0,76	0,67	0,71	0,72	0,83	1,05	1,12	0,96
3	1,25	1,19	0,96	0,78	0,63	0,58	0,74	0,84	1,08	1,25	1,37	0,98
4	1,18	1,02	0,80	0,65	0,57	0,49	0,83	1,09	1,26	1,46	1,36	0,99
5	1,07	0,84	0,69	0,64	0,59	0,54	0,99	1,29	1,40	1,44	1,12	0,99
6	0,93	0,74	0,67	0,72	0,72	0,75	1,14	1,40	1,40	1,24	1,01	0,99
7	0,83	0,72	0,74	0,85	0,91	0,86	1,26	1,39	1,16	1,03	0,85	0,98
8	0,80	0,80	0,86	1,03	1,16	1,06	1,26	1,15	1,01	0,86	0,74	0,98
9	0,82	0,91	1,01	1,16	1,23	1,15	1,08	0,98	0,84	0,76	0,73	0,96
10	0,90	1,05	1,09	1,16	1,25	0,96	0,95	0,84	0,77	0,75	0,86	0,96
# Ciclos	134	104	99	90	62	28	135	107	91	76	40	984

5.7 SÍNTESIS

En base a la implementación disponible en Python del modelo de Lorenz 63 junto con el método de asimilación ETKF determinístico fue posible realizar una caracterización de la evolución del error de cada uno de los miembros del ensamble en función del horizonte de pronóstico, así como analizar hasta qué punto dicha caracterización se refleja en el siguiente ciclo de pronóstico.

En todos los casos, la habilidad de los miembros del ensamble se midió respecto del Análisis y no de la verdadera trayectoria del sistema o de las observaciones, ya que en la atmósfera el Análisis es la mejor estimación disponible del estado del sistema en cada paso de tiempo.

En lo que refiere a la caracterización de la evolución del error y la dispersión del ensamble a medida que avanza el horizonte de pronóstico, se observa que, como era de esperar, a medida que se avanza en el horizonte de pronóstico aumenta el error y la dispersión de los miembros del ensamble, es decir que disminuye la predictibilidad del sistema.

Luego, buscando emplear toda la información disponible para mejorar la descripción de la incertidumbre enfrentada, se propusieron dos metodologías para la ponderación de los miembros del ensamble según su habilidad reciente. Para ello se considera el primer paso de la penúltima inicialización, pues en un escenario operativo se supone que el Análisis en $t+1$ (futuro) no está aún disponible. La primera metodología se basa en la selección del “mejor” sub-ensamble mediante la técnica de Cluster Analysis (k-means) al inicio de cada ciclo de asimilación. La segunda consiste en la construcción de un ensamble no equiprobable o “pesado” asignando el peso de cada miembro según el inverso de la distancia al Análisis.

Ambas metodologías se aplicaron a distintos ciclos de pronóstico bajo dos esquemas, que dependen de las características del sistema de asimilación: el esquema de “time lagged-ensemble” y el de “cambio de ciclo”. Bajo el esquema de “time lagged-ensemble” se considera, para cada inicialización, el pronóstico inicializado en el ciclo anterior, para el cual se definieron previamente los clusters y pesos según su primer paso. El esquema de “cambio de ciclo” consiste en considerar los clusters y pesos definidos según el primer paso del penúltimo pronóstico, pero aplicados al último pronóstico disponible. Dicho esquema es válido solamente cuando el sistema de asimilación conserva la “memoria/familiaridad” entre los miembros del ensamble de un ciclo al siguiente.

De la evaluación de las metodologías desarrolladas en comparación a la habilidad de predicción del ensamble completo de la última inicialización disponible (considerado como el “conjunto de referencia”) se desprende que, si bien el error de la media de los ensambles modificados es mayor al de la media de todo el ensamble, sí se verifica que la dispersión de los primeros es siempre menor que la del conjunto de referencia. En particular, la metodología de ponderación de miembros mediante la construcción de un ensamble no equiprobable presenta un mejor desempeño que la del agrupamiento en el “mejor” sub-ensamble.

Teniendo en cuenta que la predictibilidad del sistema depende del estado inicial del mismo en cada paso de pronóstico, se realizó una valoración de la mejora en la habilidad de predicción en función de la posición en el atractor.

Para ello, en función de las derivadas primera y segunda de la serie de la distancia entre centroides de los sub-ensambles se identificaron los “momentos clave” ($m+1$ y $M+1$, puntos siguientes a los mínimos y máximos relativos) y se completaron los puntos intermedios como $m+X$ y $M+X$. Luego, se calculó la evolución a lo largo del horizonte de pronóstico del error de la media, la media del error y la dispersión de los ensambles pesados y todo el ensamble (conjunto de referencia) submuestreando cada conjunto de puntos. En particular, se calculó el promedio de los cocientes entre las medias de sus errores, de manera de contemplar tanto al error como a la dispersión de cada conjunto. De dicha comparación se desprende que, para todas las posiciones en el ciclo del atractor de Lorenz se tiene una mejora de la habilidad de predicción para algún horizonte de pronóstico, basada fundamentalmente en la reducción de la dispersión del ensamble.

En base a todo lo anterior se concluye que, en una nueva inicialización o paso de asimilación del modelo de Lorenz 63, la construcción de ensambles modificados según el desempeño de cada miembro en el período inmediato anterior puede ofrecer información más útil a sistemas de decisión sensibles no sólo a la media del pronóstico, sino también a la dispersión del mismo a través de estadísticos

como el error medio u otros. La magnitud y horizonte de la mejora dependen del estado del sistema en cada ciclo particular de pronóstico.

CAPÍTULO 6

APLICACIÓN DE TÉCNICAS DE “TIME-LAGGED ENSEMBLES” AL PRONÓSTICO DE PRECIPITACIÓN DEL MODELO GEFS

6. Aplicación de técnicas de “time-lagged ensembles” al pronóstico de precipitación del modelo GEFS

De la evaluación de la calidad del pronóstico por ensambles de precipitación del modelo GEFS en la cuenca del Río Negro presentada en el capítulo 3 surge que, si bien el pronóstico captura satisfactoriamente el comportamiento de la precipitación observada, la dispersión del ensamble es excesivamente baja -en comparación con el error medio del mismo- durante los primeros días, atenuándose el problema a medida que avanza el horizonte de pronóstico. Por tanto, el dato observado está demasiado a menudo fuera del rango del ensamble. Esta subestimación en la amplitud de la incertidumbre que enfrenta el sistema en el horizonte inmediato (uno a pocos días) afecta el cálculo de la operación óptima del sistema eléctrico.

En este capítulo se busca sentar las bases de una metodología general para mejorar este aspecto del desempeño del pronóstico por ensambles de precipitación. Para ello se propone una técnica de bajo costo computacional basada en la combinación de “time-lagged ensembles” (Hoffman & Kalnay, 1983), que incorpora las últimas observaciones (locales) disponibles a través de una ponderación simple de los miembros de cada ensamble en función de su habilidad reciente.

A continuación, en primer lugar, se presenta un breve marco teórico que sustenta el desarrollo de la metodología propuesta. Luego, se presenta la evaluación del desempeño de los super-ensambles equiprobables (sin pesos diferenciales) que surgen de combinar los distintos “time-lagged ensembles” de precipitación del modelo GEFS en la cuenca del Río Negro. Por último, se incorporan los pesos a través de una ponderación simple en función de la habilidad reciente de cada miembro y se evalúa el desempeño del super-ensamble pesado resultante.

6.1 MARCO TEÓRICO

Las previsiones hidrológicas operativas normalmente se generan mediante un proceso de modelación formado por varios componentes encadenados, siendo los dos principales el pronóstico meteorológico y el modelo hidrológico. Debido a la incertidumbre inherente a dicho proceso, en las últimas dos décadas la mayoría de los centros operacionales ha comenzado a desarrollar y emplear modelos probabilísticos basados en simulaciones por ensambles, buscando representar adecuadamente (desde el punto de vista estadístico) la distribución de los posibles estados futuros del sistema. En particular, en la actualidad el desafío de combinar los diversos pronósticos disponibles en uno “superior”

resulta de gran interés (DelSole et al., 2017; Bellier et al., 2021; Troin et al., 2021). Para ello se han propuesto numerosas metodologías: (i) combinar múltiples pronósticos meteorológicos inicializados en diferentes momentos en un “*time-lagged ensemble*” (Jie et al., 2014); (ii) combinar ensambles meteorológicos provenientes de diferentes modelos numéricos en un “*gran ensemble*” (He et al., 2009; Pappenberger et al., 2008; Qu et al., 2017); (iii) emplear múltiples modelos hidrológicos en un enfoque “*multimodelo*” (Velázquez et al., 2011; Thiboult et al., 2016); (iv) una combinación de los enfoques anteriores.

La técnica de “*Time-Lagged Ensembles*” (TLE) se basa en la generación de ensambles a partir de múltiples pronósticos inicializados en diferentes momentos, pero todos verificados al mismo tiempo. Dada la diferencia en la calidad de los miembros, se les suele asignar diferentes pesos en función de su “edad” y/o habilidad reciente. De esta manera, permite aprovechar la información de simulaciones y observaciones pasadas, a la vez que incorpora la última inicialización disponible (Hoffman & Kalnay, 1983; Du et al., 2018). La principal ventaja es su bajo costo computacional.

En la Figura 6-1 se muestra la representación esquemática de un sistema de TLE: el eje horizontal corresponde al tiempo y el eje vertical al estado de la variable X , las distintas series representan la evolución de X para los ciclos de pronósticos inicializados en $0, -\tau, -2\tau$ y -3τ , t_f representa el horizonte de pronóstico.

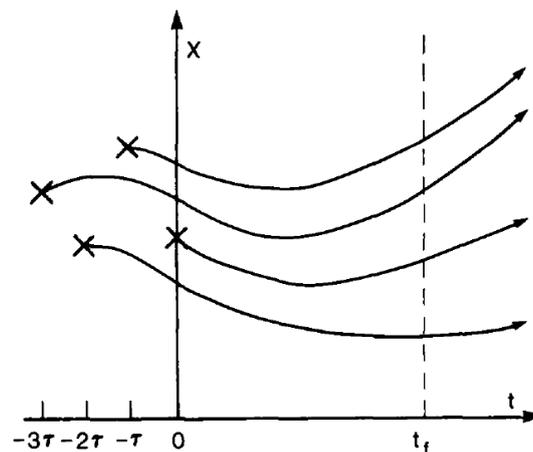


Figura 6-1: Representación esquemática de un sistema de “*time-lagged ensembles*”. El eje horizontal corresponde al tiempo y el eje vertical al estado de la variable X .

Fuente: Hoffman & Kalnay (1983).

Esta metodología tiene dos “factores opuestos” que influyen en la habilidad del pronóstico resultante: mientras que el uso de las simulaciones anteriores aumenta el tamaño del ensamble y puede mejorar la habilidad y confiabilidad de la predicción, la inclusión de pronósticos asociados a horizontes cada vez más lejanos puede resultar en una degradación de la habilidad. Debido a estos dos “factores opuestos”, no se conoce a priori cuál será el efecto de diferentes configuraciones de TLE en la habilidad de predicción (Chen et al., 2013; DelSole

et al., 2017). A la vez, el grado de consistencia entre las sucesivas simulaciones es presumiblemente una medida de la confianza del pronóstico. Es de esperar que bajo regímenes más “predecibles” las diferencias entre pronósticos sucesivos sean pequeñas, mientras que bajo regímenes de flujo atmosférico más “volátiles” se espera que dichas diferencias aumenten.

La técnica de TLE ha sido aplicada con éxito tanto para pronósticos meteorológicos a corto plazo y alta resolución (Mittermaier, 2007; Yuan et al., 2009; Ben Bouallègue et al., 2013), como para pronósticos a mediano plazo (Brankovic et al., 1990; Jie et al., 2014) y estacionales (Saha et al. 2006, Chen et al., 2013). También ha sido empleada en la aviación y el transporte marítimo (Zhou et al., 2010; Du & Zhou, 2017). En general, en estos estudios el ensamble TLE se genera combinando diferentes pronósticos determinísticos (con diferentes antelaciones) y considerando pesos equiprobables para todos los miembros.

El enfoque TLE también se puede aplicar a pronósticos por ensambles, en lugar de a pronósticos determinísticos, para obtener un “*super-ensamble*” (Lawrence & Hansen, 2007). Ben Bouallègue et al. (2013) demostraron que este enfoque mejora en gran medida el desempeño de los pronósticos probabilísticos de corto plazo de precipitación. Esto se debe a un aumento del tamaño del ensamble, así como a una mejora en su distribución y también a la información adicional que aportan los pronósticos inicializados en diferentes momentos. Una pregunta que surge a menudo al combinar los distintos pronósticos es si deben ponderarse por igual o no (DelSole et al., 2013). Además, bajo el supuesto de que una ponderación diferencial proporciona valor añadido, es necesario evaluar el tipo de ponderación óptima (Raynaud et al., 2015).

En este sentido, estudios recientes han intentado mejorar la habilidad del ensamble TLE mediante el desarrollo de un “*ensamble pesado/ponderado*”, en el cual se les asignan pesos a los diferentes miembros de manera de maximizar su desempeño. Una primera estimación simple, adecuada cuando los errores no están correlacionados, es que el peso de cada miembro sea inversamente proporcional al error cuadrático medio del pronóstico (DelSole et al., 2017). Sin embargo, las ponderaciones no siempre conducen a mejoras en la habilidad del pronóstico respecto del desempeño del ensamble equiprobable (Ben Bouallègue et al., 2013; DelSole et al., 2013). Los pesos pueden variar en el tiempo (Raynaud et al., 2015) o ser constantes (Lu et al., 2007). En este sentido, Raynaud et al. (2015) no encontraron una mejora significativa en el desempeño al permitir variaciones temporales en los mismos. Entre las técnicas de combinación probabilística de pronósticos por ensambles se destaca el método BMA “Bayesian Model Averaging” (Raftery et al., 2005). Este método representa la función de densidad de probabilidad (PDF) predictiva como un promedio ponderado de las PDFs centradas en los pronósticos individuales, donde los pesos son las probabilidades posteriores de los modelos y reflejan las contribuciones relativas de cada uno a la

habilidad del pronóstico por ensambles durante un período de entrenamiento. Sloughter et al. (2007) implementaron una extensión del método BMA válida específicamente para pronósticos probabilísticos de precipitación. Casanova & Ahrens (2009) evaluaron el desempeño de tres metodologías de ponderación de modelos individuales en un ensamble multimodelo de temperatura: ensamble equiprobable (EW, “equal weighting”), ponderación simple basada en la habilidad considerando como pesos las inversas normalizadas de los errores cuadráticos medios (SW, “simple skill-based weighting”) y el método BMA. En la mayoría de los casos, llegaron a que el método simple SW basado en la habilidad es igual o más eficaz que el BMA. Teniendo en cuenta el costo computacional de este último método, recomiendan su aplicación en los casos en que se identifiquen modelos individuales consistentemente buenos en el ensamble (ya que el BMA efectivamente les asigna mayor peso).

