

Tesis Doctoral

Estudio de los efectos de diferentes fuentes de error sobre la calidad de los análisis generados por un sistema de asimilación por filtros de Kalman

Saucedo, Marcos Adolfo

2016-03-04

Este documento forma parte de la colección de tesis doctorales y de maestría de la Biblioteca Central Dr. Luis Federico Leloir, disponible en digital.bl.fcen.uba.ar. Su utilización debe ser acompañada por la cita bibliográfica con reconocimiento de la fuente.

This document is part of the doctoral theses collection of the Central Library Dr. Luis Federico Leloir, available in digital.bl.fcen.uba.ar. It should be used accompanied by the corresponding citation acknowledging the source.

Cita tipo APA:

Saucedo, Marcos Adolfo. (2016-03-04). Estudio de los efectos de diferentes fuentes de error sobre la calidad de los análisis generados por un sistema de asimilación por filtros de Kalman. Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires.

Cita tipo Chicago:

Saucedo, Marcos Adolfo. "Estudio de los efectos de diferentes fuentes de error sobre la calidad de los análisis generados por un sistema de asimilación por filtros de Kalman". Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires. 2016-03-04.

EXACTAS UBA

Facultad de Ciencias Exactas y Naturales



UBA

Universidad de Buenos Aires



UNIVERSIDAD DE BUENOS AIRES

Facultad de Ciencias Exactas y Naturales
Departamento de Ciencias de la Atmósfera y los Océanos

**Estudio de los efectos de diferentes fuentes de error
sobre la calidad de los análisis generados por un
sistema de asimilación por filtros de Kalman**

Tesis presentada para optar al título de Doctor de la Universidad de Buenos
Aires en el área de Ciencias de la Atmósfera y los Océanos

Marcos Adolfo Saucedo

Directores de tesis: Andrea Celeste Saulo
Juan José Ruiz

Consejero de Estudios: Andrea Celeste Saulo

Lugar de trabajo: Centro de Investigaciones del Mar y la Atmósfera (CIMA),
Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires.

Buenos Aires, 2015

Estudio de los efectos de diferentes fuentes de error sobre la calidad de los análisis generados por un sistema de asimilación por filtros de Kalman

Resumen

El presente trabajo de tesis plantea la realización de experimentos idealizados de asimilación de datos basado en un Filtro de Kalman por ensambles (EnKF) sobre un dominio regional centrado en Sudamérica. En particular se emplea el algoritmo conocido como Local Ensemble Transform Kalman Filter (LETKF) acoplado al modelo numérico Weather Research and Forecasting (WRF). Los experimentos exploran la sensibilidad del sistema de asimilación frente a los errores de modelo y los errores presentes en las condiciones de borde lateral.

Los resultados indican que las regiones tropicales son más sensibles a los errores de modelo, mientras que las latitudes medias están más directamente influenciadas por los errores en las condiciones de borde lateral. Para reducir los errores del análisis se evalúan diferentes metodologías que buscan representar de manera explícita los errores en el sistema de asimilación: la inflación multiplicativa adaptativa estimada, los ensambles físicos y la introducción de perturbaciones en las condiciones de borde lateral. El empleo de dichas técnicas permite reducir el error del análisis y contribuye a mejorar la representación de su incertidumbre. Sin embargo, los mejores resultados se obtienen al combinar dichas técnicas de forma simultánea.

Finalmente, se llevan adelante experimentos utilizando observaciones reales en los que se explora el impacto de la resolución del modelo en la calidad del análisis y de los pronósticos a corto plazo. En estos experimentos se encuentra que el aumento de la resolución del modelo numérico genera una mejora tanto de la calidad del análisis como del pronóstico resultante. Sin embargo, los resultados sugieren que un tratamiento adecuado de las diferentes fuentes de

incertidumbre que afectan a un sistema de análisis - pronóstico regional, junto con la incorporación de una mayor cantidad de observaciones, podría producir un impacto mayor sobre la calidad del análisis.

Palabras clave: asimilación de datos, LETKF, fuentes de error, resolución horizontal, análisis, pronóstico

Study of the effects of different error sources upon the quality of analysis generated by a Kalman Filter data assimilation system

Abstract

The present work proposes the realization of idealized data assimilation experiments based on an Ensemble Kalman Filter (EnKF) in a regional domain centered in South America. In particular, the Local Ensemble Transform Kalman Filter (LETKF) coupled with the Weather Research and Forecasting (WRF) model is employed. These experiments explore the sensitivity of the assimilation system to the model and lateral boundary condition errors.

Results indicate that tropical regions are more sensitive to model errors, whereas mid-latitudes are more affected by lateral boundary condition errors. In order to reduce analysis errors different methodologies that seek to represent explicitly errors present in the assimilation system are employed: the estimated adaptive multiplicative inflation, perturbed physic ensemble and perturbed lateral boundary conditions. The employment of these techniques provides a reduction of the analysis error and contributes to improve the representation of the uncertainty. Nevertheless, the best results are obtained when these techniques are employed simultaneously.

Finally, data assimilation experiments using real observations exploring the impact of model's horizontal resolution in both the analysis and short term forecast are carried on. In these experiments it is found that the increment in model resolution results in an improvement of both the analysis and the forecast. However, results suggest that an adequate treatment of the different error sources that affect a regional analysis - forecast system and the inclusion of a greater amount of observations in the assimilation process further enhance the improvement on the analysis quality.

Key words: data assimilation, LETKF, error sources, horizontal resolution, analysis, forecast.

Agradecimientos

Como toda etapa que se transita en la vida, encarar un doctorado y elaborar su tesis representa un gran desafío personal. Es un camino en el que se entremezclan las dificultades propias de un trabajo de investigación en el que más de una vez se debe recomenzar, con las pequeñas alegrías que aparecen cada tanto a medida que se avanza en la investigación y se encuentran resultados, sean estos triviales o inesperados. El doctorado es en definitiva una etapa de crecimiento personal y de autoafirmación, en el que se requiere tanto de paciencia como de amor y pasión por el tema de investigación.

Como persona de fe, veo en el doctorado una etapa de mi vida recorrida bajo la Providencia divina, un llamado a perfeccionarme como meteorólogo que es la vocación que el Señor me regaló. El fin último del doctorado, más allá de una realización personal o de una meta cumplida, es el de formarme para poder servir mejor a una sociedad que gratuitamente me ha formado a lo largo de 15 años.

Es por esto que mi primer agradecimiento es para con Dios, que me pensó en esta vida como meteorólogo regalándome un gran número de dones y talentos y que me da todo su Amor en cada paso de mi camino hacia El. Sin embargo, la generosidad de Dios no se agota allí, sino que ha puesto en mi camino un sinnúmero de personas que me ha acompañado a lo largo de esta etapa, y que no quiero dejar de mencionar en este espacio a riesgo de ser injusto e ingrato con ellas.

Debo mencionar en primer lugar a mi familia, y en especial a mi padre Carlos y a mi madre Ana Inés, junto con mis hermanos Martín, Javier, Ana Inés y Andrés. Esto sin olvidar a mis cuñados Susana, Fernando y Mariana, y a mis sobrinos Ana Carolina, María de los Ángeles, Lara Belén y Matías. De ellos aprendí el valor incalculable que tiene una familia unida, en donde el amor es moneda corriente, y en donde los valores de honestidad, humildad, sacrificio, esfuerzo y comprensión mutua forman parte de una identidad común, más allá de las diferencias particulares. A ellos les estoy eternamente agradecido, porque sin ellos jamás podría haber llegado hasta aquí. Debo agradecer especialmente el hecho de que me hayan impulsado a continuar mi formación con el doctorado hace 6 años, cuando en ese entonces no estaba seguro de qué camino seguir.

Lógicamente, no puedo obviar a quienes me dirigieron a lo largo del doctorado, a los doctores Celeste Saulo y Juan Ruiz. A Celeste por inculcarme su visión de futuro y animarme a soñar en grande eligiendo un tema de investigación prácticamente virgen en la Argentina, sabiendo que elegía un camino áspero y

difícil con un gran número de sinsabores. A pesar de sus múltiples ocupaciones Celeste siempre me animó a continuar y a no rendirme. A Juan por su enorme dedicación y su disponibilidad para atender todas mis dudas y ayudarme a resolver todas mis dificultades. Del gran número de charlas e intercambios de ideas que llevaron incontables horas aprendí un montón de cosas de Juan, si las mencionara una por una pienso que escribiría tantas páginas como las que tiene esta Tesis. La más importante de todas es su humildad, diría que Juan posee la humildad de los grandes, y es para mí un gran orgullo que me haya dirigido a lo largo de este camino.

Como ningún trabajo de este tipo se puede realizar si no se cuentan con los recursos adecuados, deseo agradecer al Centro de Investigaciones del Mar y la Atmósfera (CIMA) por proveerme en primer lugar el espacio físico para desarrollar el trabajo de investigación. Pero en particular deseo agradecer al CIMA por permitirme la utilización de su cluster adherido al Sistema Nacional de Cómputos de Alto Desempeño (SNCAD), lo cual posibilitó la realización de esta Tesis. También deseo agradecer al Consejo Nacional de Investigaciones Científicas y Tecnológicas (CONICET) por el financiamiento otorgado a través de las becas de investigación que permitieron costear mis estudios.