En el capítulo anterior (capítulo 5) se evaluaron dos metodologías para la ponderación de miembros en base al modelo Lorenz 63 con asimilación de datos mediante el método EnKF: (i) selección del “mejor” sub-ensamble mediante la técnica de Cluster Analysis (k-means); (ii) construcción de un ensamble no equiprobable o “pesado”, asignando el peso de cada miembro según el inverso de la distancia al Análisis. Ambas metodologías se aplicaron a distintos ciclos de pronóstico bajo dos esquemas, que dependen de las características del sistema de asimilación: el esquema TLE y el de “cambio de ciclo”. De los resultados obtenidos se desprende que, en una nueva inicialización o paso de asimilación del modelo de Lorenz 63, la construcción de ensambles modificados según el desempeño de cada miembro en el período inmediato anterior puede ofrecer información más útil a sistemas de decisión sensibles no sólo a la media del pronóstico, sino también a la dispersión del mismo a través de estadísticos como el error medio u otros. La magnitud y horizonte de la mejora dependen del estado del sistema en cada ciclo particular de pronóstico. En particular, la metodología de ponderación de miembros mediante la construcción de un ensamble no equiprobable presentó un mejor desempeño que la del agrupamiento en el “mejor” sub-ensamble.

6.2 EVALUACIÓN DE SUPER-ENSAMBLES EQUIPROBABLES

En esta sección se presenta la evaluación del desempeño de los super-ensambles equiprobables (sin pesos diferenciales) que surgen de combinar los distintos “time-lagged ensembles” de precipitación del modelo GEFS en la cuenca del Río Negro.

Al igual que en el capítulo 3, para la evaluación se empleó la versión V12 del GEFS, compuesta por la corrida de control más 30 miembros perturbados, y se consideró únicamente la simulación iniciada a las 00UTC (por ser la que utiliza ADME en las salas de programación para el despacho semanal). El periodo

analizado comprende noviembre de 2020 a diciembre de 2022 (777 ciclos de pronóstico).

Para la evaluación se consideró una resolución temporal diaria (acumulado de las últimas 24 horas a las 10UTC) y una agregación espacial en la cuenca “total” de aporte del Río Negro con cierre en Constitución (cuenca RN) con una extensión superficial de 62.900 km² (ver Figura 3-6).

Los datos históricos empleados para evaluar los pronósticos de precipitación son las estimaciones RK en base a la combinación de imágenes satelitales y observaciones pluviométricas en superficie desarrolladas por De Vera et al. (2021) y actualizadas por Alfaro (2022), presentadas en la sección 2.3.2.1.

6.2.1 Construcción de super-ensambles

Para la construcción de los super-ensambles se combinó el último pronóstico disponible en t (**Lag-0**), con los pronósticos iniciados hasta tres días antes (si bien el modelo GEFS se ejecuta cuatro veces al día, en este análisis se consideran únicamente las simulaciones iniciadas a las 00UTC):

- **Lag-0-1** (60 miembros): Compuesto por el ensamble Lag-0 y el ensamble iniciado el día anterior (**Lag-1**).
- **Lag-0-1-2** (90 miembros): Compuesto por los ensambles Lag-0, Lag-1 y el ensamble iniciado dos días antes (**Lag-2**).
- **Lag-0-1-2-3** (120 miembros): Compuesto por los ensambles Lag-0, Lag-1, Lag-2 y el ensamble iniciado tres días antes (**Lag-3**).

En la Figura 6-2 se muestra una representación esquemática de la configuración TLE adoptada. El eje horizontal corresponde al horizonte de pronóstico y el eje vertical a las sucesivas inicializaciones, $X_k^{t_{ini}}$ corresponde al pronóstico de la simulación iniciada en el tiempo t_{ini} para el paso k dentro del horizonte de pronóstico (empleando la misma notación presentada en la sección 5.2). A modo de ejemplo, dentro del recuadro rojo se resalta el super-ensamble Lag-0-1-2-3 para el horizonte $t+1$. Cuánto más oscuro sea el sombreado, mayor será la antelación y más antiguo el pronóstico.

Horizonte de pronóstico →

		t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5
Inicialización	Lag-0					X_1^t	X_2^t	X_3^t	X_4^t	X_5^t
	Lag-1				X_1^{t-1}	X_2^{t-1}	X_3^{t-1}	X_4^{t-1}	X_5^{t-1}	X_6^{t-1}
	Lag-2			X_1^{t-2}	X_2^{t-2}	X_3^{t-2}	X_4^{t-2}	X_5^{t-2}	X_6^{t-2}	X_7^{t-2}
	Lag-3		X_1^{t-3}	X_2^{t-3}	X_3^{t-3}	X_4^{t-3}	X_5^{t-3}	X_6^{t-3}	X_7^{t-3}	X_8^{t-3}

Figura 6-2: Esquema de construcción de los super-ensambles mediante la combinación de los TLE inicializados en t-3 (Lag-3), t-2 (Lag-2), t-1 (Lag-1) y t (Lag-0). A modo de ejemplo, dentro del recuadro rojo se resalta el super-ensamble Lag-0-1-2-3 (compuesto por 120 miembros) para el horizonte t+1. Cuánto más oscuro sea el sombreado, mayor será la antelación y más antiguo el pronóstico.

6.2.2 Metodología de evaluación

La metodología seguida para la evaluación de los super-ensambles es análoga a la desarrollada en el capítulo 3 para los ensambles de pronósticos de precipitación diaria del modelo GEFS:

- Caracterización del error y la dispersión del ensamble a lo largo del horizonte de pronóstico.
- Construcción de los histogramas de análisis de rangos (Diagramas de Talagrand) a lo largo del horizonte de pronóstico. Dado que los super-ensambles evaluados están conformados por un número diferente de miembros (que conducen a un número diferente de rangos), para la comparación se remuestraron todos los rangos considerando un total de 30 intervalos en cada caso.

Cabe destacar que se presenta la evolución a lo largo del horizonte de pronóstico hasta el paso de tiempo t+5 (k = 5).

6.2.3 Resultados

A continuación, se presentan los principales resultados obtenidos en la evaluación del desempeño de los super-ensambles equiprobables construidos según la metodología anterior, en comparación a la habilidad de predicción del ensamble de la última inicialización disponible "Lag-0" (considerado como el "conjunto de referencia").

En la Tabla 6-1 se muestra la evolución a lo largo de los primeros cinco días del horizonte de pronóstico del RMSE de la media del ensamble (expresado en mm) para el ensamble Lag-0 y los super-ensambles, considerando todos los ciclos de pronóstico disponibles (lo que es equivalente a adoptar un umbral de precipitación de 0 mm). Para cada horizonte (k) se empleó una escala gradual de colores de manera de facilitar la visualización (verde: menor RMSE, rojo: mayor RMSE).

Tabla 6-1: Evolución a lo largo de los primeros cinco días del horizonte de pronóstico del RMSE de la media del ensamble (expresado en mm) para el ensamble de referencia (Lag-0) y los tres super-ensambles construidos mediante la técnica TLE (umbral = 0 mm).

Super-ensamble	Horizonte de pronóstico				
	k = 1 día	k = 2 días	k = 3 días	k = 4 días	k = 5 días
Lag-0	5,14	5,27	5,21	5,42	6,43
Lag-0-1	5,10	5,12	5,19	5,88	6,53
Lag-0-1-2	4,98	5,09	5,51	6,02	6,57
Lag-0-1-2-3	4,96	5,33	5,63	6,14	6,62

En la Figura 6-3 se presenta la evolución del cociente entre la dispersión del ensamble (valor medio en todos los ciclos considerados) y el RMSE de la media del ensamble (ratio SPREAD/RMSE) para el ensamble Lag-0 (gris), el super-ensamble Lag-0-1 (celeste), el super-ensamble Lag-0-1-2 (rosado) y el super-ensamble Lag-0-1-2-3 (verde), adoptando un umbral de precipitación de 0 mm.

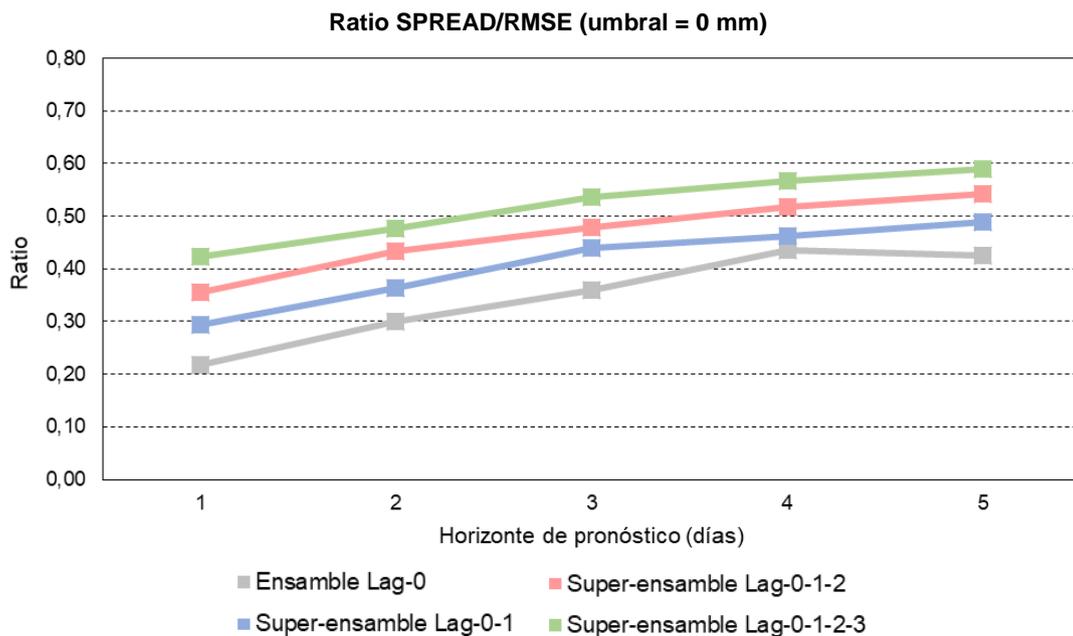


Figura 6-3: Evolución a lo largo de los primeros cinco días del horizonte de pronóstico del cociente entre la dispersión del ensamble y el RMSE de la media del ensamble (adoptando un umbral de precipitación de 0 mm).

Análogamente, en la Tabla 6-2 y Figura 6-4 se presentan los mismos resultados pero considerando únicamente los ciclos de pronóstico en los que la precipitación observada en el horizonte correspondiente es mayor o igual a 5 mm (del orden de 110 casos por horizonte).

Tabla 6-2: Evolución a lo largo de los primeros cinco días del horizonte de pronóstico del RMSE de la media del ensamble (expresado en mm) para el ensamble de referencia (Lag-0) y los tres super-ensambles construidos mediante la técnica TLE (umbral = 5 mm).

Super-ensamble	Horizonte de pronóstico				
	k = 1 día	k = 2	k = 1 día	k = 4	k = 1 día
Lag-0	11,92	11,18	11,11	11,98	14,50
Lag-0-1	11,40	10,90	11,26	13,17	14,91
Lag-0-1-2	10,99	10,99	12,14	13,56	15,21
Lag-0-1-2-3	10,97	11,66	12,51	14,04	15,48

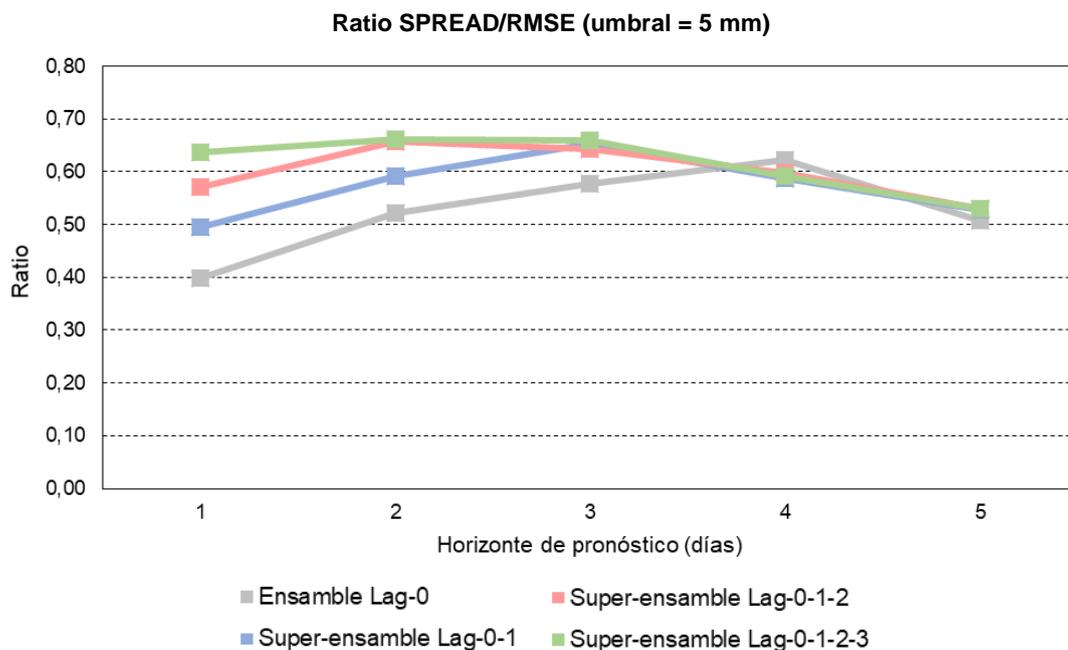


Figura 6-4: Evolución a lo largo de los primeros cinco días del horizonte de pronóstico del cociente entre la dispersión del ensamble y el RMSE de la media del ensamble para los ciclos de pronóstico con precipitación observada mayor o igual a 5 mm (110 ciclos).

Se observa que al aumentar el umbral de precipitación (> 0 mm) se mantiene la estructura de los resultados, pero cambia la evolución del cociente SPREAD/RMSE. Esto puede deberse a la disminución del muestro de ciclos disponibles en cada caso (766 versus 110 ciclos).

En la siguiente figura se presentan los histogramas de análisis de rangos (con remuestreo a 30 intervalos) para los horizontes de pronóstico $k = 1, 3$ y 5 días para el ensamble de referencia (Lag-0) y los tres super-ensambles construidos mediante la técnica TLE (adoptando un umbral de precipitación de 0 mm). En todos los casos se incluye el nivel que representa la frecuencia teórica en cada

categoría para un sistema de pronóstico por ensamble perfectamente confiable (línea horizontal roja). Cabe destacar que el eje vertical (frecuencia) varía con el horizonte de pronóstico, de manera de permitir una mejor visualización de los histogramas en cada caso.