Otra persona de la que no me puedo olvidar en estas páginas es del doctor Takemasa Miyoshi. En primer lugar es mi deber agradecerle el haberme permitido la utilización de la computadora K del Riken Advanced Institute de Japón para llevar a cabo los experimentos de asimilación que forman parte de esta Tesis y que de no haber tenido a disposición semejante poder de cómputo, la obtención de los resultados habría demandado un tiempo considerablemente mayor. Sin embargo, la participación de Takemasa no se limitó a un mero permiso para utilizar la computadora K, sino que también enriqueció este trabajo con comentarios y sugerencias sumamente valiosos y que permitieron una mejor comprensión de los resultados obtenidos.

A quienes deseo agradecer en estas páginas es a mis compañeros de viaje Cristian Waimann, Pablo Spenneman, Marisol Osman y Mariano Alvarez. Debo agregar también aquí a Félix Carrasco y a Henrique Repinaldo. Con cada uno de ellos compartí muchos momentos agradables y anécdotas de lo más variadas, además de viajes, cursadas, eventos sociales y partidos de fútbol. Ciertamente hicieron muy ameno mi camino a lo largo de estos años, y me dejaron muchos recuerdos que persisten en mi memoria y que me hacen mirar con cierta añoranza los momentos vividos.

Tampoco puedo olvidar a María Eugenia Dillon y a Pablo Echevarría, con quienes tuve la dicha de trabajar en esta temática y compartir dudas e inquietudes cuando dábamos los primeros pasos en el curso de asimilación de

datos dictado en Corrientes en el año 2011. En este punto los recuerdos de mi mente saltan hacia otras personas que conocí allí como Manuel Pulido, Pierre Tandeo, Patricia Blatter, Pablo Llamado y Andrés Pérez, entre otros. Tanto a Manuel como a Pierre, junto con Juan, les agradezco enormemente la dedicación y paciencia que tuvieron para dictar un curso que fue vital para la comprensión de la temática. Al resto, si bien escasas veces los volví a ver, les agradezco el haber compartido en dicho curso un montón de buenos momentos.

También agradezco a todos los docentes que me enseñaron en estos años sobre diversas temáticas. Si bien las mismas no estaban vinculadas directamente con la asimilación de datos, me sirvieron para complementar mi formación, y al mismo tiempo me llevaron a descubrir lo más atractivo de cualquier disciplina que es el idear soluciones para diferentes problemas. En este punto quiero agradecer a los profesores que tuve la dicha de conocer en mis viajes de estudio en el exterior, verdaderas eminencias mundiales de la asimilación de datos que volcaron generosamente todos sus conocimientos.

Mención aparte debo hacer de mi tía Blanca María, quien amablemente se prestó a la lectura de esta Tesis con el fin de determinar la correcta estructuración y claridad de conceptos volcados en la misma. Sus comentarios y sugerencias han sido de una gran ayuda, a la vez que su apoyo ha resultado ser un gran aliciente para alcanzar el fin último de la Tesis.

Finalmente deseo agradecer con todo mi corazón a mis hermanos del Movimiento de la Palabra de Dios de Adrogué, a quienes tuve la enorme dicha de encontrar a mitad de este camino. Si bien mi agradecimiento es para con todos los miembros de esta comunidad, deseo hacer un agradecimiento especial a mis hermanos directos: Anabella, Paula, Yael, Camila, Martina, Javier y Martín, y a quienes fueron mis coordinadores: Carlos, Elena, Sofía, Keila y Juan Pablo. A ellos les agradezco por sus oraciones y bendiciones, y por constituir un espacio de vida en donde la gracia de Dios se hace presente y permite transitar los caminos más duros.

A todas las personas mencionadas, y a las que no nombré directamente pero que también guardo en mi corazón, sólo puedo decirles una palabra que de tan simple, expresa toda mi gratitud: GRACIAS.

Índice

Capítulo 1: La asimilación de datos

1.1 Introducción	13
1.2 El problema de la estimación de las condiciones iniciales: la asimilación de datos	16
1.3 Antecedentes y situación actual del pronóstico meteorológico a nivel local	22
1.4 Motivaciones y objetivos	26
1.5 Organización de la Tesis	29

Capítulo 2: Técnicas de asimilación de datos por ensambles y su verificación

2.1 Introducción	30
2.2 Filtros de Kalman	30
2.3 Filtros de Kalman por Ensamble	36
2.4 Fortalezas y debilidades del EnKF	38
<i>2.4.1 Ventajas del EnKF</i>	38
<i>2.4.2 Debilidades del EnKF</i>	39
2.5 Localización en EnKF	40
2.6 Representación de errores en EnKF	41
2.7 Local Ensemble Transform Kalman Filter	47

2.7.1 Planteo formal del LETKF	47
2.7.2 Localización en LETKF	50
2.7.3 Implementación de la técnica IMA en LETKF	50
2.8 Verificación de la calidad y consistencia del análisis	51
2.8.1 Verificación del ajuste del primer momento o error del análisis	52
2.8.2 Verificación del ajuste del segundo momento o consistencia del análisis	58

Capítulo 3: Experimentos idealizados – impacto de las fuentes de error en el sistema de asimilación-pronóstico

3.1 Introducción	62
3.2 Datos y metodología	62
3.2.1 El sistema LETKF-WRF	62
3.2.2 Diseño experimental	65
3.2.3 Observaciones	70
3.3 Experimentos idealizados: condiciones de Modelo Perfecto y Bordes Perfectos (MPBP)	73
3.4 Experimentos idealizados: condiciones de Modelo Imperfecto y Bordes Perfectos (MIBP)	86

3.5 Experimentos idealizados: condiciones de modelo perfecto y bordes imperfectos (MPBI)	98
--	----

3.6 Experimentos idealizados: condiciones de modelo y bordes imperfectos (MIBI)	103
---	-----

Capítulo 4: Experimentos idealizados – implementación de técnicas para la representación de las fuentes de error en el sistema

4.1 Introducción	108
------------------	-----

4.2 Experimentos de Modelo Imperfecto	108
---------------------------------------	-----

4.3 Experimentos de Bordes Imperfectos	119
--	-----

4.4 Experimentos de Modelo y Bordes Imperfectos	126
---	-----

Capítulo 5: Sensibilidad del análisis y del pronóstico a la resolución horizontal del modelo: Experimentos con observaciones reales

5.1 Introducción	130
------------------	-----

5.2 Diseño experimental	131
-------------------------	-----

5.3 Verificación de la calidad del análisis	135
5.4 Verificación de la calidad del pronóstico	142
5.5 Verificación de los pronósticos de ciclones tropicales	152
 <u>Capítulo 6: Conclusiones y perspectivas futuras</u>	
6.1 Resumen y aspectos sobresalientes de los resultados	160
6.2 Perspectivas futuras	170
 <u>Apéndice de definiciones</u>	176
 <u>Listado de acrónimos</u>	178
 <u>Referencias</u>	180
 <u>Apéndice de Figuras</u>	201
<i>Capítulo 1: La asimilación de datos</i>	202
<i>Capítulo 2: Técnicas de asimilación de datos por ensambles y su verificación</i>	205
<i>Capítulo 3: Experimentos idealizados – impacto de las fuentes de error en el sistema de asimilación-pronóstico</i>	209

<i>Capítulo 4: Experimentos idealizados – implementación de técnicas para la representación de las fuentes de error en el sistema</i>	240
<i>Capítulo 5: Sensibilidad del análisis y del pronóstico a la resolución horizontal del modelo: Experimentos con observaciones reales</i>	259

“¿Qué es más difícil? Lo que parece más fácil:

ver con los ojos lo que está delante de ellos”

Johann Wolfgang von Goethe (1749-1832)

Capítulo 1: La asimilación de datos

1.1 Introducción

Uno de los grandes desafíos que la meteorología ha enfrentado desde sus primeros tiempos, es la predicción del tiempo a diferentes escalas temporales, desde plazos de las horas hasta las semanas. En efecto, diversas actividades humanas se ven afectadas por el comportamiento de la atmósfera en dichas escalas de tiempo. Por este motivo, la meteorología es requerida por diferentes actores para anticiparse a cambios que podrían afectarlos y eventualmente tomar la decisión adecuada que permita minimizar pérdidas y costos o hasta sacar el mayor provecho de una situación prevista.

Si bien la predicción meteorológica es una actividad que interesó a la humanidad desde la antigüedad, el verdadero salto cualitativo en esta rama de la ciencia se produjo recién en el último siglo. Hace poco más de 100 años, el físico y meteorólogo noruego Vilhelm Bjerkness (1904) estableció las bases de la predicción meteorológica actual, al postular que el estado futuro de la atmósfera podía ser determinado a partir de integrar numéricamente las ecuaciones que rigen la evolución del sistema atmosférico. Este planteo implica resolver simultáneamente un conjunto de ecuaciones, las cuales incluyen las ecuaciones de conservación de movimiento, energía, masa junto con la ecuación de estado. De esta manera, Bjerkness planteó el problema de la previsión del tiempo como un problema de condiciones iniciales. Esto significa que si pretendemos conocer el estado futuro de la atmósfera, debemos determinar primero las condiciones actuales de la atmósfera (lo que se denomina determinar las condiciones iniciales), y a partir de dicho estado integrar numéricamente las ecuaciones que gobiernan la física de la atmósfera (lo que se conoce como integrar un modelo numérico).

Aproximadamente 20 años más tarde, el físico, matemático y meteorólogo inglés Lewis Richardson (1922), tomando las ideas de Bjerkness, intentó realizar la primera integración numérica de las ecuaciones primitivas del sistema atmosférico, con el objetivo de obtener un pronóstico a 6 horas para el norte de Europa. Dicho intento resultó infructuoso, dado que los resultados que Richardson obtuvo de esta integración fueron físicamente irreales. La causa de tal fracaso se dio por una serie de motivos, entre los que podemos destacar la mala determinación de las condiciones iniciales y la falta del filtrado de las ondas de crecimiento más rápido, lo cual condujo a tasas de cambio de la presión en superficie de un orden de magnitud mayor a los típicamente observados. Asimismo, en la época en que Richardson realizó lo que fue la primera integración numérica de un modelo atmosférico, no se disponía del poder de cómputo necesario para llevar a cabo dicha tarea.

No fue sino hacia la década de 1950 cuando se logró el primer pronóstico del tiempo exitoso a 1 día de plazo a partir de un modelo numérico simplificado (Charney y otros, 1950). Desde entonces, el continuo crecimiento de la capacidad de cálculo computacional permitió que los modelos fueran cada vez más sofisticados, con mayor resolución espacial y con una menor cantidad de aproximaciones. En consecuencia, los modelos fueron progresivamente capaces de representar más adecuadamente los procesos de menor escala presentes en la atmósfera, lo cual ayudó a mejorar en el transcurso de los años la calidad de los pronósticos. Sin embargo, debido al hecho de que el problema del pronóstico del tiempo es esencialmente un problema de condiciones iniciales, la mejora de la calidad del pronóstico está limitada en gran medida por el grado de aproximación de la condición inicial. Esto implica que para mejorar la calidad de un pronóstico a corto plazo es imprescindible avanzar en la mejora de la estimación de las condiciones iniciales. No obstante, debe tenerse en cuenta que no es suficiente mejorar la condición inicial para obtener un mejor pronóstico, sino que dicha condición inicial debe respetar ciertas condiciones de balance del flujo. De no respetarse tales condiciones, es muy posible que se exciten ondas dentro del modelo que rápidamente degraden la calidad del pronóstico y por lo tanto la mejora

obtenida en el campo inicial no redunde en un beneficio mayor en el pronóstico.

Durante la década de 1960 se produjo un descubrimiento que revolucionó la ciencia de la previsión del tiempo. En efecto, en el trabajo pionero de Lorenz (1963) se descubrió que la atmósfera es un sistema caótico, y por lo tanto su predictibilidad es limitada. Esto significa que pasado un cierto tiempo, la distancia entre el estado pronosticado por un modelo numérico y el estado real de la atmósfera será estadísticamente tan grande como dos estados del sistema atmosférico tomados al azar. El límite teórico de predictibilidad depende de la escala de movimiento atmosférico representada. Para la escala sinóptica $O(10^3\text{km})$, Lorenz estimó el límite de predictibilidad en el orden de las 2 semanas. Para la escala convectiva $O(1\text{km})$, el límite de predictibilidad es mucho más corto, de entre 1 y 2 horas.

Este hecho implica entonces que aproximarse al límite teórico de predictibilidad depende esencialmente de dos factores, por un lado de la capacidad para minimizar la incertidumbre en la determinación de la condición inicial (equiparable al concepto de tener el mejor análisis posible) y por otro de la capacidad de representar la física del sistema con la mayor exactitud realizable (equiparable a la idea de tener el mejor modelo posible). De esta manera, pueden reconocerse los dos grandes desafíos de la meteorología, que en la actualidad son abordados desde perspectivas complementarias: la asimilación de datos, y el modelado numérico, respectivamente. Ambas especialidades se han caracterizado, ya desde sus comienzos, por la necesidad de recursos computacionales muy costosos y también por una sofisticación creciente desde el punto de vista tecnológico. Ambos requisitos resultan del desarrollo de algoritmos muy complejos matemáticamente, y de la incorporación de mayor cantidad de procesos físicos, que formulan de manera cada vez más detallada, no sólo aquéllos procesos que se dan en la atmósfera, sino también los que se dan en sus interfases con la superficie, como son el océano, la criosfera y la biosfera.

1.2 El problema de la estimación de las condiciones iniciales: la asimilación de datos

La estimación de las condiciones iniciales necesarias para la integración de un modelo numérico es una ciencia en sí misma. La técnica desarrollada para resolver este problema es la asimilación de datos, cuyo objetivo fundamental es utilizar toda la información disponible para determinar, tan exactamente como sea posible, el estado de un sistema dinámico como podría ser la atmósfera o el océano (Talagrand, 1997). El proceso de la asimilación de datos permite entonces obtener las condiciones iniciales, o como llamamos comúnmente el análisis, para poder luego integrar el modelo de pronóstico a partir de dicho análisis.

La ciencia de la asimilación de datos se ha caracterizado desde sus inicios a mediados del siglo pasado por un continuo desarrollo de técnicas y algoritmos, con el fin de determinar de la manera más exacta y eficiente posible, las condiciones iniciales de un sistema dinámico como es la atmósfera. En los experimentos pioneros de Richardson (1922) y Charney y otros (1950), los campos iniciales se obtenían mediante interpolaciones hechas a mano a partir de las observaciones disponibles a la retícula del modelo, los cuales luego se digitalizaban. Este era un procedimiento sumamente costoso en tiempo y por ende poco práctico. Por este motivo, rápidamente se volvió evidente la necesidad de realizar en forma automática análisis objetivos. Los primeros métodos objetivos y automatizados de asimilación de datos consistían en interpolaciones espaciales de las observaciones a la retícula del modelo (Panofsky, 1949, Gilchrist y Cressman, 1954, Barnes, 1964). Sin embargo, estos métodos ignoraban un problema práctico fundamental: el número de observaciones disponibles para llevar a cabo la interpolación era mucho menor a la cantidad de puntos de retícula de un modelo. Por otro lado, la distribución espacial de observaciones disponibles en tiempo real no es uniforme, ya que existen regiones con una gran densidad de observaciones (como las zonas continentales de Norteamérica, Europa o el este asiático), y otras regiones pobremente observadas (como por ejemplo el hemisferio Sur que es mayormente ocupado por océanos). Si bien es cierto que en la actualidad se

cuenta con información satelital que abarca la mayor parte del globo, la información provista por los mismos no son las variables resueltas por el modelo. A pesar de ello, el hecho de que existan regiones con gran cobertura de observaciones ayuda a que otras regiones pobremente observadas se vean beneficiadas por un mejor pronóstico. Esto es así gracias a que el modelo atmosférico es capaz de transportar la información adquirida en las regiones de mayor cobertura de observaciones hacia las regiones con menor número de observaciones. Por ejemplo, a pesar de que en el Océano Atlántico Norte contamos con un pequeño número de observaciones, el hecho de que haya un gran número de observaciones sobre Norteamérica resulta en una mejora de la calidad del pronóstico sobre el área oceánica, puesto que el modelo de pronóstico transporta la información adquirida sobre el continente y provee un mejor pronóstico sobre el Atlántico.

Debido a la in-homogeneidad en la distribución espacio-temporal de las observaciones, ya en los primeros tiempos de la predicción meteorológica se hizo evidente que era necesario contar con información adicional para preparar los campos iniciales para los pronósticos (Bergthorsson y Döös, 1955). Esta información adicional se la llama habitualmente campo preliminar o incluso se adopta muchas veces la terminología del inglés *background* o *first guess*. El campo preliminar consiste esencialmente en una primera estimación del estado de la atmósfera en todos los puntos de retícula del modelo. En principio, el campo preliminar debiera ser la mejor estimación posible del estado de la atmósfera previo al uso de las observaciones disponibles. Inicialmente se utilizó como campo preliminar la climatología o bien la combinación de la climatología y un pronóstico a corto plazo (Bergthorsson y Döös, 1955, Gandin, 1963). Sin embargo, a medida que los modelos numéricos fueron mejorando en su capacidad de representar la física de la atmósfera, se adoptó el uso de pronósticos a corto plazo derivados del mismo modelo para proveer el campo preliminar. Una de las ventajas de utilizar un pronóstico obtenido a partir del modelo numérico radica en que dicho campo preliminar debiera ser una buena primera aproximación del estado real de la atmósfera, asumiendo que los errores del pronóstico no crecen demasiado durante la integración del modelo.

Al mismo tiempo el modelo provee un campo preliminar dinámicamente balanceado, lo cual ayuda a que las correcciones introducidas por las observaciones sean relativamente pequeñas y contribuyan a generar un análisis que esté dentro del atractor del modelo, es decir un análisis que sea una solución del modelo.

Los primeros métodos de asimilación que empleaban un campo preliminar y que fueron utilizados operativamente son los llamados de análisis empíricos. Entre ellos podemos mencionar el método de Correcciones Sucesivas (Bergthorsson y Döös, 1955, Cressman, 1959), en el cual el campo preliminar es corregido en sucesivas iteraciones por las observaciones. Para cada punto del modelo, se toman todas las observaciones dentro de un determinado radio de influencia y se les asigna un error. Lo que este método provoca es esencialmente el de hacer tender el campo preliminar a las observaciones. En el caso particular de asumir que las observaciones no tienen error, este método simplemente reproduce los valores de las observaciones dentro de la retícula del modelo. Sin embargo, en la realidad las observaciones están afectadas por diversos errores, ya sea que estos provengan del instrumental mismo como de su representatividad espacial que puede no ser reproducida si la resolución horizontal del modelo es muy baja. Otro método de este tipo y que ha sido bastante utilizado es el de nudging o relajación (Kistler, 1974, Hoke y Antes, 1976). Este método consiste en agregar un término en las ecuaciones de pronóstico que lleva la solución hacia las observaciones.