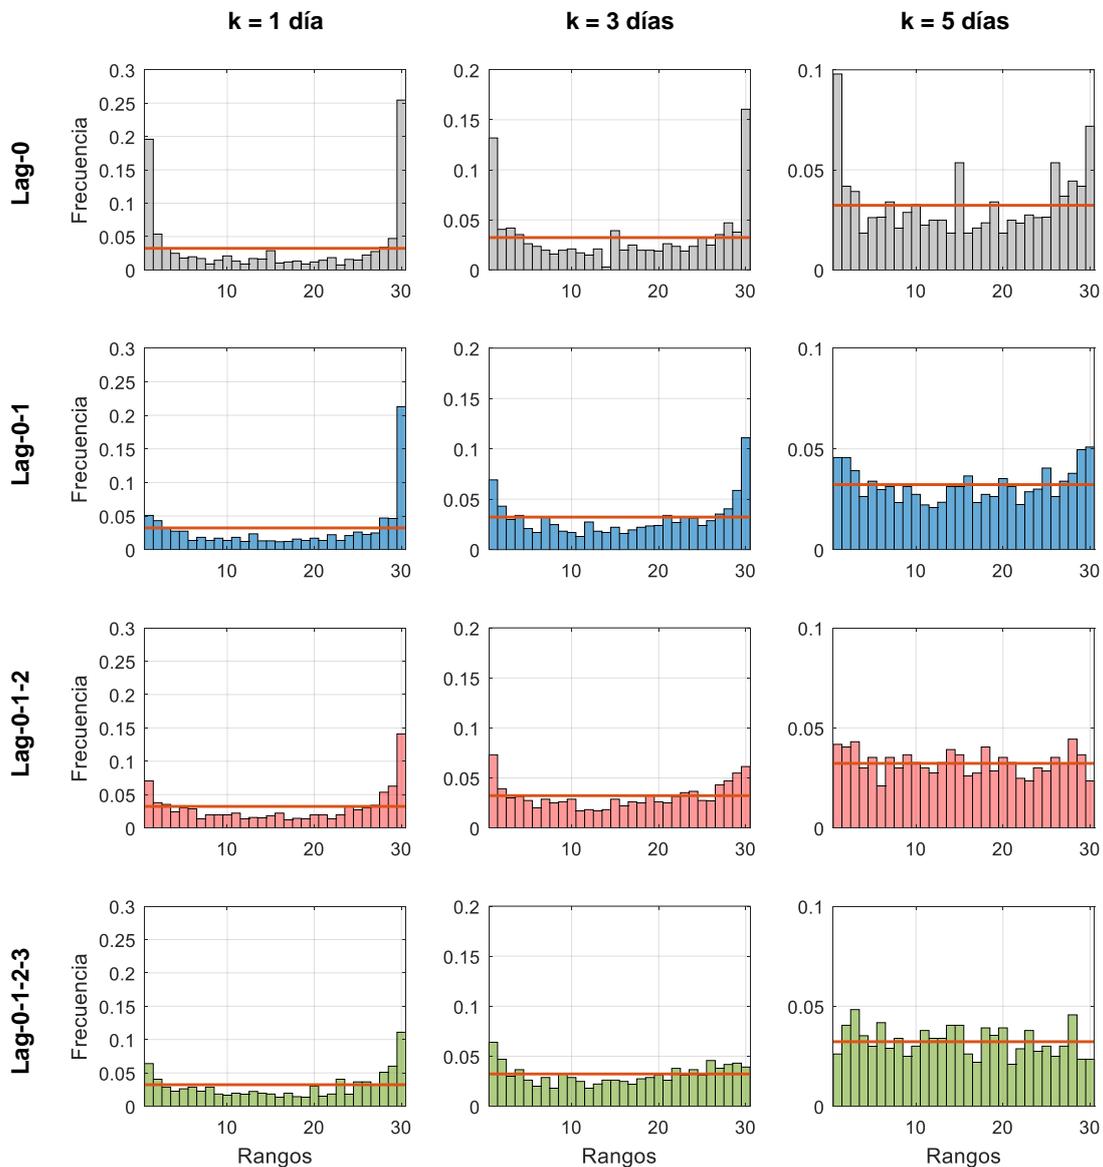


Figura 6-5: Histogramas de análisis de rangos (con remuestreo a 30 intervalos) para los horizontes de pronóstico $k = 1, 3$ y 5 días para el ensamble de referencia (Lag-0) y los tres super-ensambles construidos mediante la técnica TLE (adoptando un umbral de precipitación de 0 mm).

De los resultados obtenidos se desprende que mediante la construcción de los super-ensambles equiprobables se logra una mejora sustancial en la distribución sin deteriorar el RMSE (incluso con mejoras marginales no significativas), lo que se traduce en una mejora del cociente SPREAD/RMSE. Esto sugiere que el enfoque TLE aporta información valiosa que va más allá de aumentar el tamaño del ensamble (Raynaud et al., 2015).

Como era de esperar, a medida que avanza el horizonte de pronóstico, la inclusión de simulaciones asociadas a antelaciones cada vez más lejanas resulta en una degradación de la habilidad.

6.3 INCORPORACIÓN DE PESOS

Una vez evaluado el desempeño de los super-ensambles equiprobables, se procede a la incorporación de pesos diferenciales a través de una ponderación simple en función de la habilidad reciente de cada miembro y se evalúa el desempeño del super-ensamble pesado resultante.

Para medir la habilidad de los miembros se considera únicamente el error en el campo de precipitación integrado en la cuenca del Río Negro, siendo conscientes de las limitaciones que ello implica: (i) es un campo que tiene asociada una gran incertidumbre en su estimación; (ii) su carácter binario (llueve/no llueve) conlleva a que se tengan muchos “ceros” en la serie temporal (en nuestra región el porcentaje anual de días “secos” es del orden del 70%); (iii) su distribución asimétrica positiva, en la que los montos grandes de precipitación son relativamente poco frecuentes. En particular, en el periodo analizado (noviembre de 2020 a diciembre de 2022) el muestreo de días lluviosos es bajo (solamente en el 15% de los días la precipitación fue superior a 5 mm) ya que, en nuestra región, dicho periodo se caracteriza por ser un periodo de déficit hídrico (ver sección 3.2.1).

En todos los casos, la habilidad se mide respecto de la última observación disponible (estimación RK en base a la combinación de imágenes satelitales y observaciones pluviométricas en superficie).

Cabe destacar que los pesos que aquí se incorporan no distinguen a los TLE según su edad (“lag”), si no que se calculan exclusivamente en función de la habilidad de cada miembro respecto de la observación.

6.3.1 Definición de los pesos

Medida del error según el campo de precipitación

Para cuantificar la habilidad de cada miembro del ensamble se define una medida del error (distancia) que incluye no solo el monto de precipitación sino también su dimensión espacial.

Para ello, para cada día de pronóstico (t), se calcula el baricentro (G_X, G_Y) ponderado por los montos de la precipitación pronosticada (GEFS) y observada (RK), considerando como agregación espacial las 25 subcuencas del Río Negro (según se presenta en la Figura 2-2):

$$w^s(t) = \frac{P_s(t) \times A_s}{P_{RN}(t) \times A_{RN}}$$

$$w_{norm}^s(t) = \frac{w^s(t)}{\sum_{s=1}^{25} w^s(t)}$$

$$G_X(t) = \sum_{s=1}^{25} w_{norm}^s(t) \times X_{cen}^s$$

$$G_Y(t) = \sum_{s=1}^{25} w_{norm}^s(t) \times Y_{cen}^s$$

donde P_s y A_s son la precipitación y el área de la subcuenca s , P_{RN} y A_{RN} son la precipitación media areal y el área de la cuenca del Río Negro, w^s es el peso correspondiente a la subcuenca s , w_{norm}^s es el peso normalizado de la subcuenca s , (X_{cen}^s, Y_{cen}^s) son las coordenadas (x,y) del baricentro de la subcuenca s y (G_X, G_Y) son las coordenadas (x,y) del baricentro ponderado por los montos.

Si la precipitación media areal observada o pronosticada es cero, en ese caso se adopta como baricentro de la precipitación el baricentro de la cuenca del Río Negro (como si hubiera llovido uniforme).

De esta manera, para cada día de pronóstico, se tiene un valor promedio areal en la cuenca del Río Negro (P_{RN}) y un baricentro asociado a dicho monto (G_X, G_Y), tanto para la precipitación pronosticada como para la observada.

A modo de ejemplo, en la Figura 6-6 se presenta el mapa con la precipitación media areal observada en las 25 subcuencas del Río Negro (sombreado en tonos de azul), junto con la ubicación del baricentro ponderado por los montos (cuadrado rojo) para el día 10/04/2021 con una precipitación media en la cuenca de 34,2 mm.

Luego, se define la distancia (d) según:

$$d(t) = k_1 + \text{abs}(Anl(t) - Fcst(t)) + \text{min}(Anl(t), Fcst(t)) \times \frac{\Delta G(t)}{k_2}$$

donde Anl es la precipitación media areal observada en la cuenca del Río Negro, $Fcst$ es la precipitación media areal pronosticada, ΔG es la distancia entre los baricentros ponderados por los montos, k_1 y k_2 son parámetros de ajuste.

El primer término previene que resulten grandes diferencias a partir de distinguir precipitaciones nulas con precipitaciones insignificanemente pequeñas. El parámetro k_1 , expresado en mm, representa dicho valor mínimo. El segundo término indica la diferencia de montos de precipitación (media areal) y el tercero valora las discrepancias en la distribución espacial del monto correctamente pronosticado. El parámetro k_2 , expresado en unidad de distancia (en este caso km), representa una escala espacial que distingue las distancias grandes de las pequeñas.

Los valores de k_1 y k_2 son estimados empíricamente de forma que los pesos resultantes sean lo suficientemente diferentes entre sí (para alejarse del caso

equiprobable), pero sin ser excesivamente grandes. Cuanto mayor sea el valor de k_1 , más uniformes son los pesos; en cambio, la dependencia de los resultados al parámetro k_2 es despreciable (dentro de rangos razonables). En función de los resultados obtenidos (ver Figura 6-7), el valor del parámetro k_1 se fijó en **0,1 mm** y el del parámetro k_2 en **50 km**.

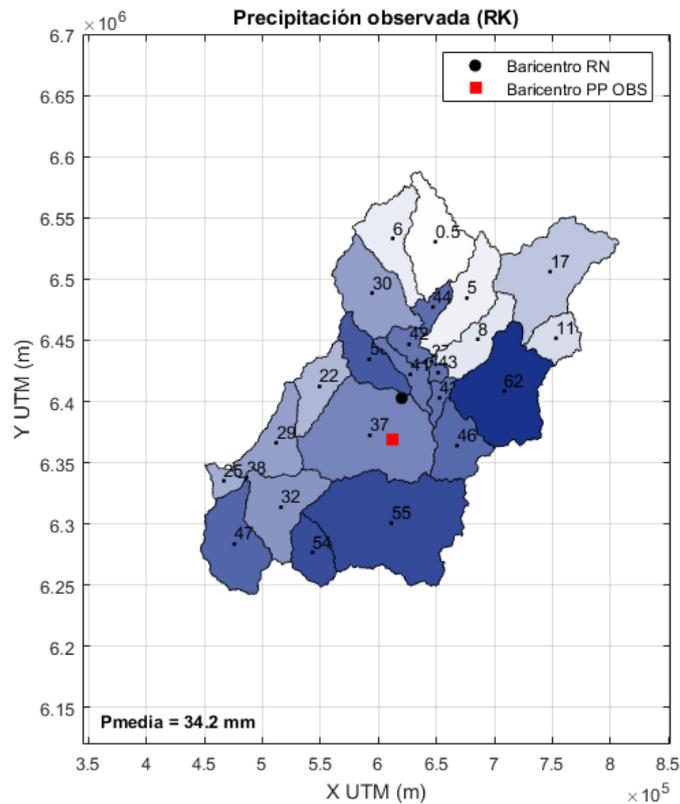


Figura 6-6: Mapa con la precipitación media areal observada en las 25 subcuencas del Río Negro, junto con la ubicación del baricentro ponderado por los montos para el 10/04/2021.

Asignación de pesos

Para cada ciclo de asimilación (t), el peso de cada miembro ($w^m(t)$) se define como el inverso de su distancia ($d(t)$) a la última observación disponible (estimación RK), dependiendo del “lag” es el paso de pronóstico que se considera en cada caso:

- **Lag-1:** Pesos según el primer paso del pronóstico iniciado en $t-1$ evaluado contra el Análisis más reciente: $X_1^{m,t-1}(t)$ versus $X_a(t)$, donde $X_k^{m,t_{ini}}(t)$ corresponde al pronóstico del miembro m para el paso k dentro del horizonte de pronóstico en la simulación iniciada en el tiempo t_{ini} , t refiere al paso de tiempo absoluto al que corresponde el pronóstico.
- **Lag-2:** Pesos según el segundo paso del pronóstico iniciado en $t-2$ evaluado contra el Análisis más reciente: $X_2^{m,t-2}(t)$ versus $X_a(t)$.
- **Lag-3:** Pesos según el segundo paso del pronóstico iniciado en $t-3$ evaluado contra el Análisis más reciente: $X_3^{m,t-3}(t)$ versus $X_a(t)$.

En el caso del ensamble **Lag-0** (última inicialización disponible), al no ser posible cuantificar la habilidad de cada miembro ya que en un escenario operativo el Análisis en t+1 aún no se conoce, se considera que todos los miembros del ensamble son equiprobables ($w^m(t) = 1/30$).

Una vez determinado el peso de cada miembro de cada TLE (Lag-1, Lag-2 y Lag-3), se lo normaliza ($w_{norm}^m(t)$) dividiendo entre la sumatoria del peso de todos los miembros para dicho ciclo (t):

$$w_{norm}^m(t) = \frac{w^m(t)}{\frac{1}{N} \sum_{m=1}^N w^m(t)}$$

donde N varía según el tamaño del ensamble o super-ensamble considerado.

Tanto la media del ensamble como el error y la dispersión del mismo, se calculan como el promedio ponderado de los miembros o el valor esperado del ensamble no equiprobable.

Con el propósito de ilustrar el rango de variación de los pesos así calculados, en la Figura 6-7 se presenta el valor del mayor peso asignado en cada ciclo de pronóstico para los ensambles Lag-1, Lag-2 y Lag-3 (compuestos por 30 miembros). A modo de referencia, en rojo se incluye el peso correspondiente al caso equiprobable (1/30).