Al tiempo que se aplicaban las técnicas empíricas en la generación de análisis operativos, se iban desarrollando otras técnicas basadas en teorías de estimación estadística, más robustas desde el punto de vista conceptual, ya que toman en consideración que tanto el análisis que se obtenga como el campo preliminar y las observaciones tienen errores. Como consecuencia de esta concepción del problema de la estimación de la condición inicial, el objetivo de estas técnicas es el de obtener el análisis combinando, de manera óptima, el campo preliminar y las observaciones disponibles. De esta forma se busca minimizar el error del análisis, a partir del error del campo preliminar y

de las observaciones. El primero de estos métodos fue el de Interpolación Óptima (denotado históricamente por las siglas OI), derivado originalmente por Eliassen (1954), y aplicado para obtener un análisis objetivo por Gandin (1963). Este último trabajo tuvo una gran influencia en las décadas siguientes, ya que este método se transformó en el esquema utilizado por los centros mundiales de pronóstico durante la década del 80 y hasta principios de los 90.

En los últimos años del siglo XX se produjo un salto cualitativo en la disciplina de asimilación al desarrollarse nuevas técnicas de filosofía similar a la de la Interpolación Óptima. El desarrollo de estas técnicas derivó en lo que actualmente se reconocen como los 2 abordajes principales al problema de encontrar la mejor estimación posible de las condiciones iniciales en un modelo numérico.

El primer grupo de técnicas lo constituyen los esquemas variacionales, que plantean el análisis como un estado óptimo que maximiza su probabilidad de ocurrencia, es decir que corresponde a la moda de la distribución de posibles estados de la atmósfera. Desde el punto de vista algorítmico, esta máxima probabilidad se traduce en reducir en términos cuadráticos la distancia entre el estado estimado del sistema a las observaciones y al campo preliminar, pesado en ambos casos por una estimación de sus respectivos errores. Las técnicas más importantes de este tipo son el 3-D Var (Parrish y Derber, 1992) y el 4-D Var (Talagrand y Courtier, 1987). La técnica 3-D Var es en esencia una forma más elaborada de la técnica OI en la que los errores del campo preliminar consisten en una matriz estática (derivada generalmente de una climatología de errores del modelo) que no tiene en cuenta las posibles variaciones del error del pronóstico según el estado del flujo atmosférico. Por su parte la técnica 4-D Var parte de una matriz de errores del campo preliminar estática, pero dado que incluye una evolución temporal de los errores del campo preliminar con respecto a las observaciones que ingresan en el ciclo de asimilación a partir de una versión linealizada del modelo (conocido como tangente lineal), provee una estimación del error del campo preliminar que varía según las inestabilidades que se manifiestan en el sistema. Este tipo de

técnicas fueron implementados durante la última década del siglo XX en la gran mayoría de los centros mundiales de pronóstico, en lugares tales como el Centro Europeo (ECMWF), el National Center for Environmental Prediction (NCEP) de Estados Unidos, el Bureau of Meteorology de Australia (BOM), el Japan Meteorological Agency (JMA) de Japón, la Météo France de Francia y el UK Met-Office del Reino Unido.

El segundo grupo de técnicas de asimilación empleados en la actualidad es el de métodos de asimilación por ensambles, cuyo exponente principal lo constituyen los Filtros de Kalman por ensambles (EnKF, Evensen, 1994). Su característica distintiva respecto de otros métodos de asimilación de datos es que los Filtros de Kalman estiman los errores del pronóstico a partir de un ensamble, es decir de un conjunto de pronósticos. Como resultado de esto, la estimación de las condiciones iniciales se realiza generando un ensamble de análisis. Al mismo tiempo, debido a su formulación, estas técnicas tienen en cuenta la evolución temporal del error del campo preliminar, al igual que la técnica 4-D Var. Este tipo de esquemas es actualmente implementado en centros tales como el Canadian Meteorological Centre (CMC) de Canadá y el Korea Meteorological Administration (KMA) de Corea del Sur. Por su parte, el UK Met Office también ha implementado esta técnica operativamente para su sistema de pronóstico por ensambles, conocido por sus siglas MOGREPS (por Met Office Global and Regional Ensemble Prediction System) (Bowler y otros, 2008). También se han implementado técnicas de este tipo en el JMA, en el Servicio Meteorológico de Alemania, en el Centro de Previsión del Tiempo y Estudios Climáticos (CPTEC) de Brasil y en el modelo de pronóstico operativo regional del Servicio Meteorológico de Italia (Bonavita, 2008, 2010).

Cada uno de estos esquemas tiene sus ventajas y desventajas, ya sea en lo que hace a la precisión del análisis obtenido como al costo computacional de su implementación práctica. Algunas de estas ventajas y desventajas las mencionaremos en el próximo capítulo. Más allá de estas cuestiones, podemos afirmar que no existe en la comunidad científica dedicada especialmente a la asimilación de datos un consenso acerca de cuál abordaje resulta ser el mejor.

Por el contrario, la tendencia general en la mayoría de los centros mundiales es la de implementar técnicas híbridas en las que se utilicen ambos abordajes al mismo tiempo, intentando sacar provecho de los aspectos más favorables de las técnicas variacionales y de los EnKF. Es así que varios centros de pronóstico proyectan implementar técnicas híbridas como el 4D-EnVar (Liu y otros, 2008, 2009, Buehner y otros, 2010 a,b), o el 3D-Var/EnKF (Kleist, 2013). También se plantea utilizar la técnica variacional sobre un ensamble obtenido mediante la técnica de asimilación por ensambles (Bonavita, 2012).

Típicamente, en cualquier centro mundial de pronóstico, el ciclo del análisis adopta la forma que se muestra en la Figura 1.1. El ciclo de análisis es esencialmente un sistema de asimilación de datos que, en forma continua, estima las condiciones iniciales para inicializar los diferentes ciclos de pronósticos operativos. Por lo general, un centro de pronóstico global genera análisis cada 6 o 12 horas en tiempos prefijados (por ejemplo a las 00, 06, 12 y 18 UTC). El ciclo del análisis funciona de la siguiente manera: supongamos que tenemos un análisis a las 00 UTC. Con dicho análisis iniciamos el ciclo de pronóstico de las 00 UTC con el modelo de pronóstico, de forma tal de obtener el pronóstico operativo de dicho ciclo. En vistas de generar el análisis del ciclo siguiente, correspondiente a las 06 UTC, utilizamos el pronóstico a 6 horas del ciclo anterior como campo preliminar. Al mismo tiempo, se toman las observaciones disponibles 3 horas antes y 3 horas después de las 06 UTC para, mediante la técnica de asimilación de datos, corregir lo más eficientemente posible los errores del campo preliminar, y generar así el análisis correspondiente a las 06 UTC. Con el nuevo análisis se genera el pronóstico operativo de las 06 UTC, y el ciclo se vuelve a repetir para generar el análisis de las 12 UTC. De esta manera, un sistema de asimilación-pronóstico cíclico permite hacer un uso eficaz de las observaciones, ya que las mismas una vez que son incorporadas en el sistema de asimilación tienen su influencia en los ciclos de pronóstico sub-siguientes, contribuyendo a una mejora tanto del pronóstico como del análisis en tiempos futuros y en otras regiones del globo.

1.3 Antecedentes y situación actual del pronóstico meteorológico a nivel regional

Dado el avance de esta disciplina en las últimas décadas y los recursos computacionales y humanos requeridos, son muy pocos los centros a nivel mundial con la capacidad necesaria para correr en forma operativa un sistema de análisis-pronóstico. Este hecho ha dado lugar a un modelo de trabajo internacional en el que centros como el NCEP que cuenta con capacidad técnica para el desarrollo de modelos y de sistemas de asimilación, tienden a producir herramientas que luego hacen disponibles a la comunidad científica toda, con el fin de ampliar su utilización y testear la potencialidad de las mismas bajo diferentes condiciones. Es dentro de este marco en el que la predicción meteorológica se ha desarrollado en la región. En general, los modelos numéricos utilizados en la región a fines de pronóstico meteorológico en la actualidad, han sido desarrollados en grupos científicos del exterior.

Esto ha permitido a los diferentes países de Sudamérica implementar y desarrollar permanentemente sus sistemas numéricos a fines de pronóstico. En este sentido Brasil es el país que mayor grado de desarrollo ha alcanzado en la temática. Por ejemplo el CPTEC actualmente realiza pronósticos a nivel global con un sistema propio de asimilación de datos, que permite al mismo tiempo alimentar a sus modelos regionales de pronóstico como el Eta (Mesinger y otros, 2012) y el BRAMS (Brazilian Regional Atmospheric Modelling System, Walko y otros, 2000), en sus resoluciones de 15 y 5 km, respectivamente. Asimismo, el sistema de asimilación de datos sirve de base para el sistema de pronóstico por ensambles global de 200 km de resolución y 15 miembros, que se encuentra operativo desde el año 2001.

A modo de ejemplo, podemos citar el modelo WRF (Weather Research and Forecasting, Skamarock y otros, 2008), que desde hace ya varios años es utilizado en el Centro de Investigaciones del Mar y la Atmósfera (CIMA) para la realización de un pronóstico operativo experimental (Saulo y otros, 2009). Este modelo también es utilizado en el Servicio Meteorológico Nacional (SMN) en forma experimental en alta resolución (4 km) desde mediados del 2013

(Matsudo y otros, 2013). También podemos citar al modelo ETA (Janjic, 1990, 1994) que corre en forma operativa 2 veces al día en el Servicio Meteorológico Nacional (SMN) desde el año 2002 hasta el presente. Todos estos modelos en general se utilizan a escala regional, es decir que no generan pronósticos a nivel global, sino para el sur de Sudamérica y los océanos adyacentes. Estos modelos también han sido utilizados para el estudio de situaciones sinópticas de interés particular para nuestra región (Saulo y otros, 2007). Dichos trabajos han sido claves para evaluar estrategias para la mejora del pronóstico a corto plazo sobre la región incluyendo la aplicación de pronósticos por ensambles para la obtención de pronósticos probabilísticos de precipitación (Ruiz, 2009 y Ruiz y otros, 2009) representando la incertidumbre en las condiciones iniciales y en la formulación del modelo.

Dada esta experiencia local, y teniendo en cuenta el contexto científico internacional en la actualidad, surge la cuestión de cómo continuar trabajando en la mejora de los sistemas de pronóstico del tiempo. Dentro de esta perspectiva, la cuestión que aparece como de vital importancia en pos del objetivo propuesto, es la de la asimilación de datos. Esta tarea es la más relegada dentro de esta problemática a nivel nacional, dado que la gran mayoría de los pronósticos operativos en nuestro país son inicializados utilizando los análisis operativos del NCEP. La única excepción a esto lo constituye el modelo ARPE (Australian Regional Primitive Equations, Mc Gregor y otros, 1978, Leslie y otros, 1985), que es un modelo que se corre operativamente en el SMN desde 1998 con baja resolución y que cuenta con un sistema propio de asimilación de datos, que se basa en el método de correcciones sucesivas. Sin embargo, su performance está por debajo de la de cualquier otro sistema de pronóstico que se utilice operativamente sobre la región.

Si extendemos la mirada al ámbito académico, vemos que existen muy pocos antecedentes referidos a la asimilación de datos sobre nuestro país. Primeramente, Vera y otros (1990) aplicaron un método de interpolación optimal a un modelo simplificado (cuasi-geostrófico) y también al modelo

global del NCEP (Vera, 1994 a,b) y muy posteriormente García Skabar y Nicolini (2008) y Nicolini y García Skabar (2011) generaron un reanálisis en alta resolución, basado en la incorporación de datos de superficie, globos piloto y radiosondeos, combinados con los pronósticos del modelo BRAMS mediante la combinación de las técnicas de Barnes y de nudging (García Skabar, 2009).

Si bien estos antecedentes son muy valiosos, desde el punto de vista metodológico los esquemas de asimilación de datos empleados en nuestro país son bastante simplificados si se los compara con el análisis variacional, ya sea en sus versiones 3D y 4D, o con el EnKF. Esta situación pone en evidencia la necesidad de incursionar en la asimilación de datos en vistas de progresar en la mejora de la predicción numérica a nivel nacional. El hecho de ser capaces de realizar un análisis regional en nuestro país presenta una serie de ventajas adicionales con respecto a la situación actual en el que los pronósticos regionales son inicializados con análisis globales. La más importante radica en la posibilidad de contar con un análisis de mayor resolución horizontal (del orden de los 5 km) que el análisis global, los cuales en la actualidad rondan los 15 km de resolución horizontal. Asimismo, existen observaciones locales, generalmente de superficie, que por lo general no ingresan en el sistema global de telecomunicaciones GTS (Global Telecommunication System) y que son los datos asimilados por los centros globales de pronóstico. La posibilidad de contar con más información para un sistema de asimilación local, proveería al análisis resultante de información adicional que actualmente no se encuentra en el análisis global, y en consecuencia se deberían obtener pronósticos numéricos mejores y por ende más útiles. Una ventaja adicional que se obtendría de un sistema de análisis local es la posibilidad de poder trabajar en lo sucesivo para mejorar y optimizar el sistema de asimilación para nuestra región.

Es por estos motivos que existen planes para implementar en el futuro un sistema de asimilación de datos operativo en el SMN (Dillon y otros, 2016). Sin embargo, la mirada no debe detenerse solamente en el desarrollo de este sistema a los fines de un pronóstico numérico, ya que la asimilación de datos

debe pensarse en la meteorología de nuestro país dentro de un contexto más amplio. Por un lado se está llevando a cabo en la actualidad el proyecto SINARAME (Sistema NAcional de RAdares MEteorológicos), cuyo fin es el de aumentar la cobertura espacial de los radares meteorológicos operativos en nuestro país. Esto permitirá el monitoreo permanente de tormentas en gran parte de nuestro país, y servirá como plataforma para el desarrollo del pronóstico inmediato (conocido como nowcasting), que es una rama de la predicción meteorológica a plazos de hasta 6 horas que se aboca a fenómenos asociados a tormentas, y que constituye una de las deudas pendientes de la meteorología en nuestro país. En este punto, la asimilación de datos es un pilar fundamental para el desarrollo del pronóstico inmediato, ya que el fin último es el de asimilar información proveniente de los radares meteorológicos, lo que implica la asimilación de observaciones en muy alta resolución, en escalas espaciales de centenares de metros.

Dentro de esta perspectiva es que se enmarca el programa Alert.ar, cuyo objetivo fundamental es dar el puntapié para el desarrollo del pronóstico inmediato y así mejorar la calidad de los pronósticos y alertas tempranas a la población, y/o a diferentes organismos afectados por algún evento meteorológico particular. Por lo expuesto anteriormente, la asimilación de datos será una herramienta imprescindible para alcanzar los objetivos propuestos en dicho programa. En este contexto tenemos también el futuro experimento RELAMPAGO (Remote sensing of Electrification, Lightning, and Mesoscale/Microscale Processes with Adaptive Ground Observation), el cual se llevará a cabo a fines de 2017, y que tendrá como objetivo ganar conocimiento acerca de las características de la convección en nuestro país. En dicho experimento la asimilación de datos servirá de plataforma fundamental para comprender de forma más acabada las características de la convección en nuestro país.

En conclusión, a fines de posibilitar el desarrollo de la meteorología operativa en nuestro país, la asimilación de datos es una técnica que demanda ser desarrollada con urgencia, para dar valor agregado a los pronósticos globales

que llegan al SMN. En un sistema globalizado, como el que existe en la actualidad, es de esperar que los pronósticos globales continúen aumentando la resolución y sólo la inclusión de datos locales (radares, perfiladores de viento u otros) con más alta resolución aún, va a proporcionar el valor agregado que se requiere para contribuir efectivamente a la provisión de alertas ante eventos severos.

1.4 Motivaciones y objetivos

Dada la situación de la meteorología operativa en nuestro país y las perspectivas futuras detalladas en la sección anterior, la presente Tesis se avoca al estudio de la implementación de un sistema de asimilación-pronóstico a nivel regional, estudiando las fuentes de error presentes en un sistema de análisis-pronóstico regional. Para ello se ha escogido basar el estudio en la combinación de un EnKF con el modelo de pronóstico WRF. Esta es una estrategia que permite la generación del análisis y de un ensamble de pronósticos, ofreciendo una alternativa completa al problema del desarrollo de un sistema de pronóstico a escala regional. Sin embargo, la implementación de un sistema de asimilación-pronóstico adecuado para modelos regionales conlleva una serie de complejidades que es necesario abordar a los fines de obtener un sistema óptimo desde el punto de vista de la generación del análisis y también de la calidad de los pronósticos que de él se deriven. En la Figura 1.2 se muestra el funcionamiento de un sistema de análisis-pronóstico regional, cuya diferencia fundamental con un sistema global radica en que es necesario utilizar condiciones de borde provenientes de un modelo global. Esta componente del sistema es crítica a fines de generar un análisis regional por dos motivos. En primer lugar por el hecho de que las condiciones de borde son necesarias para integrar un modelo regional. En segundo lugar las condiciones de borde representan una fuente de incertidumbre adicional que no está presente en un sistema de análisis global (si no tenemos en cuenta los bordes inferiores) y que a lo largo de la presente Tesis será un tema de discusión.

Una de las primeras cuestiones que debe plantearse es cuáles son las fuentes de error presentes en un sistema de asimilación regional e intentar contemplarlas en el diseño experimental. En términos generales, las fuentes de error están dadas por las incertidumbres en las condiciones iniciales, en las condiciones de contorno y en las provocadas por los errores del modelo (Kalnay, 2003, Palmer y Hagedorn 2006). Consecuentemente, en esta Tesis nos planteamos determinar cómo generar un ensamble que represente adecuadamente estas fuentes de error. Para ello, se realiza en primer lugar un conjunto de experimentos idealizados con el fin de determinar la importancia relativa de las fuentes de errores mencionadas en la calidad de un análisis en nuestra región. Como segundo paso, se busca implementar una serie de estrategias que permitan contemplar la presencia de las fuentes de error dentro del sistema de asimilación.