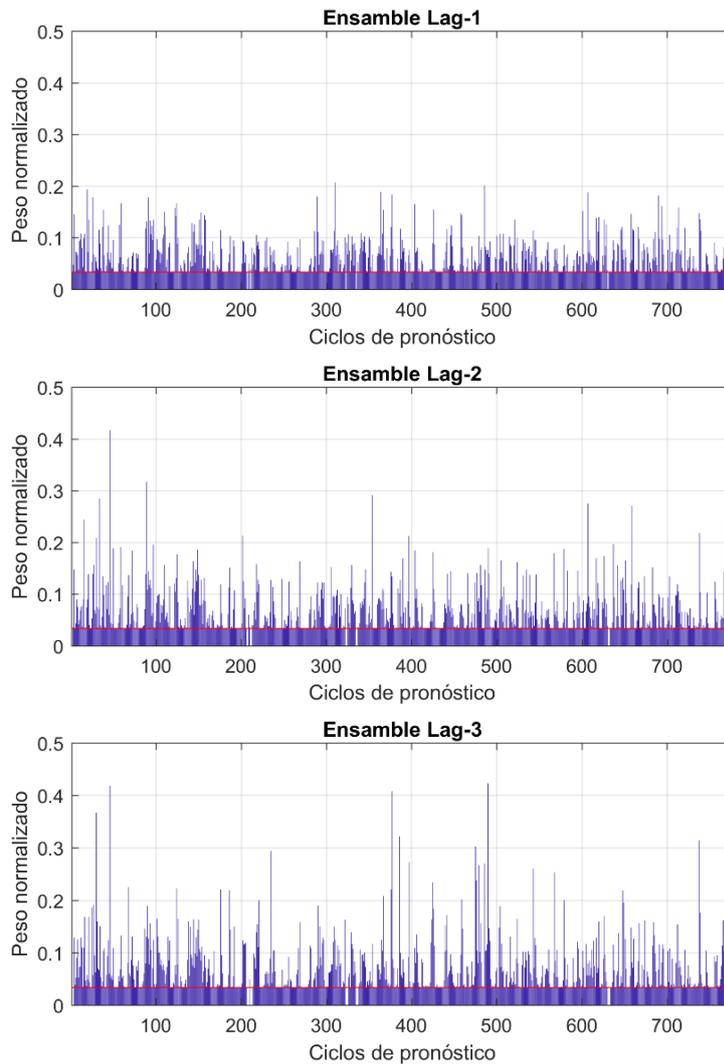


Figura 6-7: Valor del mayor peso asignado en cada ciclo de pronóstico para los TLE Lag-1, Lag-2 y Lag-3 (compuestos por 30 miembros).

Adicionalmente, a modo de ejemplo, en la Figura 6-8 se presenta la distribución de los pesos normalizados para cada miembro del ensemble Lag-1 en superposición con la precipitación (panel superior) y la distancia entre los baricentros ponderados por los montos (panel inferior) para un día lluvioso (con una precipitación media areal observada en la cuenca de 73 mm). En dicho ejemplo se observa que el miembro 1 es el que tiene asignado el mayor peso ($w^1 = 0,076$), ya que pronosticó una precipitación de 78 mm (muy próxima a la observada) con una distancia entre baricentros de 13 km. En segundo lugar, se ubica el miembro 3 ($w^3 = 0,054$) con una precipitación de 40,5 mm y una distancia entre baricentros menor a 2 km. En cambio, el menor peso corresponde al miembro 28 ($w^{28} = 0,022$) con un monto pronosticado de 34,7 mm y una distancia entre baricentros de 65 km (mayor distancia entre todos los miembros del ensemble).

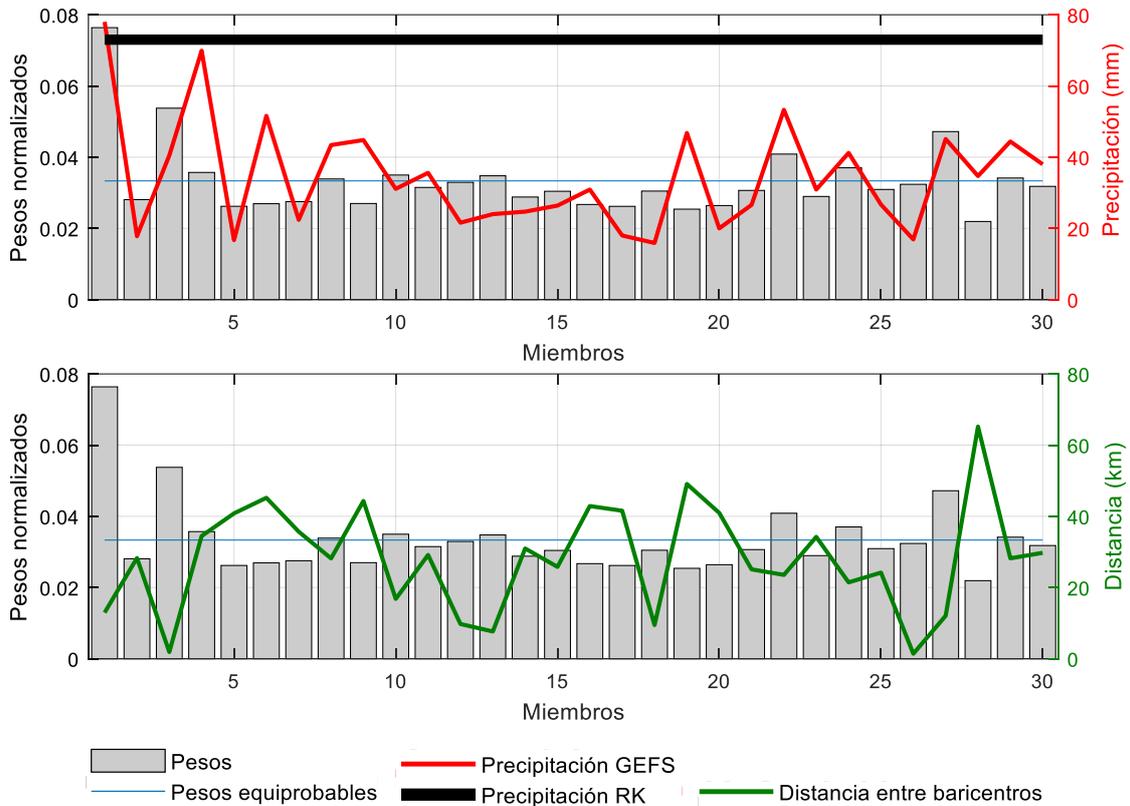


Figura 6-8: Ejemplo de la distribución de los pesos normalizados para cada miembro del ensamble Lag-1 en superposición con la precipitación (panel superior) y la distancia entre los baricentros ponderados por los montos (panel inferior) para un día lluvioso.

En la Figura 6-9 se muestran los mapas de la precipitación media areal por subcuenca del Río Negro junto con la ubicación del baricentro ponderado por los montos para el día del ejemplo anterior, para la precipitación observada (panel superior izquierdo) y la precipitación pronosticada por los miembros 1, 3 y 28 del ensamble Lag-1.

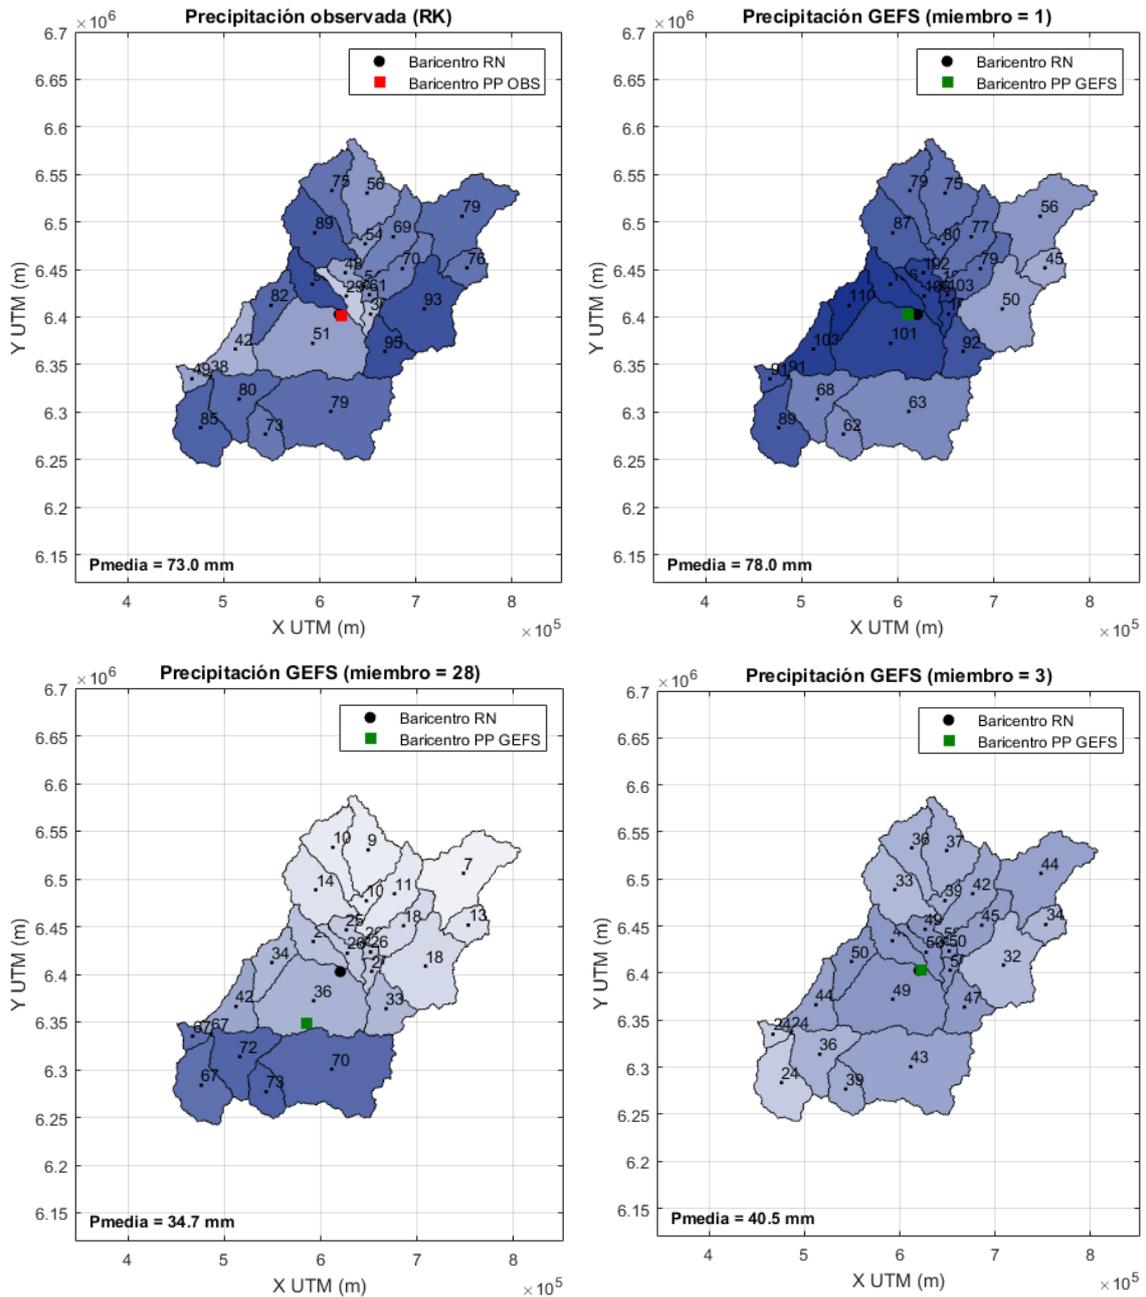


Figura 6-9: Mapas de la precipitación media areal por subcuenca y ubicación del baricentro ponderado por los montos para el día del ejemplo anterior para la precipitación observada (panel superior izquierdo) y la precipitación pronosticada por los miembros 1, 3 y 28 del ensamble Lag-1.

6.3.2 Resultados

A continuación, se presenta la evaluación del impacto de la incorporación de los pesos definidos según la metodología propuesta en función de la habilidad reciente de cada miembro. En particular, se presenta la comparación del desempeño del super-ensamble Lag-0-1-2-3 equiprobable y pesado.

En la Figura 6-10 se muestra el diagrama de dispersión del RMSE de la media del ensamble (panel izquierdo) y del cociente SPREAD/RMSE (panel derecho) a partir del super-ensamble equiprobable (eje x) versus el super-ensamble pesado (eje y) para un umbral de precipitación de 0 mm (un punto por horizonte de pronóstico k).

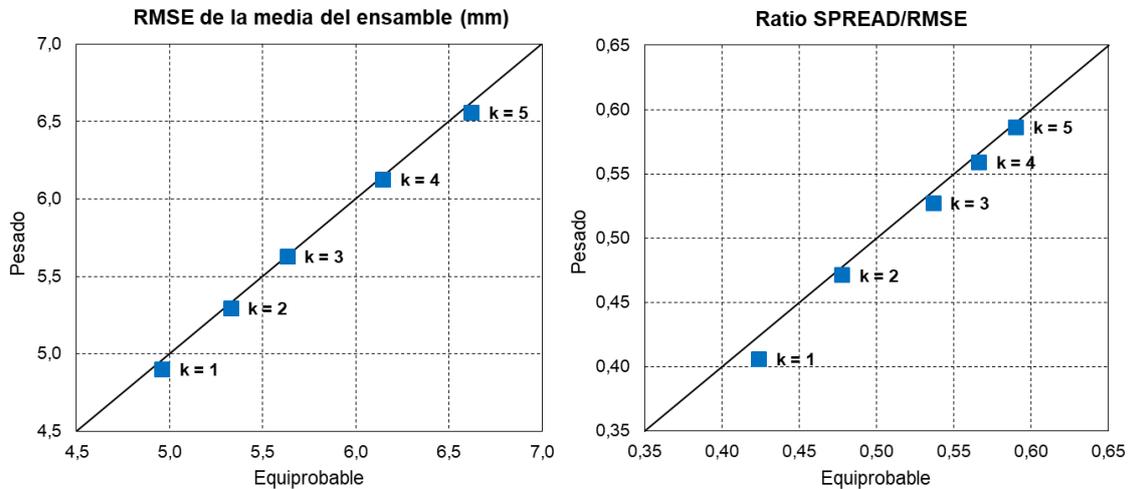


Figura 6-10: Diagrama de dispersión del RMSE de la media del ensamble (panel izquierdo) y del cociente SPREAD/RMSE (panel derecho) a partir del super-ensamble equiprobable versus el super-ensamble pesado para un umbral de precipitación de 0 mm (un punto por horizonte de pronóstico k).

De las figuras anteriores se desprende que con la incorporación de los pesos según la metodología propuesta no se identifica una mejora en los estadísticos evaluados (RMSE y dispersión del ensamble). El desempeño del super-ensamble pesado es comparable al del caso equiprobable, con lo cual por simplicidad no se justifica el empleo de los pesos así definidos.

Este resultado pone de manifiesto la importancia de la selección de una métrica más adecuada para el cálculo de la habilidad reciente para incluir en las ponderaciones de los miembros del ensamble.

6.4 SÍNTESIS

En este capítulo se busca sentar las bases de una metodología general para mejorar el desempeño del pronóstico por ensambles de precipitación del modelo GEFS (versión V12) en la cuenca del Río Negro. En particular, se busca mejorar la representación de la incertidumbre que enfrenta el sistema en el horizonte inmediato. Para ello se propuso una técnica de bajo costo computacional basada en la combinación de “time-lagged ensembles”, que incorpora las últimas observaciones (locales) disponibles a través de una ponderación simple de los miembros de cada ensamble en función de su habilidad reciente.

La técnica de “Time-Lagged Ensembles” (TLE) se basa en la generación de ensambles a partir de múltiples pronósticos inicializados en diferentes momentos, pero todos verificados al mismo tiempo. Dada la diferencia en la calidad de los miembros, se les suele asignar diferentes pesos en función de su “edad” y/o habilidad reciente. De esta manera, permite aprovechar la información de simulaciones y observaciones pasadas, a la vez que incorpora la última inicialización disponible. La principal ventaja es su bajo costo computacional.

En primer lugar, se realizó la evaluación del desempeño de los super-ensambles equiprobables (sin pesos diferenciales) que surgen de combinar el último pronóstico disponible (Lag-0) con los distintos TLE iniciados hasta tres días antes (Lag-1, Lag-2 y Lag-3). La metodología seguida para la evaluación es análoga a la desarrollada en el capítulo 3 e incluye la caracterización del error y la dispersión del ensamble y la construcción de los histogramas de análisis de rangos (Diagramas de Talagrand) a lo largo del horizonte de pronóstico (en este caso se analiza hasta $t+5$). El periodo analizado comprende noviembre de 2020 a diciembre de 2022 (777 ciclos de pronóstico). Para la evaluación se consideró una resolución temporal diaria y una agregación espacial en la cuenca “total” de aporte del Río Negro con cierre en Constitución. Los datos históricos empleados para evaluar los pronósticos de precipitación son las estimaciones RK en base a la combinación de imágenes satelitales y observaciones pluviométricas en superficie desarrolladas. De los resultados obtenidos se desprende que mediante la construcción de los super-ensambles equiprobables se logra una mejora en la distribución sin deteriorar el RMSE, lo que se traduce en una mejora del cociente SPREAD/RMSE. Esto sugiere que el enfoque TLE aporta información valiosa que va más allá de aumentar el tamaño del ensamble. Como era de esperar, a medida que avanza el horizonte de pronóstico, la inclusión de simulaciones asociadas a antelaciones cada vez más lejanas resulta en una degradación de la habilidad.

Posteriormente, se procedió a la incorporación de pesos diferenciales a través de una ponderación simple en función de la habilidad reciente de cada miembro y a la evaluación del desempeño del super-ensamble pesado resultante. Para medir la habilidad de los miembros se consideró únicamente el error en el campo de precipitación integrado en la cuenca del Río Negro (respecto de la última observación disponible), contemplando tanto el monto de precipitación como su dimensión espacial. Los pesos incorporados no distinguen a los TLE según su edad (“lag”), si no que se calculan exclusivamente en función de la habilidad de cada miembro respecto de la observación. Luego, para evaluar el impacto de la incorporación de los pesos así definidos, se comparó el desempeño del super-ensamble Lag-0-1-2-3 equiprobable y pesado (compuesto por 120 miembros). En función de los resultados obtenidos, se llegó a que con la incorporación de los pesos según la metodología propuesta no se alcanza una mejora en los estadísticos evaluados. El desempeño del super-ensamble pesado es comparable

al del caso equiprobable, con lo cual por simplicidad no se justifica el empleo de los pesos así definidos.

Este resultado pone de manifiesto la importancia de la selección de una métrica adecuada para el cálculo de la habilidad reciente para definir las ponderaciones de los miembros del ensamble. En este sentido, una potencial mejora a la metodología aquí propuesta sería considerar una métrica más integral y representativa del estado del sistema al inicio de la simulación como, por ejemplo, la energía total húmeda de la diferencia/perturbación integrada en un dominio regional (Hotta, 2014).

Otras alternativas de mejora podrían incluir: (i) la incorporación en el cálculo de la medida de la habilidad (para definir los pesos) de las observaciones pasadas en una ventana de longitud a definir y no considerar únicamente la última observación disponible; (ii) la construcción de TLE considerando un desfase temporal sub-diario, de manera de aprovechar los pronósticos más actuales disponibles cada seis horas; (iii) la construcción de un “gran ensamble” combinando el modelo GEFS con otros ensambles meteorológicos provenientes de diferentes modelos numéricos (con lo cual la ponderación de miembros asociados a un mismo “lag”, pero pertenecientes a distintos ensambles, podría aportar información más valiosa).

CAPÍTULO 7

CONCLUSIONES Y LÍNEAS FUTURAS DE TRABAJO

7. Conclusiones y líneas futuras de trabajo

La creciente incorporación de energías renovables en Uruguay (hidroeléctrica, eólica y solar) ha complejizado la operación y el despacho de energía eléctrica por su alto grado de incertidumbre meteorológica. La energía hidráulica, además de contribuir significativamente a la generación del país, es un recurso almacenable. Por esta razón la previsión de disponibilidad de agua en los embalses de las centrales hidroeléctricas es clave para la planificación del Sistema Interconectado Nacional (SIN), contribuyendo a optimizar el uso de cada fuente de energía, con el correspondiente beneficio económico y ambiental.

En este sentido, a lo largo de este trabajo de tesis se proponen diferentes desarrollos metodológicos buscando mejorar la calidad del pronóstico por ensambles de los aportes hidrológicos a las centrales del Río Negro, que se encuentra operativo en la Administración del Mercado Eléctrico (ADME) para informar el proceso de toma de decisión del despacho energético a mediano y corto plazo.

La estrategia seguida se basó en tres enfoques para cumplir con el objetivo planteado: (i) la evaluación de los pronósticos hidrometeorológicos por ensambles; (ii) la asimilación de datos observados de caudal; (iii) la representación de la incertidumbre asociada a los pronósticos por ensambles de precipitación.

Evaluación de los pronósticos hidrometeorológicos por ensambles

Se desarrolló una metodología para la evaluación de la calidad de los pronósticos por ensambles de precipitación y caudal generados desde la puesta en operación del modelo. Dicha metodología se basa en la recomendación de emplear una combinación de indicadores de desempeño y gráficos de diagnóstico, de manera de abarcar diferentes aspectos de la calidad del pronóstico, en este caso el sesgo, la precisión y la confiabilidad.

La metodología desarrollada se aplicó tanto a los pronósticos por ensambles de precipitación del modelo GEFS (versión V12) del NCEP-NOAA en la cuenca del Río Negro (empleados como forzantes del modelo hidrológico), como a los ensambles de caudales de aporte a las centrales hidroeléctricas obtenidos a partir del modelo hidrológico alimentado por los pronósticos del GEFS. En ambos casos se llegó a que las series simuladas capturan satisfactoriamente el comportamiento de las series observadas. Como era de esperar, a medida que se avanza en el horizonte de pronóstico, aumenta el error y la dispersión de los miembros del ensamble, es decir que disminuye la predictibilidad del sistema. Tanto para los pronósticos por ensambles de precipitación como los de caudales, se

identificaron sesgos positivos en el error de la media del ensamble (tendencia a la sobreestimación), a la vez que se observó una asimetría negativa en su distribución. Durante los primeros días del horizonte de pronóstico el ensamble tiene una dispersión excesivamente baja, la observación está demasiado a menudo fuera del rango del ensamble. Luego, a medida que avanza el horizonte de pronóstico, el ensamble tiende a estar mejor distribuido. Este aspecto es aún más notorio en el caso de los caudales de aporte, en el cual la dispersión del ensamble es muy pequeña hasta el día 5 de pronóstico. Los resultados obtenidos evidencian la necesidad de la asimilación de datos de caudal observados, ya que se tienen ciclos de pronóstico en los que el error inicial supera el $\pm 100\%$ del caudal teórico.

En relación a la exploración de comportamientos bimodales en la distribución de precipitación de los miembros del ensamble, se identificó una notoria diferencia entre los ciclos unimodales y bimodales. Esto sugiere que evaluar diferentes metodologías y/o procesamientos para los ciclos de pronóstico en función de la bimodalidad del ensamble de precipitación podría mejorar el desempeño del pronóstico, ya que en el cálculo del coeficiente de bimodalidad sólo participa el ensamble y no la observación (por lo que puede calcularse “a priori”).

Entre los posibles pasos a desarrollar en el futuro, en particular asociados al esquema considerado para la modelación hidrológica, se propone:

- Discretización de la cuenca del río Yí (subcuenca ID 12 con una extensión superficial de 9.000 km²) en al menos dos subcuencas incrementales e implementación del tránsito hidrológico en dicha cuenca mediante el método de Muskingum.
- Evaluación de otras alternativas para el modelo conceptual de lluvia-escorrentía, en particular buscando mejorar la representación de los caudales bajos y la memoria de largo plazo del sistema (sin perder habilidad en los caudales pico). En este sentido: (i) el modelo GR5J incorpora un parámetro adicional para considerar intercambios de agua más complejos entre cuencas (Le Moine, 2008); (ii) el modelo GR6J introduce un nuevo reservorio de tránsito en paralelo (Pushpalatha et al., 2011).

Asimilación de datos observados de caudal

Se propuso una metodología para la asimilación al modelo hidrológico de datos observados de caudal, la cual puede ser implementada de manera operativa con la información disponible actualmente. Dicha metodología se aleja conceptualmente de los diseños tradicionales de relajación o “nudging” de datos observados a sistemas de pronóstico. En el caso de estudio, la variable observada disponible no es un estado sino una salida del modelo (caudal), por lo que no puede ser ajustada directamente. Por tanto, en la asimilación que se instrumentó

el ajuste se plantea como una corrección de la precipitación antecedente (forzante que representa la mayor fuente de incertidumbre del proceso de modelación) hasta el día de inicio del pronóstico, proporcional a la amplitud del error relativo del caudal simulado. Dicha corrección produce estados del sistema y caudales hidrológicamente consistentes. En particular, el ajuste se implementó en tres subcuencas de aporte al embalse de G. Terra: la cuenca alta del Río Negro, la cuenca de aporte del río Tacuarembó y la cuenca incremental de aporte al embalse de G. Terra.

La metodología de asimilación propuesta reduce significativamente el error al inicio del pronóstico, en comparación con el desempeño del modelo hidrológico sin retroalimentación. Sin embargo, para caudales bajos (muy frecuentes en el periodo analizado), no logra corregir el marcado sesgo positivo (sobrestimación) existente en el modelo original. El desempeño es muy sensible a los “saltos” y limitaciones particulares identificadas en la serie teórica de aportes a G. Terra. La mejora se atenúa a medida que se avanza en el horizonte de pronóstico.

Como próximo paso en esta línea se plantea la implementación operativa en ADME de la metodología de asimilación de datos de caudal propuesta en la cuenca de aporte al embalse de G. Terra, así como la extensión de dicha metodología a otras subcuencas del Río Negro, por ejemplo: la cuenca del arroyo Salsipuedes Grande con cierre en la estación Salsipuedes (subcuenca de aporte a Baygorria), la cuenca del arroyo Grande con cierre en la estación Paso de Lugo (subcuenca de aporte a Constitución), la cuenca del río Yí con cierre en la ciudad de Durazno (subcuenca de aporte a Constitución).

A la vez, se identifican los siguientes aspectos en los que es de interés continuar trabajando en el futuro:

- Análisis y corrección de componentes del balance de masa en los embalses de las centrales hidroeléctricas del Río Negro, para mejorar la estimación de los caudales diarios de aporte teóricos. Dicho análisis debería de incluir la revisión de las distintas hipótesis consideradas en el balance hídrico, las estimaciones de los caudales erogados por vertido y turbinado, el efecto del viento en la superficie de los embalses, la incertidumbre en las mediciones, etc. Algunos de estos aspectos fueron explorados en Morquio (2022) para el embalse de G. Terra en el marco de la “Iniciativa del Río Negro para la mejora de la calidad de agua en la cuenca”.
- Exploración de metodologías de asimilación más complejas como, por ejemplo, el método de Filtro de Kalman por ensambles (EnKF). Para ello, además de la propia instrumentación computacional del método, se requiere avanzar en la estimación de la incertidumbre asociada a los forzantes meteorológicos, los parámetros y estados del modelo, y especialmente a las observaciones disponibles. No es recomendable dar este paso antes del anterior, pues la versión actualmente disponible del

caudal teórico tiene propiedades estadísticas no adecuadas. Un ejemplo detallado de los pasos a seguir para la implementación del método EnKF en un modelo hidrológico conceptual concentrado (modelo GR5J) se presenta en Piazzini et al. (2021).

- Implementación y evaluación de la asimilación de información satelital de humedad de suelo en el modelo hidrológico. Esta variable, de gran peso en los procesos del ciclo hidrológico, es de compleja determinación a gran escala espacial con los instrumentos tradicionales de medición in situ debido a que toman medidas puntuales en un campo con una estructura espacial compleja a pequeña escala. En las últimas décadas el desarrollo tecnológico ha permitido cuantificar de manera correcta la humedad en los primeros centímetros del suelo a través de sensoramiento remoto con sensores de microondas. Como antecedente a nivel local, se cuenta con el trabajo realizado por Narbondo (2021) sobre la incorporación de información satelital de humedad de suelo en modelos hidrológicos para pronóstico de inundaciones en la cuenca del río Yí.

Representación de la incertidumbre asociada a los pronósticos de precipitación

Se propuso una técnica simple e implementable sin recursos adicionales para mejorar el desempeño del pronóstico por ensambles de precipitación del modelo GEFS en la cuenca del Río Negro. En particular, con el propósito de mejorar la representación de la incertidumbre que enfrenta el sistema en el horizonte inmediato; de la evaluación surge que durante los primeros días de pronóstico la dispersión del ensamble es excesivamente baja, en comparación con el error medio del mismo.

En este sentido, a los efectos de explorar metodologías en un modelo más simple que los atmosféricos, se recurrió al modelo Lorenz 63 con asimilación de datos mediante el método EnKF. Allí se evaluaron dos técnicas para la ponderación de miembros del ensamble según su desempeño reciente: (i) selección del “mejor” sub-ensamble mediante la técnica de Cluster Analysis (k-means); (ii) construcción de un ensamble no equiprobable o “pesado”, asignando el peso de cada miembro según el inverso de la distancia al Análisis. Ambas metodologías se aplicaron a distintos ciclos de pronóstico bajo dos esquemas, que dependen de las características del sistema de asimilación: el esquema “time-lagged ensembles” (TLE) y el de “cambio de ciclo”. De los resultados obtenidos se desprende que, en una nueva inicialización o paso de asimilación del modelo de Lorenz 63, la construcción de ensambles modificados según el desempeño de cada miembro en el período inmediato anterior puede ofrecer información más útil a sistemas de decisión sensibles no sólo a la media del pronóstico, sino también a la dispersión del mismo a través de estadísticos como el error medio u otros. La magnitud y horizonte de la mejora dependen del estado del sistema en cada ciclo particular de pronóstico. En particular, la metodología de ponderación

de miembros mediante la construcción de un ensamble no equiprobable presentó un mejor desempeño que la del agrupamiento en el “mejor” sub-ensamble.

En vistas a los resultados obtenidos con el modelo Lorenz 63, se desarrolló luego una metodología de TLE basada en la construcción de super-ensambles a partir de múltiples pronósticos de precipitación inicializados en diferentes momentos, pero todos verificados al mismo tiempo.