Otra motivación de este trabajo de Tesis radica en analizar el impacto que tiene la resolución horizontal sobre la calidad del análisis y de los pronósticos. Por un lado, sabemos que la discretización horizontal de las ecuaciones da lugar a la aparición de errores de truncado en el cálculo de la solución que son parte del error de modelo y cuya magnitud es función de la resolución con la que se resuelven numéricamente las ecuaciones. Al mismo tiempo las limitaciones en la resolución horizontal impiden que determinados procesos de escala pequeña sean explícitamente representados por el modelo numérico. Dado que muchos de estos procesos son fundamentales para una adecuada representación de la circulación en las escalas que sí pueden ser resueltas explícitamente, es necesario incluir algoritmos o parametrizaciones que representen su efecto de manera simplificada. De esta manera, se espera que al modificar la resolución del modelo se tenga un impacto sobre la magnitud de los errores de modelo. Esta motivación se basa también en la necesidad de cuantificar cuánto puede impactar el aumento de resolución bajo la hipótesis que la correcta representación de la mesoescala debería conducir a una mejora de los pronósticos, ya que las circulaciones en pequeña escala suelen estar asociadas con el desarrollo de convección y precipitación abundante. En este punto debemos tener en cuenta que los centros globales proveen sistemas de

análisis con relativa baja resolución para inicializar un modelo de pronóstico regional (35 km a la fecha) con lo que es en la alta resolución espacio-temporal en la que un centro regional debe abocar la mayor proporción de esfuerzos. La hipótesis subyacente es que un análisis realizado en alta resolución espacial y temporal (i.e ~20 km, en forma horaria o tri-horaria), incluirá datos que muy probablemente sean rechazados en un ciclo de menor resolución, por incompatibilidad con la escala resuelta por el modelo. Estos datos deberían contribuir a caracterizar la circulación de una manera mucho más cercana a la realidad y, consecuentemente, serían importantes para inicializar pronósticos a corto plazo, sobre todo cuando se avencinan condiciones de tiempo severo (Stensrud et al 2009, Ha y Snyder 2014). En esta línea, estudios como el de Mass y otros (2002) han encontrado que para capturar los fenómenos de mesoescala de modo razonable, la resolución del modelo de pronóstico debería ser de al menos 4 km. Por lo tanto, una meta secundaria dentro de este objetivo es el de determinar si el aumento de la resolución horizontal del análisis resulta en una mejora del pronóstico de eventos de alto impacto, por ejemplo en situaciones de convección organizada. El trabajo de Holt y otros (2013) que se aboca a la representación de ciclones tropicales echa luz acerca de esta cuestión. En dicho trabajo se concluye que incrementar la resolución horizontal del modelo de 100 km a 36 km no se obtienen grandes mejoras en la representación de los ciclones tropicales, y que por lo tanto se requiere trabajar en escalas mucho más pequeñas para obtener mejoras, del orden de los 10 km.

Los resultados de esta Tesis permitirán sentar las bases para la implementación de un futuro sistema de asimilación de datos operativo a nivel regional sobre Sudamérica. Este sistema de asimilación de datos operativo representará un gran avance para la meteorología operativa de nuestro país, ya que ayudará a describir en mayor detalle sistemas meteorológicos de menor escala, hacer un mejor aprovechamiento de las observaciones disponibles y permitir una mejora en la calidad de los pronósticos meteorológicos sobre nuestra región que incluya la incertidumbre a partir de la utilización de ensambles. Asimismo, estos resultados permitirán avanzar en el entendimiento

de cómo las diferentes fuentes de incertidumbre afectan el desempeño de los sistemas de asimilación de datos a nivel regional y de la importancia de generar ensambles que incorporen un tratamiento lo más completo posible de las mismas.

1.5 Organización de la Tesis

El presente trabajo de Tesis está organizado de la siguiente manera. En el Capítulo 2 se formula el planteo teórico del problema de la asimilación de datos y se describen las técnicas de asimilación basadas en EnKF, haciendo hincapié en el algoritmo de asimilación denominado Local Ensemble Transform Kalman Filter (LETKF, Hunt y otros, 2007). Junto con el LETKF, también se describen algunas técnicas preparadas para mitigar los efectos del error de modelo en la calidad del análisis. Finalmente, en dicho capítulo se describen las métricas utilizadas en esta Tesis a los fines de la verificación de los resultados.

En el Capítulo 3 se estudia en primer lugar el impacto de incorporar datos a nivel regional. Luego se analizan los resultados de introducir errores en el modelo y en las condiciones de borde. En el Capítulo 4, una vez conocidos los efectos producidos por las fuentes de error introducidas en el capítulo anterior, se implementan técnicas destinadas a mitigar los efectos producidos por dichas fuentes de error.

El Capítulo 5 está dedicado al estudio de la sensibilidad de la calidad del análisis frente a la resolución horizontal del mismo. En particular se analiza el grado de mejora del análisis al incrementar la resolución, para luego verificar la calidad del pronóstico derivado de los mismos. Por último, se analiza la calidad del pronóstico de los diferentes sistemas de análisis en situaciones de convección organizada.

Finalmente, en el Capítulo 6 se vuelcan las conclusiones más importantes de los resultados obtenidos en los capítulos previos, y se traza una línea de investigación y desarrollo futuro de los aspectos más relevantes.

Capítulo 2: Técnicas de asimilación de datos por ensambles y su verificación

2.1 Introducción

Habiendo definido en el capítulo anterior el objetivo principal de la asimilación de datos, junto con sus diversos esquemas, el presente capítulo profundiza en algunos aspectos teóricos de la asimilación de datos, sin llegar a ser una revisión exhaustiva de un tema sumamente amplio y complejo.

En este capítulo se realiza en primer lugar una descripción de la técnica de asimilación empleada en esta Tesis, en donde se incluye el planteo formal de los Filtros de Kalman (KF). Junto con esto, se describen las metodologías empleadas para mitigar algunos problemas relacionados con dicho esquema de asimilación. Esta primera parte del presente capítulo está basado principalmente en Kalnay (2003), Hunt y otros (2007) y Lahoz (2010).

La segunda parte del presente capítulo está avocada a la descripción de las métricas de verificación utilizadas en los Capítulos 3, 4 y 5 de esta Tesis.

2.2 Filtros de Kalman

Los KF provienen originalmente de problemas de ingeniería. El KF fue derivado por primera vez por Kalman (1960) para un modelo perfecto lineal y con errores gaussianos (Kalman y Bucy, 1961). Sin embargo, su aplicación a fluidos geofísicos llegó varias décadas más tarde, con el trabajo pionero de Evensen (1994). Desde entonces, su implementación ha crecido rápidamente en diversas aplicaciones de la meteorología y la oceanografía, hasta posicionarse como una alternativa viable frente a la técnica variacional, la cual se encontraba muy en boga a mediados de la década de 1990.

A continuación, desarrollaremos el planteo formal de los KF. Todo el desarrollo desde la definición original de los KF hasta llegar al LETKF se muestra esquemáticamente en la Figura 2.1.

Primeramente supongamos que la evolución de nuestro sistema geofísico (cuyo estado viene dado por un vector x de dimensión m) está regido por un modelo M , el cual evoluciona al sistema desde un estado inicial en un instante de tiempo $i-1$ (que daremos en llamar x_{i-1}^a o análisis) a un estado x^b en el instante i (que denotaremos como x_i^b o pronóstico). Hasta aquí, el modelo M puede ser o no lineal. Formalmente, planteamos lo siguiente:

$$x_i^b = M_{i-1,i}[x_{i-1}^a] + \eta_i \quad (2.1)$$

En donde la expresión $M_{i-1,i}[\]$, denota la integración desde el tiempo $i-1$ a i , del modelo M , utilizando en este caso el vector análisis en el tiempo $i-1$ como condición inicial. Por su parte el término η_i representa el error del modelo M en el instante i , con una matriz de covarianza Q_i .

Supongamos además que tenemos en el tiempo i una serie de observaciones y_i^o de dicho sistema que dependen del estado del mismo y que contienen errores cuya distribución es gaussiana, con media cero y varianza ε_i^o . Dichas observaciones las podemos escribir de la siguiente forma:

$$y_i^o = H(x_i^t) + \varepsilon_i^o \quad (2.2)$$

En donde el vector x_i^t denota el estado real del sistema en el tiempo i . H denota al operador de las observaciones, cuya función es la de transformar las variables del espacio del estado (x) al de las observaciones (y). Es decir, obtiene el valor del vector x^b en los puntos y tiempos de las observaciones. En este punto, consideramos al operador H como un operador no lineal.

El problema a resolver a continuación es el de determinar, dadas las observaciones y_i^o , cuál es la evolución o trayectoria del sistema que mejor se ajusta a dichas observaciones.

Como primera aproximación, podemos plantear el caso en que el modelo es lineal (en cuyo caso lo denotaremos como **M**) y que el operador H también es lineal (en cuyo caso denotaremos como **H**). En este caso estamos bajo las condiciones del KF, en las que suponemos que la distribución de estados

posibles del sistema puede describirse mediante una función de probabilidad con distribución gaussiana. Bajo esta condición sólo necesitamos conocer un vector que describa su estado promedio (primer momento de la distribución) y una matriz que describa la covarianza de los estados (segundo momento de la distribución). Por lo tanto, podemos suponer que en el tiempo $i-1$ tenemos un análisis, con una estimación $\bar{x}_{i-1}^a$ y una matriz de covarianza asociada P_{i-1}^a . En términos probabilísticos, $\bar{x}_{i-1}^a$ y P_{i-1}^a representan la media y la covarianza de la distribución de probabilidad de los posibles estados del sistema dadas las observaciones de los tiempos 1 a $i-1$. El Filtro de Kalman determina el vector $\bar{x}_i^a$ y la matriz de covarianza P_i^a en el instante de tiempo i , dadas las observaciones entre los tiempos $i-1$ e i . Desde esta perspectiva, el vector $\bar{x}_i^a$ representa la estimación del estado más probable del sistema, mientras que la matriz P_i^a representa el error o incertidumbre asociada a la estimación del estado del sistema. Para obtener la distribución de probabilidad de estados del sistema en el tiempo i , debemos realizar dos pasos.