En primer lugar, se evaluó el desempeño de los super-ensambles equiprobables (sin pesos diferenciales) que surgen de combinar los distintos TLE de precipitación del modelo GEFS en la cuenca del Río Negro considerando antelaciones (lags) de hasta tres días (Lag-0, Lag-1, Lag-2 y Lag-3). Si bien el modelo GEFS se ejecuta cuatro veces al día, se consideró un desfase temporal diario entre los sucesivos pronósticos (simulaciones iniciadas a las 00UTC). La construcción de los super-ensambles equiprobables logra una mejora en la distribución sin deteriorar el RMSE (incluso con mejoras marginales), lo que se traduce en una mejora del cociente SPREAD/RMSE (en comparación con el desempeño del ensamble de la última inicialización disponible, Lag-0). Esto sugiere que el enfoque TLE aporta información valiosa que va más allá de aumentar el tamaño del ensamble. Como era de esperar, a medida que avanza el horizonte de pronóstico, la inclusión de simulaciones asociadas a antelaciones cada vez más lejanas resulta en una degradación de la habilidad.

Posteriormente, se procedió a la incorporación de pesos diferenciales a través de una ponderación simple en función de la habilidad reciente de cada miembro y a la evaluación del desempeño del super-ensamble pesado resultante. Para medir la habilidad de los miembros se consideró únicamente el error en el campo de precipitación integrado en la cuenca del Río Negro (respecto de la última observación disponible), contemplando tanto el monto de precipitación como su dimensión espacial. Los pesos incorporados no distinguen a los TLE según su edad (“lag”), se calculan exclusivamente en función de la habilidad de cada miembro respecto de la observación. A partir de los resultados obtenidos, se llegó a que la incorporación de los pesos según la metodología propuesta no resulta en una mejora en los estadísticos evaluados. El desempeño del super-ensamble pesado es comparable al del caso equiprobable, con lo cual por simplicidad no se justifica el empleo de los pesos así definidos. Este resultado pone de manifiesto la importancia de la selección de una métrica adecuada para el cálculo de la habilidad reciente para definir las ponderaciones de los miembros del ensamble.

Considerando el potencial de la metodología desarrollada y teniendo en cuenta las principales limitaciones a superar, a continuación se enumeran algunas de las posibles líneas de trabajo a desarrollar en el futuro:

- Incorporación en el cálculo de la medida de la habilidad (para definir los pesos de los miembros del ensamble) de las observaciones pasadas en una

ventana de longitud a definir y no considerar únicamente la última observación disponible.

- Construcción de TLE considerando un desfase temporal sub-diario (cada seis horas), de manera de aprovechar los pronósticos más actuales disponibles. También los pluviómetros automáticos y las estimaciones satelitales pueden proveer campos de precipitación sub-diaria.
- Ponderación de los miembros del ensamble en función de su habilidad reciente considerando una métrica más integral y representativa del estado atmosférico al inicio de la simulación como, por ejemplo, la energía total húmeda de la diferencia/perturbación integrada en un dominio regional (Hotta, 2014).
- Evaluación de otros pronósticos por ensambles de precipitación provenientes de diferentes modelos numéricos (ECMWF, ICON, etc.) y construcción de un “gran ensamble” mediante la combinación con el modelo GEFS, incluyendo la ponderación de los miembros en función de su habilidad reciente.
- Identificación de comportamientos bimodales (o multi-modales) en la distribución de precipitación de los miembros del ensamble y propuesta de una metodología de ponderación de los miembros condicionada a la bimodalidad. Esto puede ser particularmente pertinente cuando los miembros (provenientes de un mismo modelo o, con más razón, de distintos modelos numéricos), difieren en el pronóstico.

Finalmente, se destaca que las metodologías desarrolladas en este trabajo de tesis demostraron su capacidad para mejorar algún aspecto del pronóstico por ensambles de los aportes hidrológicos a las centrales del Río Negro. En todos los casos, los desarrollos propuestos son pasibles de ser incorporados fácilmente en las herramientas de simulación del sistema eléctrico de Uruguay.

Si bien es de esperar que dichas mejoras se traduzcan en un agregado de “valor” al sistema de pronóstico, está aún pendiente la evaluación cuantitativa del impacto de la incorporación de los pronósticos hidrológicos en el proceso de toma de decisión del despacho energético. Para ello se requiere de plazos prolongados de evaluación, que integren sobre un conjunto representativo de situaciones hidrológicas y energéticas.

CAPÍTULO 8

REFERENCIAS BIBLIOGRÁFICAS

8. Referencias bibliográficas

- ADME (2022). Informe Anual 2021. Administración del Mercado Eléctrico, Uruguay. https://www.adme.com.uy/db-docs/Docs_secciones/nid_526/Informe_Anual_2021.pdf
- Alfaro P. (2022). Implantación de modelos de incorporación de datos satelitales para la mejora de la estimación de la precipitación efectivamente ocurrida en la cuenca del Río Negro. Segunda etapa de consultoría ADME. Informe final. Agosto de 2022.
- Alvarado-Montero R., Talsma J., Zamanillo E., Failache N., Badagian J. (2018). Implementación y evaluación de pronósticos hidrológicos probabilísticos para Salto Grande. *XXVIII Congreso Latinoamericano de Hidráulica*, IAHR, Buenos Aires, Argentina.
- Aubert D., Loumagne C., Oudin L. (2003). Sequential assimilation of soil moisture and streamflow data in a conceptual rainfall runoff model. *J. Hydrol.*, **280**, 145–161. DOI: [https://doi.org/10.1016/S0022-1694\(03\)00229-4](https://doi.org/10.1016/S0022-1694(03)00229-4)
- Anctil F., Ramos MH. (2019). Verification Metrics for Hydrological Ensemble Forecasts. In: Duan Q., Pappenberger F., Wood A., Cloke H., Schaake J. (eds) *Handbook of Hydrometeorological Ensemble Forecasting*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-39925-1_3
- Bárdossy A., Das T. (2008) Influence of rainfall observation network on model calibration and application. *Hydrol. Earth Syst. Sci.*, **12**, 77–89, <https://doi.org/10.5194/hess-12-77-2008>
- Bellier J., Bontron G., Zin I. (2021). Selecting components in a probabilistic hydrological forecasting chain: the benefits of an integrated evaluation, *LHB*, 107:1. <https://doi.org/10.1080/27678490.2021.1936825>
- Ben Bouallègue Z., Theis S., Gebhardt Ch. (2013). Enhancing COSMO-DE ensemble forecasts by inexpensive techniques. *Meteorologische Zeitschrift*, **22**, 49-59. <http://doi.org/10.1127/0941-2948/2013/0374>
- Bennett N.D., Croke B.F.W., Guariso G., Guillaume J.H.A., Hamilton S.H., Jakeman A.J., ... Andreassian V. (2013). Characterising performance of environmental models. *Environmental modelling & software*, **40**, 1-20. DOI: <https://doi.org/10.1016/j.envsoft.2012.09.011>
- Boucher M.A., Ramos M.H. (2018). Ensemble Streamflow Forecasts for Hydropower Systems. In: Duan, Q., Pappenberger, F., Thielen, J., Wood, A., Cloke, H., Schaake, J. (eds) *Handbook of Hydrometeorological Ensemble Forecasting*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-40457-3_54-1

- Bradley A.A., Demargne J., Franz K.J. (2019). Attributes of Forecast Quality. In: Duan Q., Pappenberger F., Wood A., Cloke H., Schaake J. (eds) Handbook of Hydrometeorological Ensemble Forecasting. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-39925-1_2
- Brankovic C., Palmer T.N., Molteni F., Tibaldi S., Cubasch U. (1990). Extended-range predictions with ECMWF models: time-lagged ensemble forecasting. *Quarterly Journal of the Royal Meteorological Society*, **116**(494), 867–912. <https://doi.org/10.1002/qj.49711649405>
- Brocca L., Melone, F., Moramarco, T., Wagner, W., Naeimi, V., Bartalis, Z., Hasenauer, S. (2010). Improving runoff prediction through the assimilation of the ASCAT soil moisture product. *Hydrology and Earth System Sciences*, **14**, 1881–1893. <https://doi.org/10.5194/hess-14-1881-2010>
- Buizza R., Du J., Toth Z., Hou D. (2019). Major Operational Ensemble Prediction Systems (EPS) and the Future of EPS. In: Duan Q., Pappenberger F., Wood A., Cloke H., Schaake J. (eds). Handbook of Hydrometeorological Ensemble Forecasting. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-39925-1_14
- Burnash R.J.C., Ferral R.L., McGuire R.A. (1973). *A generalized streamflow simulation system: Conceptual modeling for digital computers*. Jt. Fed. and State River Forecast Cent., U.S. Natl. Weather Serv. and Calif. Dep. of Water Resour., Sacramento.
- Carrassi A., Bocquet M., Bertino L., Evensen G. (2018). Data assimilation in the geosciences: An overview of methods, issues, and perspectives. *WIREs Clim Change*. 9:e535. <https://doi.org/10.1002/wcc.535>
- Casanova S., Ahrens B. (2009). On the weighting of multimodel ensembles in seasonal and short-range weather forecasting. *Mon. Wea. Rev.*, **137**(11), 3811–3822. <https://doi.org/10.1175/2009MWR2893.1>
- Casaravilla G., Chaer R., Alfaro P. (2008). SimSEE - Simulador de Sistemas de Energía Eléctrica, Proyecto PDT 47/12, Universidad de la República, Facultad de Ingeniería, Instituto de Ingeniería Eléctrica. <https://hdl.handle.net/20.500.12008/36746>
- Chaer R. (2005). Modelo de series correlacionadas CEGH. Disponible en: https://simsee.org/simsee/curso2013/Cap9_sintetizadorCEGH.pdf
- Chaer R. (2008). Simulación de sistemas de energía eléctrica. Tesis de maestría en Ingeniería Eléctrica, UdelaR, FI. Uruguay. Disponible en: <https://www.colibri.udelar.edu.uy/jspui/handle/20.500.12008/2877>
- Chen M., Wang W., Kumar A. (2013). Lagged Ensembles, Forecast Configuration, and Seasonal Predictions. *Mon. Wea. Rev.*, **141**, 3477–3497, <https://doi.org/10.1175/MWR-D-12-00184.1>

- Chilès J.P., Delfiner P. (2012). *Geostatistics: Modeling Spatial Uncertainty*. Second Edition, No. 2009. John Wiley & Sons, Inc.
- Chow V.T., Maidment D.R., Mays L.W. (1994). "Hidrología Aplicada". McGraw-Hill. ISBN: 958-600-171-7.
- Climate Data Tools (CDT-IRI). <https://iri.columbia.edu/our-expertise/climate/tools/cdt/>.
- Collischonn W., Allasia D.G, Silva B.C., Tucci C.E.M. (2007). The MGB-IPH model for large scale rainfall-runoff modeling. *Hydrol. Sci. J.*, **52**, 878–895. <https://doi.org/10.1623/hysj.52.5.878>
- Cressman G.P. (1959). An operational objective analysis system. *Mon. Wea. Rev.*, **87**, 367-374.
- Crisci M., Terra R. (2014). Valorization of Irrigation Water in A Basin with Large Hydropower Production through Coupled Hydrological and Electric System Modelling. *Water Resour Manage*, **28**, 605–623. <https://doi.org/10.1007/s11269-013-0497-7>
- Cuo L., Pagano T., Wang Q. (2011). A review of quantitative precipitation forecasts and their use in short -to medium- range streamflow forecasting. *J. Hydrometeor.* Vol. 12, p.: 713-728. <https://doi.org/10.1175/2011JHM1347.1>
- Daron J.D., Stainforth D.A. (2015). On quantifying the climate of the nonautonomous Lorenz-63 model. *Chaos* **25**, 043103. <https://doi.org/10.1063/1.4916789>
- Day G. (1985). Extended streamflow forecasting using NWSRFS. *J. Water Resour. Plan. Manag.* **111**(2), 157–170; [https://doi.org/10.1061/\(ASCE\)0733-9496\(1985\)111:2\(157\)](https://doi.org/10.1061/(ASCE)0733-9496(1985)111:2(157))
- DelSole T., Yang X., Tippett M.K. (2013). Is unequal weighting significantly better than equal weighting for multi-model forecasting? *Quarterly Journal of the Royal Meteorological Society*, **139**, 176–183. <https://doi.org/10.1002/qj.1961>
- DelSole T., Trenary L., Tippett M.K. (2017). The weighted-average lagged ensemble. *Journal of Advances in Modeling Earth Systems*, **9**, 2739–2752. <https://doi.org/10.1002/2017MS001128>
- Desaint B., Nogues P., Perret C., Garçon R. (2009). La prévision hydrométéorologique opérationnelle: l'expérience d'Electricité de France. *La Houille Blanche* **5**, 39–46.
- DINAGUA (2012). Ciclos anuales y estacionales de parámetros hidrológicos (1980-2004). Informe temático de la División Recursos Hídricos, Departamento de Hidrología, Dirección Nacional de Aguas, MVOTMA, Uruguay.

- De Lannoy G.J.M., Reichle R.H., Houser P.R., Arsenault K.R., Verhoest N.E.C., Pauwels V.R.N. (2010). Satellite-Scale Snow Water Equivalent Assimilation into a High-Resolution Land Surface Model. *J. Hydrometeorol.*, **11**, 352–369. <https://doi.org/10.1175/2009JHM1192.1>
- De Vera A., Flieller G., Crisci M., Chaer R., Terra R. (2020). Integración de ensambles de pronósticos hidrológicos a las herramientas de operación del sistema eléctrico en Uruguay. *ENERLAC*, **IV**(1), 96-117. ISBN digital: 2631-2522. Available online: <http://enerlac.olade.org/index.php/ENERLAC/article/view/122/147>
- De Vera A., Alfaro P., Terra R. (2021). Operational Implementation of Satellite-Rain Gauge Data Merging for Hydrological Modeling. *Water* 2021, **13**, 533. <https://doi.org/10.3390/w13040533>
- De Vera A., Flieller G., Chaer R., Terra R. (2022). Evaluación de un sistema operativo de pronósticos hidrológicos por ensambles para la gestión del sistema eléctrico en Uruguay. *Ribagua*, **9**:1, 10-24. <https://doi.org/10.1080/23863781.2023.2213843>
- Du J., Zhou B. (2017). Ensemble fog prediction. In the Book of "Marine Fog: Challenges and Advancements in Observations, Modeling, and Forecasting" (eds. by D. Koracin and C. E. Dorman). Springer, 477-509. <https://doi.org/10.1007/978-3-319-45229-6>
- Du J., Berner J., Buizza R., Charron M., Houtekamer P., Hou D., Isidora J., Mu M., Wang X., Wei M., Yuan H. (2018). Ensemble methods for meteorological predictions. NCEP Office Note 493, National Centers for Environmental Prediction (U.S.). <http://doi.org/10.7289/V5/ON-NCEP-493>
- Durán A., Califra. A., Molfino J.H (1999). Suelos del Uruguay según Soil Taxonomy.
- Epstein E.S. (1969). Stochastic dynamic prediction. *Tellus*, **21**: 739-759. <https://doi.org/10.1111/j.2153-3490.1969.tb00483.x>
- Evans E., Bhatti N., Kinney J., Pann L., Peña M., Yang S. C., ... & Hansen, J. (2004). RISE undergraduates find that regime changes in Lorenz's model are predictable. *Bulletin of the American Meteorological Society*, **85**(4), 520-524. <https://doi.org/10.1175/BAMS-85-4-520>
- Evensen G. (2009). Data assimilation. The ensemble Kalman filter. Second Edition. Springer, pp 307.
- Fan F.M., Paiva R.C.D., Collischonn W. (2016). Chapter 2: Hydrological forecasting practices in Brazil, in *Flood Forecasting – A Global Perspective*, ed. by T. E. Adams III, T. C. Pagano, 433 p. ISBN: 978-0-12-801884-2.
- Flieller G., Chaer R. (2020). Introduction of ensemble based forecasts to the electricity dispatch simulator SimSEE. Proceedings of the IEEE Power &

Energy Society T&D – Latin America, Montevideo, Uruguay, October 2020; vp 18.4.

- Hamill T.M., Snyder C. (2000). A hybrid ensemble Kalman filter-3D variational analysis scheme. *Mon. Wea. Rev.*, **128**, 2905-2919.
- He Y., Wetterhall F., Cloke H., Pappenberger F., Wilson M., Freer J., McGregor G. (2009). Tracking the uncertainty in flood alerts driven by grand ensemble weather predictions. *Meteorological Applications*, **16**(1), 91–101. <https://doi.org/10.1002/met.132>
- Hengl T. (2009). A Practical Guide to Geostatistical Mapping. 2nd Edition. University of Amsterdam. ISBN: 978-90-9024981-0.
- Hoffman R.N., Kalnay E. (1983). Lagged average forecasting, an alternative to Monte Carlo forecasting. *Tellus*, **35A**, 100-118. <https://doi.org/10.1111/j.1600-0870.1983.tb00189.x>
- Hoke J., Anthes R. (1976). The initialization of numerical models by a dynamic relaxation technique. *Mon. Wea. Rev.*, **104**, 1551-1556.
- Hong Y. et al. (2019). Remote Sensing Precipitation: Sensors, Retrievals, Validations, and Applications. In: Li X., Vereecken H. (eds). Observation and Measurement of Ecohydrological Processes. *Ecohydrology*, Vol 2. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-662-48297-1_4
- Hotta D. (2014). Proactive Quality Control based on Ensemble Forecast Sensitivity to Observations. Ph.D. Thesis. Faculty of the Graduate School of the University of Maryland, College Park. <https://doi.org/10.13016/M23W3P>
- Huang Z. & Zhao T. (2022). Predictive performance of ensemble hydroclimatic forecasts: Verification metrics, diagnostic plots and forecast attributes. *Wiley Interdisciplinary Reviews: Water*, e1580. <https://doi.org/10.1002/wat2.1580>
- Hunt B., Kostelich E., Szunyogh I. (2007). Efficient data assimilation for spatiotemporal chaos: A local ensemble transform Kalman filter. *Physica D: Nonlinear Phenomena*. **230** (1): 112-126. <https://doi.org/10.1016/j.physd.2006.11.008>.
- IMFIA-IRN (2022). Modelación hidro-sedimentológica y de calidad de agua del embalse de Rincón del Bonete. Informe Final, Parte II: Modelación hidrodinámica. Convenio de cooperación MA-DINACEA, FIS y FJR-IMFIA-FING-UdelaR. Iniciativa del Río Negro (IRN) para la mejora de la calidad de agua de la Cuenca del Río Negro. Disponible en: https://www.ambiente.gub.uy/oan/documentos/IRN_IMFIA_Informe_Final_Parte2_ENVIADO_20221223.pdf

- Jie W., Wu T., Wang J. et al. (2014). Improvement of 6–15 day precipitation forecasts using a time-lagged ensemble method. *Adv. Atmos. Sci.* **31**, 293–304. <https://doi.org/10.1007/s00376-013-3037-8>
- Jiménez K.Q., Collischonn W., Paiva R.C.D. (2019). Data assimilation using the ensemble Kalman filter in a distributed hydrological model on the Tocantins River, Brasil. *RBRH*, **24**, e14. <https://doi.org/10.1590/2318-0331.241920180031>
- Kalnay E. (2003). Atmospheric modelling, data assimilation and predictability. Cambridge University Press. <https://doi.org/10.1017/CBO9780511802270>
- Lahoz W.A., Khatatov B., Ménard R. (eds.). (2010). Data Assimilation: making sense of observations. Springer. pp. 718, ISBN 978-3-540-74702-4. <https://doi.org/10.1007/978-3-540-74703-1>
- Larrosa D., Casaravilla G., Chaer R. (2012). Evaluation of contractual arrangement of new energy sources for generation expansion in Uruguay and its impact on the risk matrix of the utility costs. In: Transmission and distribution: Latin America Conference and Exposition, IEEE. pp 1–3.
- Lawrence A., Hansen J.A. (2007). A transformed lagged ensemble forecasting technique for increasing ensemble size. *Mon. Weather Rev.*, **135**: 1424–1438. <https://doi.org/10.1175/MWR3357.1>
- Le Moine N. (2008). Le bassin versant de surface vu par le souterrain: une voie d'amélioration des performances et du réalisme des modèles pluie-débit? (The catchment seen from underground: a direction to improve the performance and realism of rainfall-runoff models?). Ph.D. thesis. UPMC, Paris, France. Disponible en: https://webgr.irstea.fr/wp-content/uploads/2012/07/2008-LE_MOINE-THESE.pdf
- Li Y., Ryu D., Western A.W., Wang Q.J. (2015). Assimilation of stream discharge for flood forecasting: Updating a semidistributed model with an integrated data assimilation scheme. *Water Resour. Res.*, **51**, 3238–3258. <https://doi.org/10.1002/2014WR016667>
- Li B., Rodell M., Kumar S., Beaudoin H.K., Getirana A., Zaitchik B.F., de Goncalves L.G., Cossetin C., Bhanja S., Mukherjee A., et al. (2019). Global GRACE Data Assimilation for Groundwater and Drought Monitoring: Advances and Challenges. *Water Resour. Res.*, **55**, 7564–7586. <https://doi.org/10.1029/2018WR024618>
- Lindström G., Johannson B., Persson M., Gardelin M., Bergström S. (1997). Development and test of the distributed HBV-96 hydrological model. *Journal of Hydrology*, **201**, 272–288. [https://doi.org/10.1016/S0022-1694\(97\)00041-3](https://doi.org/10.1016/S0022-1694(97)00041-3)

- Lorenz E.N. (1963). "Deterministic nonperiodic flow," *J. Atmos. Sci.* **20**, 130–141. [https://doi.org/10.1175/1520-0469\(1963\)020<0130:DNF>2.0.CO;2](https://doi.org/10.1175/1520-0469(1963)020<0130:DNF>2.0.CO;2)
- Lu C., Yuan H., Schwartz B.E., Benjamin S.G. (2007). Short-range numerical weather prediction using time-lagged ensembles. *Weather and Forecasting*, **22**(3), 580–595. <https://doi.org/10.1175/WAF999.1>
- Maciel F., Terra R., Díaz A. (2012). Incorporación de información climática en la simulación de aportes a represas en un modelo del sistema eléctrico. *Memorias del XXV Congreso Latinoamericano de Hidráulica*, San José, Costa Rica. ISBN: 978-9968-933-06-3.
- Maciel F., Terra R., Chaer R. (2015). Economic impact of considering El Niño-Southern Oscillation on the representation of streamflow in an electric system simulator. *Int. J. Climatol.*, **35**, 4094-4102. <https://doi.org/10.1002/joc.4269>
- Mazzoleni M., Noh S.J., Lee H., Liu Y., Seo D-J, Amaranto A., Alfonso L, Solomatine D.P. (2018). Real-time assimilation of streamflow observations into a hydrological routing model: effects of model structures and updating methods. *Hydrological Sciences Journal*, **63:3**, 386-407. <https://doi.org/10.1080/02626667.2018.1430898>
- MGAP (2001). Compendio Actualizado de Información de Suelos del Uruguay a escala 1/1000.000. División Suelos y Aguas, Dirección de Recursos Naturales, Ministerio de Ganadería Agricultura y Pesca (MGAP), Uruguay.
- Mittermaier M.P. (2007). Improving short-range high-resolution model precipitation forecast skill using time-lagged ensembles. *Quart. J. Roy. Meteor. Soc.* **133**, 1487–1500. <https://doi.org/10.1002/qj.135>
- Miyoshi T., Sun Q. (2022). Control simulation experiment with Lorenz's butterfly attractor. *Nonlin. Processes Geophys.*, **29**, 133–139, <https://doi.org/10.5194/npg-29-133-2022>
- Molfino J.H., Califra A. (2001). Agua Disponible de las Tierras del Uruguay. División de Suelos y Aguas, Ministerio de Ganadería Agricultura y Pesca (MGAP), Uruguay.
- Moriasi D.N., Gitau M.W., Pai N., Daggupati P. (2015). Hydrologic and water quality models: performance measures and evaluation criteria. *Transactions of the ASABE* **58**(6), 1763-1785.
- Morquio E. (2022). Análisis y corrección de componentes de balance de masa en embalse Rincón del Bonete. Informe de Pasantía de Ingeniería Civil, perfil H-A. Tutora: Mariana Mendina. UdelaR, FI, IMFIA.

- Murphy A.H. (1993). What is a good forecast – An essay on the nature of goodness in weather forecasting. *Weather Forecast*, **8**, 281–293. [https://doi.org/10.1175/1520-0434\(1993\)008<0281:WIAGFA>2.0.CO;2](https://doi.org/10.1175/1520-0434(1993)008<0281:WIAGFA>2.0.CO;2)
- Musuuza J.L., Gustafsson D., Pimentel R., Crochemore L., Pechlivanidis I. (2020). Impact of Satellite and In Situ Data Assimilation on Hydrological Predictions. *Remote Sensing*, **12(5)**:811. <https://doi.org/10.3390/rs12050811>
- Narbondo S., Crisci M., Chreties C. (2018). Modelación hidrológica diaria en cuencas con diferentes características de Uruguay. *XXVIII Congreso Latinoamericano de Hidráulica*, IAHR, Buenos Aires, Argentina.
- Narbondo S., Gorgoglione A., Crisci M., Chreties Ch. (2020). Enhancing physical similarity approach to predict runoff in ungauged watersheds in sub-tropical regions. *Water* 2020, **12** (2), 528. <https://doi.org/10.3390/w12020528>
- Narbondo S. (2021). Incorporación de información satelital de humedad de suelo en modelos hidrológicos para pronóstico de inundaciones en cuencas de Uruguay. Tesis de maestría. UdelaR, FI, IMFIA. Disponible en <https://www.colibri.udelar.edu.uy/jspui/handle/20.500.12008/28533>
- OMM (2021). Guidelines on Ensemble Prediction System Post-processing. 2021 Edition. WMO-No. 1254. ISBN: 978-92-63-11254-5. https://library.wmo.int/doc_num.php?explnum_id=10726
- Oudin L., Moulin L., Bendjoudi H., Ribstein P. (2010). Estimating potential evapotranspiration without continuous daily data: possible errors and impact on water balance simulations. *Hydrological Sciences Journal*, **55:2**, 209-222, <https://doi.org/10.1080/02626660903546118>
- Palmer T.N. (1993). Extended-range atmospheric prediction and the Lorenz model. *Bull. Amer. Meteor. Soc.* **74**, 49–66.
- Pappenberger F., Bartholmes J., Thielen J., Cloke H. L., Buizza R., De Roo A. (2008). New dimensions in early flood warning across the globe using grand-ensemble weather predictions. *Geophysical Research Letters*, **35** (10), 1–7. <https://doi.org/10.1029/2008GL033837>
- Peña M., Toth Z. (2014). Estimation of analysis and forecast error variances. *Tellus A*, **66** (1), 21767. <https://doi.org/10.3402/tellusa.v66.21767>
- Perrin C., Michel C. y Andréassian V. (2003). Improvement of a parsimonious model for streamflow simulation. *Journal of Hydrology*, **279** (1), 275-289. [https://doi.org/10.1016/S0022-1694\(03\)00225-7](https://doi.org/10.1016/S0022-1694(03)00225-7)
- Piazzzi G., Thirel G., Perrin C., Delaigue O. (2021). Sequential data assimilation for streamflow forecasting: Assessing the sensitivity to uncertainties and updated variables of a conceptual hydrological model at basin scale. *Water Resources Research*, **57**, 2020WR028390. <https://doi.org/10.1029/2020WR028390>

- Pushpalatha R., Perrin C., Moine N.L., Mathevet T., Andreassian V. (2011). A downward structural sensitivity analysis of hydrological models to improve low-flow simulation. *J. Hydrol.* **411**, 66e76. <http://dx.doi.org/10.1016/j.jhydrol.2011.09.034>
- Qu B., Zhang X., Pappenberger F., Zhang T., Fang Y. (2017). Multi-Model Grand Ensemble Hydrologic Forecasting in the Fu River Basin Using Bayesian Model Averaging. *Water*, **9**(2), 74. <https://doi.org/10.3390/w9020074>
- Raftery A.E., Gneiting T., Balabdaoui F., Polakowski M. (2005). Using Bayesian Model Averaging to Calibrate Forecast Ensembles. *Monthly Weather Review*, **133**(5), 1155-1174. <https://doi.org/10.1175/MWR2906.1>
- Raynaud L., Pannekoucke O., Arbogast P., Bouttier F. (2015). Application of a bayesian weighting for short-range lagged ensemble forecasting at the convective scale. *Quarterly Journal of the Royal Meteorological Society*, **141**(687), 459–468. <https://doi.org/10.1002/qj.2366>
- Renard B., Kavetski D., Kuczera G., Thyer M., Franks S.W. (2010). Understanding predictive uncertainty in hydrologic modeling: The challenge of identifying input and structural errors. *Water Resour. Res.*, **46**, W05521, <https://doi.org/10.1029/2009WR008328>
- Saha S., Nadiga S., Thiaw C., Wang J., et al. (2006). The NCEP Climate Forecast System. *J. Climate*, **19**, 3483–3517. <https://doi.org/10.1175/JCLI3812.1>
- Saltzman B. (1962). Finite amplitude free convection as an initial value problem. *J. Atmos. Sci.* **19**, 329-341.
- Santos L., Thirel G., Perrin C. (2018). Continuous state-space representation of a bucket-type rainfall-runoff model: A case study with the GR4 model using state-space GR4 (version 1.0). *Geosci. Model Dev.*, **11**, 1591–1605. <https://doi.org/10.5194/gmd-11-1591-2018>
- SAS Institute Inc. (1989). *SAS/STAT user's guide*. Cary, NC: Autor.
- Scherrer S.C., Frei C., Croci-Maspoli M., Van Geijtenbeek D., Hotz C., Appenzeller C. (2011). Operational quality control of daily precipitation using spatio-climatological plausibility testing. Article in *Meteorologische Zeitschrift*.
- Schwanenberg D., Fan F.M., Naumann S., Kuwajima J.I., Montero R.A., Assis dos Reis A. (2015). Short-term reservoir optimization for flood mitigation under meteorological and hydrological forecast uncertainty. Application to the Três Marias Reservoir in Brazil. *Water Resour. Manag.* **29**(5), 1635–1651; <https://doi.org/10.1007/s11269-014-0899-1>.
- Slingo J., Palmer T. (2011). Uncertainty in weather and climate prediction. *Phil. Trans. R. Soc. A.* **369**, 4751–4767. <https://doi.org/10.1098/rsta.2011.0161>