El primero consiste en propagar la estimación del estado del sistema $\bar{x}_{i-1}^a$ y su covarianza P_{i-1}^a utilizando el modelo de pronóstico para generar el campo preliminar del estado del sistema en el tiempo i . Al campo preliminar lo denotaremos como $\bar{x}_i^b$, mientras que a su matriz de covarianza la denotaremos como P_i^b . Este paso se conoce comúnmente como paso de pronóstico. Formalmente obtenemos lo siguiente:

$$\bar{x}_i^b = \mathbf{M}_{i-1,i}[\bar{x}_{i-1}^a] + \eta_i \quad (2.3)$$

$$P_i^b = \mathbf{M}_{i-1,i}[P_{i-1}^a]\mathbf{M}_{i-1,i}^T + Q_i \quad (2.4)$$

Dado que el modelo es lineal, una distribución gaussiana de estados que se propaga temporalmente alcanza una distribución de estados finales que también es gaussiana. Por lo tanto, las ecuaciones (2.3) y (2.4) alcanzan para definir la distribución de probabilidades de los estados del sistema en el tiempo

i. O dicho de otra manera, la ecuación (2.3) nos da el estado más probable del sistema que ha evolucionado desde su estado anterior en el tiempo $i-1$ mediante el modelo $\mathbf{M}$; mientras que la ecuación (2.4) nos da la incertidumbre de dicha estimación, siendo que ha evolucionado desde el tiempo $i-1$ y que se ha originado a partir de la incertidumbre de la estimación del estado en dicho instante de tiempo. Es importante notar en este punto que como el sistema es lineal, si el modelo es perfecto (i.e: no tiene errores), la única fuente de incertidumbre o error la constituye el error en la estimación del estado en el tiempo $i-1$, y las ecuaciones (2.3) y (2.4) se simplifican al eliminarse los términos η_i y Q_i , respectivamente. En lo sucesivo, se asumirá que el modelo es perfecto. El segundo paso consiste en realizar lo que se llama el análisis en donde se busca obtener la estimación del vector $\bar{x}_i^a$ y de la matriz P_i^a . Para ello es menester hacer uso de algún criterio matemático de teoría de filtrado. Entre ellos podemos escoger el criterio de máxima probabilidad a posteriori o el de varianza mínima (Jazwinski, 1970). Esto es equivalente a aplicar la regla de Bayes para la maximización de la distribución de probabilidad conjunta del estado del sistema, dadas las observaciones y^o y la estimación previa del estado del sistema $\bar{x}_i^b$ y P_i^b . Todos estos abordajes conducen a la misma estimación en el tiempo i , siendo que estamos en condiciones de linealidad. La estimación de máxima probabilidad a posteriori $p(x_i)$, lleva a maximizar la siguiente expresión:

$$p(x_i) = a * \exp \left[-\frac{1}{2} \left([x_i - \bar{x}_i^b]^T (P_i^b)^{-1} [x_i - \bar{x}_i^b] + [y_i^o - \mathbf{H}_i x_i]^T R_i^{-1} [y_i^o - \mathbf{H}_i x_i] \right) \right] \quad (2.5)$$

Donde a es una constante cualquiera que no depende de $\bar{x}_i^b$, ni de y_i^o . Por su parte, la matriz R_i representa la matriz de covarianza de los errores de las observaciones. La máxima probabilidad a posteriori de la ecuación (2.5) representa la máxima probabilidad del estado x del sistema dadas las observaciones y el campo preliminar. Maximizar la probabilidad de x , es equivalente a minimizar el exponente de la ecuación (2.5) lo que motiva la definición de la siguiente función de costo:

$$J(x_i) = [x_i - \bar{x}_i^b]^T (P_i^b)^{-1} [x_i - \bar{x}_i^b] + [y_i^o - H_i x_i]^T R_i^{-1} [y_i^o - H_i x_i] + c \quad (2.6)$$

En este contexto la idea es encontrar el vector $x_i = \bar{x}_i^a$, tal que la función $J(x_i)$ sea mínima. Podemos ver entonces que el criterio del KF se basa en el de varianza mínima. Debido a que el vector $\bar{x}_i^b$ es el estado del sistema más probable teniendo en cuenta todas las observaciones hasta el tiempo $i-1$, dichas observaciones no entran en juego en la función de costo para el nuevo análisis. Esto significa que las observaciones que son utilizadas en un ciclo, no vuelven a utilizarse en los ciclos siguientes. Sin embargo, no se debe perder de vista que las observaciones entre los tiempos 1 e $i-1$ están implícitamente contenidas en la estimación de $\bar{x}_i^b$.

Una vez que obtenemos el vector $\bar{x}_i^a$, podemos plantear la siguiente igualdad:

$$\begin{aligned} [x_i - \bar{x}_i^b]^T (P_i^b)^{-1} [x_i - \bar{x}_i^b] + [y_i^o - H_i x_i]^T R_i^{-1} [y_i^o - H_i x_i] \\ = [x_i - \bar{x}_i^a]^T (P_i^a)^{-1} [x_i - \bar{x}_i^a] + c' \end{aligned} \quad (2.7)$$

Igualando los términos lineales y cuadráticos en x_i en la ecuación (2.7), obtenemos las expresiones del vector $\bar{x}_i^a$ y de la matriz de covarianza P_i^a para el nuevo ciclo:

$$\bar{x}_i^a = P_i^a \left[(P_i^b)^{-1} \bar{x}_i^b + H_i^T R_i^{-1} y_i^o \right] = \bar{x}_i^b + P_i^a H_i^T R_i^{-1} (y_i^o - H_i \bar{x}_i^b) \quad (2.8)$$

$$P_i^a = \left[(P_i^b)^{-1} + H_i^T R_i^{-1} H_i \right]^{-1} = P_i^b (I + P_i^b H_i^T R_i^{-1} H_i)^{-1} \quad (2.9)$$

Y de la ecuación (2.8) podemos definir la matriz de pesos o matriz de ganancia de Kalman como:

$$K_i = P_i^a H_i^T R_i^{-1} = P_i^b H_i^T [R_i + H_i P_i^b H_i^T]^{-1} \quad (2.10)$$

Podemos ver de la ecuación (2.8) que el análisis se obtiene sumándole al campo preliminar, el vector de innovaciones $(y_i^o - H_i \bar{x}_i^b)$ pesado por la matriz de ganancia. Al mismo tiempo vemos de la ecuación (2.10) que la matriz de

ganancia K_i está dada por el producto entre la matriz de covarianza de los errores del campo preliminar, la de covarianza de los errores del campo de las observaciones y la inversa de la covarianza del error total. Es importante notar que cuanto mayor sea el error del campo preliminar (P^b) en comparación con el error de las observaciones, mayor será la corrección introducida a dicho campo. Y a la inversa, si el error del campo preliminar es relativamente pequeño, el efecto de las observaciones será pequeño en modificar dicho campo a la hora de obtener el nuevo análisis. De esta manera, la matriz de ganancia da el peso óptimo que garantiza que, dado los errores del campo preliminar y de las observaciones, el error del análisis sea mínimo en el caso lineal. Esto último se traduce en que la precisión del análisis será la suma de las precisiones del campo preliminar y de las observaciones. De este hecho resulta que la covarianza de los errores del análisis se vea reducida por la matriz de ganancia o de pesos óptimos, tal como se observa en la siguiente ecuación:

$$P_i^a = (I - K_i H_i) P_i^b \quad (2.11)$$

En el caso lineal la solución del problema es relativamente fácil de encontrar y tenemos la garantía de que existe un único mínimo de la función costo (2.6). Además, en este caso el Filtro de Kalman resuelve esencialmente el mismo problema que el esquema variacional 4-DVAR. (Lorenc, 1986).

Cuando el modelo está regido por procesos no lineales, es posible extender el enfoque del Filtro de Kalman, aunque en este caso no hay garantías de que el filtro resulte óptimo. El procedimiento en este caso es el siguiente: por un lado, en el paso del pronóstico, el campo preliminar se calcula a partir del modelo no lineal, pero la matriz de covarianza P_i^b se calcula a partir de la linealización del modelo alrededor de $\bar{x}_{i-1}^a$. Es decir:

$$\bar{x}_i^b = M_{i-1,i} [\bar{x}_{i-1}^a] \quad (2.12)$$

$$P_i^b = M_{i-1,i} [P_{i-1}^a] M_{i-1,i}^T \quad (2.13)$$

Donde ahora el término $\mathbf{M}_{i-1,i}$ de (2.13) representa el modelo tangente lineal del modelo no lineal $M_{i-1,i}$, mientras que el modelo $\mathbf{M}_{i-1,i}^T$ es el modelo adjunto de $M_{i-1,i}$ (Errico, 1997). Por otro lado, en las ecuaciones (2.8)-(2.10), el término no lineal H_i es reemplazado por su tangente lineal $\mathbf{H}_i$. Este sistema se conoce como Filtro de Kalman extendido.