- Sloughter J.M.L., Raftery A.E., Gneiting T., Fraley C. (2007). Probabilistic Quantitative Precipitation Forecasting Using Bayesian Model Averaging. *Monthly Weather Review*, **135**(9), 3209-3220. <https://doi.org/10.1175/MWR3441.1>
- Talagrand O. (1997). Assimilation of observations: An introduction. *Journal of the Meteorological Society of Japan*, **75**, 191 – 205.
- Talagrand O., Vautard R., Strauss B. (1997). Evaluation of probabilistic prediction systems, in *Workshop on Predictability*, ed. by for Medium-Range Weather Forecasts, E.C., Shinfield Park, Reading, pp. 1–25.
- Tandeo P. et al. (2015). Combining Analog Method and Ensemble Data Assimilation: Application to the Lorenz-63 Chaotic System. In: Lakshmanan V., Gilleland E., McGovern A., Tingley M. (eds) *Machine Learning and Data Mining Approaches to Climate Science*. Springer, Cham. https://doi.org/10.1007/978-3-319-17220-0_1
- Terra R., Baethgen W.E. (2019). Lessons Learned in 25 Years of Informing Sectoral Decisions with Probabilistic Climate Forecasts. In *Sub-Seasonal to Seasonal Prediction: The Gap Between Weather and Climate Forecasting*; Robertson, A.W., Vitart, F., Eds.; Elsevier: Amsterdam, pp. 439–453.
- Thiboult A., Anctil F., Boucher M.A. (2016). Accounting for three sources of uncertainty in ensemble hydrological forecasting. *Hydrology and Earth System Sciences*, **20**(5), 1809–1825. <https://doi.org/10.5194/hess-20-1809-2016>
- Toth Z., Kalnay E. (1993). Ensemble Forecasting at NMC: The Generation of Perturbations. *Bull. Amer. Meteor. Soc.*, **74**, 2317–2330. [https://doi.org/10.1175/1520-0477\(1993\)074<2317:EFANTG>2.0.CO;2](https://doi.org/10.1175/1520-0477(1993)074<2317:EFANTG>2.0.CO;2)
- Troin M., Arsenault R., Wood A.W., Brissette F., Martel J.-L. (2021). Generating ensemble streamflow forecasts: A review of methods and approaches over the past 40 years. *Water Resources Research*, **57**, e2020WR028392. <https://doi.org/10.1029/2020WR028392>
- Van Leeuwen P.J., Künsch H.R., Neger L., Potthast R., Reich S. (2019). Particle filters for high-dimensional geoscience applications: A review. *Quarterly Journal of the Royal Meteorological Society*. ISSN: 1477870X. <https://doi.org/10.1002/qj.3551>
- Velázquez J., Anctil F., Ramos M., Perrin C. (2011). Can a multi-model approach improve hydrological ensemble forecasting? A study on 29 french catchments using 16 hydrological model structures. *Advances in Geosciences*, **29**, 33–42. <https://doi.org/10.5194/adgeo-29-33-2011>

- Whitaker J.S., Hamill T., Wei X., Song Y., Toth Z. (2008). Ensemble Data Assimilation with the NCEP Global Forecast System. *Mon. Wea. Rev.*, **136**, 463-482. <https://doi.org/10.1175/2007MWR2018.1>
- Wilks D.S. (2011). *Statistical Methods in the Atmospheric Sciences*. Third edition. International Geophysics Series, Volume 100. ISBN 978-0-12-385022-5.
- Yang S., Baker D., Li H., Cordes K., Huff M., Nagpal G., Okereke E., Villafañe J., Kalnay E. and Duane G. S. (2006). Data Assimilation as Synchronization of Truth and Model: Experiments with the Three-Variable Lorenz System. *Journal of the Atmospheric Sciences* **63**, 9, 2340-2354. <https://doi.org/10.1175/JAS3739.1>
- Yuan H., Lu C., McGinley J.A., Schultz P.J., Jamison B.D., Wharton L., Anderson C.J. (2009). Evaluation of short-range quantitative precipitation forecasts from a time-lagged multimodel ensemble. *Wea. Forecasting*, **24**, 18–38. <https://doi.org/10.1175/2008WAF2007053.1>
- Zhang Y., Zhang L., Hou J., Gu J., Huang C. (2017). Development of an Evapotranspiration Data Assimilation Technique for Streamflow Estimates: A Case Study in a Semi-Arid Region. *Sustainability*, **9(10)**:1658. <https://doi.org/10.3390/su9101658>
- Zhou B., Du J., DiMego G. (2010). Introduction to the NCEP Very Short Range Ensemble Forecast System (VSREF). *14th Conf. on Aviation, Range, and Aerospace*, 90th AMS Annual Meetings, Atlanta, GA, 17-21, 2010, available at <http://www.emc.ncep.noaa.gov/mmb/SREF/VSREF-2010-AMS-I12.3.pdf>
- Zhou X., Zhu Y., Hou D., Luo Y., Peng J., Wobus R. (2017). Performance of the New NCEP Global Ensemble Forecast System in a Parallel Experiment. *Weather and Forecasting*, **32(5)**, 1989-2004. <https://doi.org/10.1175/WAF-D-17-0023.1>
- Zhou X., Zhu Y., Hou D., Fu B., Li W., Guan H., Sinsky E., Kolczynski W., Xue X., Luo Y., Peng J., Yang B., Tallapragada V., Pegion P. (2022). The Development of the NCEP Global Ensemble Forecast System Version 12, *Weather and Forecasting* (published online ahead of print 2022). <https://doi.org/10.1175/WAF-D-21-0112.1>

ANEXOS

9. Anexo I: Datos empleados para la modelación hidrológica

9.1 EVAPOTRANSPIRACIÓN POTENCIAL DIARIA

En la Figura 9-1 se muestra la ubicación de las estaciones meteorológicas consideradas para el cálculo del ciclo medio anual de ETP y en la Figura 9-2 se presentan los ciclos anuales resultantes (obtenidos mediante el método de Penman-Monteith).

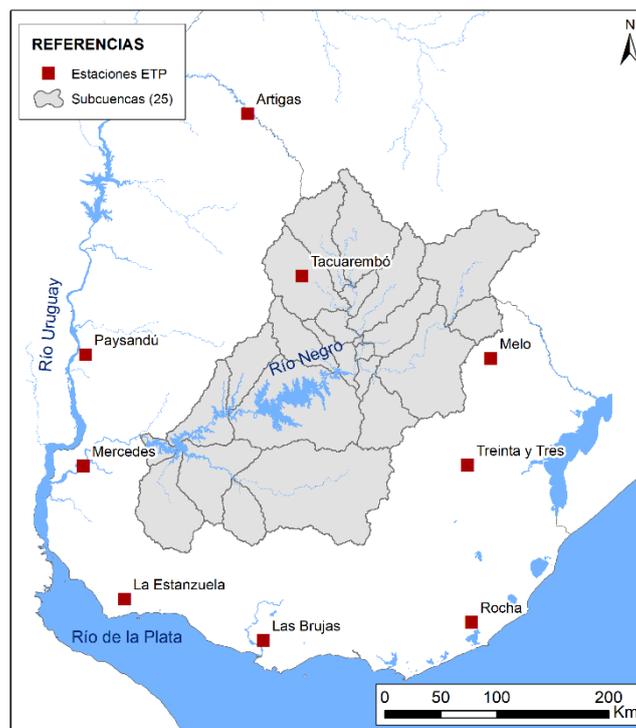


Figura 9-1: Ubicación de las estaciones meteorológicas consideradas.

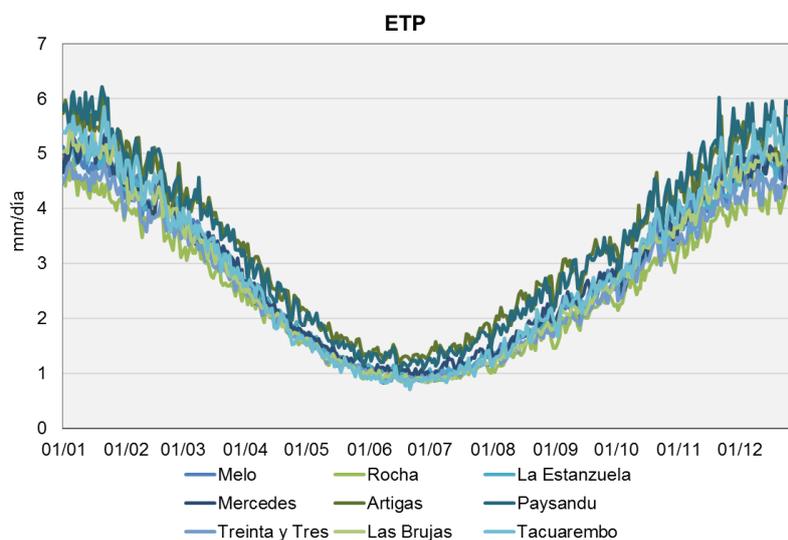


Figura 9-2: Ciclo medio anual de ETP para cada estación meteorológica (período 1991–2015).

9.2 CAPACIDAD DE ALMACENAMIENTO DE AGUA DE LOS SUELOS

Para representar la capacidad de almacenamiento de agua del suelo se elaboró el mapa de agua potencialmente disponible en los suelos de Uruguay (Figura 9-3), a partir de la Carta de Reconocimiento de Suelos del Uruguay, escala 1:1.000.000 (MGAP, 2001; Molfino y Califra, 2001).

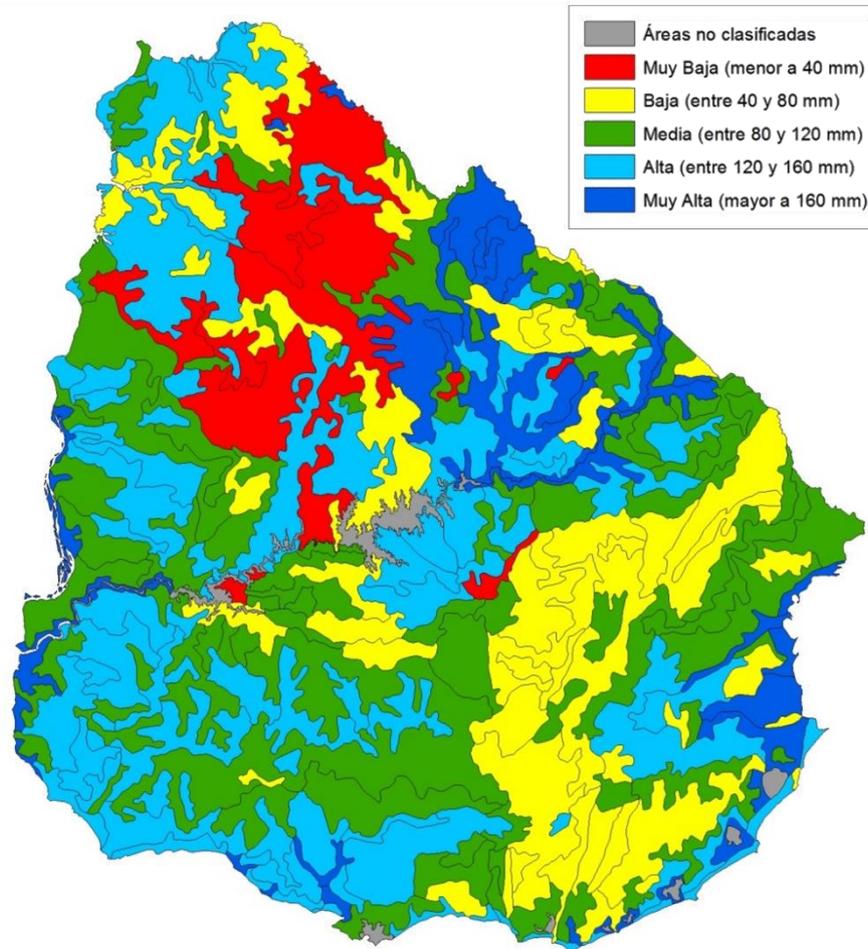
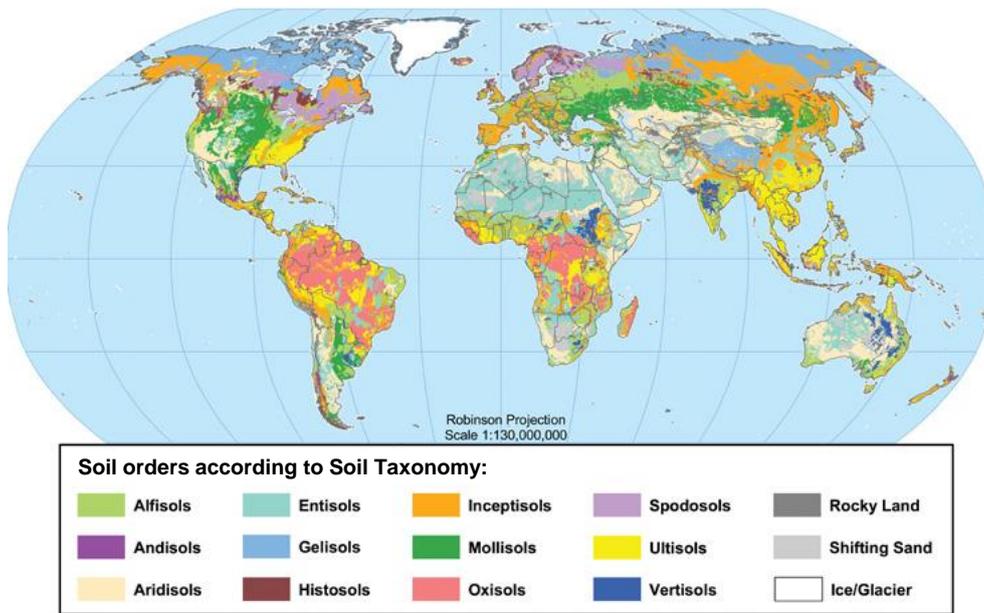


Figura 9-3: Mapa de agua potencialmente disponible en los suelos de Uruguay.

Para el resto de los suelos (no comprendidos en Uruguay), el agua potencialmente disponible se estimó a partir de la clasificación de los suelos uruguayos de acuerdo a los criterios del Soil Taxonomy (Duran et al., 1999), disponible para todo el globo (Figura 9-4).

Global Soil Regions



US Department of Agriculture
Natural Resources
Conservation Service

Soil Survey Division
World Soil Resources
soils.usda.gov/use/worldsoils

November 2005

Figura 9-4: Clasificación de suelos según Soil Taxonomy.