2.3 Fitros de Kalman por ensamble

Evensen (1994) propuso que la matriz P_i^b puede estimarse a partir de un ensamble de pronósticos. En rigor, este enfoque denominado Filtro de Kalman por ensambles, utiliza un ensamble con un número k de miembros, en donde cada miembro $x_i^{b(j)}$ evoluciona desde su respectivo análisis $x_{i-1}^{a(j)}$ de la siguiente forma:

$$x_i^{b(j)} = M_{i-1,i} \left(x_{i-1}^{a(j)} \right) \quad (2.14)$$

De esta manera, las ecuaciones (2.12) y (2.13) se escriben como:

$$\bar{x}_i^b = k^{-1} \sum_{j=1}^k x_i^{b(j)} \quad (2.15)$$

$$P_i^b = (k-1)^{-1} \sum_{j=1}^k \left(x_i^{b(j)} - \bar{x}_i^b \right) \left(x_i^{b(j)} - \bar{x}_i^b \right)^T = (k-1)^{-1} X^b (X^b)^T \quad (2.16)$$

Donde las matrices X^b y $(X^b)^T$ en (2.16) denotan las perturbaciones del campo preliminar con respecto a la media. De esta manera, la columna j -ésima de la matriz X^b representa la diferencia del miembro j con respecto a la media dentro del ensamble del campo preliminar.

De manera análoga, el vector $\bar{x}_i^a$ y la matriz P_i^a se definen ahora como:

$$\bar{x}_i^a = k^{-1} \sum_{j=1}^k x_i^{a(j)} \quad (2.17)$$

$$P_i^a = (k-1)^{-1} \sum_{j=1}^k (x_i^{a(j)} - \bar{x}_i^a)(x_i^{a(j)} - \bar{x}_i^a)^T = (k-1)^{-1} X^a (X^a)^T \quad (2.18)$$

En este caso, las matrices X^a y $(X^a)^T$ tienen un significado análogo a las matrices X^b y $(X^b)^T$ de (2.16), para el análisis.

Existen en la literatura básicamente dos tipos de EnKF, los de observaciones perturbadas (Burgers y otros, 1998, Houtekamer y Mitchell, 1998, Keppenne (2000)), y los llamados “ensemble square-root filters” (EnsSRF) (Bishop y otros, 2001, Anderson, 2001, Whitaker y Hamill, 2002, Ott y otros, 2004 y Hunt y otros, 2007).

En los primeros, se perturban las observaciones al azar, de forma tal de generar un ensamble de observaciones con media igual a las observaciones dadas por el campo preliminar y covarianza igual a la matriz R . Este procedimiento puede ayudar a evitar uno de los problemas de los EnKF que veremos en la próxima sección, que es la subestimación de la covarianza del análisis. En contrapartida, esta metodología puede introducir una fuente adicional de errores de muestreo (Whitaker y Hamill, 2002).

Los EnsSRF generan un ensamble de análisis cuya media y covarianza satisfacen las ecuaciones del KF para modelos lineales sin la necesidad de introducir perturbaciones estocásticas. Existe una gran variedad de filtros determinísticos debido a que existen diferentes formas de perturbar el ensamble de análisis y obtener la misma covarianza de errores del análisis. Entre los diferentes filtros determinísticos podemos mencionar el Ensemble Adjustment Kalman Filter (EAKF) de Anderson (2001), que fue implementado en el Data Assimilation Research Testbed (DART). Otros filtros de este tipo son el Ensemble Square Root Filter (EnsSRF) de Whitaker y Hamill (2002), el Ensemble Transform Kalman Filter (ETKF) de Bishop y otros (2001) y el LETKF

(Hunt y otros, 2007) entre otros. Tippet y otros (2003) realizan una revisión exhaustiva de los EnsSRF, a excepción del LETKF.

2.4 Fortalezas y debilidades de los EnKF

Una vez definidos formalmente los EnKF, en esta sección analizamos las principales ventajas que presentan estos esquemas con respecto a los esquemas variacionales, para luego concentrarnos en las dificultades más comunes que suelen encontrarse al aplicar dichos esquemas.

2.4.1 Ventajas del EnKF

La principal ventaja de los KF, y en particular de los EnKF, es que consideran la evolución de la matriz de covarianza de los errores entre dos ciclos de asimilación sucesivos. Esto significa que provee una estimación de los llamados “errores del día”, tanto en el campo preliminar (P_i^b) como en el análisis (P_i^a), los cuales varían espacial y temporalmente por las inestabilidades presentes en el flujo atmosférico. Este aspecto de los EnKF es la principal ventaja con respecto al esquema variacional 3D-Var, en donde los errores del día comúnmente son representados por una matriz de covarianza estática que representa típicamente una estadística de los errores del modelo. En el 4D-Var en cambio, la matriz de covarianza evoluciona temporalmente dentro de la ventana de asimilación, aunque al inicio de la misma dicha matriz no contiene información acerca de los errores del día. Por este motivo, dicho esquema sólo considera en forma parcial los errores del día.

Otra de las ventajas del EnKF radica en el hecho de que típicamente en la atmósfera en la escala sinóptica el número de direcciones de máximo crecimiento de los errores es del orden $O(100)$. Este hecho nos permite describir las direcciones de máximo crecimiento de los errores con un número de miembros que es muy pequeño si lo comparamos con el número de grados de libertad del sistema (entre 10^6 y 10^7). Este hecho hace que los EnKF sean una alternativa viable en modelos de fluidos geofísicos, frente a otras

alternativas como el Filtro de Kalman extendido que resulta demasiado costoso para dichas aplicaciones. Sin embargo, cuando se trabajan en escalas más pequeñas (como por ejemplo la convectiva), el número de miembros necesarios en el EnKF se incrementa. No obstante esto, el número de miembros necesarios para representar los errores del día se pueden reducir si se consideran las inestabilidades en forma local.

Una tercera e importante ventaja de los EnKF es que, tal como mencionamos en el Capítulo 1, proveen las condiciones iniciales para la confección de un pronóstico por ensambles, lo cual permite resolver simultáneamente las dos principales problemáticas del pronóstico numérico: la estimación de la condición inicial y la estimación del error del pronóstico.

2.4.2 Debilidades del EnKF

A pesar de las grandes ventajas que ofrecen los EnKF, estos esquemas presentan una serie de desventajas o puntos débiles que es necesario atacar si se pretende obtener análisis de una calidad comparable a los obtenidos mediante técnicas variacionales como la 4D-Var por ejemplo.

Uno de los problemas de los EnKF surge por el hecho de estimar la covarianza de los errores del pronóstico a partir de una muestra con un pequeño número de miembros en comparación con los grados de libertad del sistema dinámico. Como consecuencia de esto es común que aparezcan correlaciones espurias entre diferentes puntos separados grandes distancias entre sí. Actualmente este problema se resuelve utilizando lo que se conoce como localización de la matriz de covarianza que se discutirá en mayor detalle más adelante.

Otro gran inconveniente que tienen estos esquemas es que tienden a subestimar los errores del análisis. Esto se da como resultado de utilizar un número limitado de miembros para estimar las direcciones de inestabilidad del flujo. En consecuencia, la matriz de covarianza tenderá a subestimar sistemáticamente el error del análisis, lo cual lleva a que el error estimado del campo preliminar en los ciclos siguientes sea menor al real. Esto puede conducir a que se produzca lo que se conoce como la divergencia del filtro,

escenario en el cual esencialmente las observaciones son completamente ignoradas por el filtro por el hecho de que la matriz P^b es demasiado pequeña en comparación con el error real del vector $\bar{x}_i^b$. Como resultado de esto, el análisis resultante estará totalmente alejado de la realidad.

2.5 Localización en EnKF

Tal como se mencionó anteriormente, en los EnKF es necesario implementar alguna técnica de localización de la matriz de covarianza para evitar la aparición de correlaciones espurias entre los errores de variables tal como muestra la Figura 2.1.

Algunos autores como Houtekamer y Mitchell (2001) y Hamill y otros (2001), introdujeron la localización en la matriz P^b . La idea de este procedimiento es la de multiplicar cada término de esta matriz por un factor de tipo gaussiano (Gaspari y Cohn, 1999) de la forma:

$$W = \exp(-r_{i,j}^2/2L^2) \quad (2.19)$$

En donde $r_{i,j}^2$ representa la distancia entre dos puntos de retícula, y L es la escala de localización. El efecto de esta localización es llevar a 0 la correlación entre puntos suficientemente alejados. Mitchell y otros (2002) documentaron que la sola introducción de la localización introduce desbalances en el campo del análisis. Lorenc (2003) por su parte mostró que la localización impuesta sobre la matriz P^b , lleva a desbalances entre el geopotencial y el viento, provocando que el flujo sea altamente ageostrófico en el análisis.

Para evitar este problema Hunt y otros (2004) y Miyoshi (2005) utilizaron una localización alternativa al multiplicar a la matriz de errores de las observaciones R^{-1} por el factor gaussiano. Esto es equivalente a asumir que las observaciones a grandes distancias del punto del análisis tienen errores

grandes y que en consecuencia su impacto en dicho punto es pequeño. Debido a que la matriz R suele ser diagonal en la mayoría de las aplicaciones, a diferencia de P^b , es menos probable que este procedimiento provoque desbalances en el campo del análisis (Greybush y otros, 2011). No obstante, esta técnica tiene el peligro potencial de provocar discontinuidades en el análisis por el hecho de imponer un radio de corte para asimilar observaciones, especialmente si dicho radio no es lo suficientemente grande.

Greybush y otros (2011) compararon las diferentes técnicas de localización y encontraron que la distancia óptima de localización de las matrices P^b y R es diferente, siendo más larga para P^b . A iguales escalas de localización de ambas técnicas, la localización aplicada a R provee menor desbalance en el análisis.

2.6 Representación de errores en EnKF

Como ya hemos mencionado, un EnKF que utiliza las ecuaciones (2.8) y (2.9) para estimar el análisis y su error a partir de las ecuaciones (2.17) y (2.18), tenderá a subestimar dichos parámetros. Esto es debido al error de muestreo como consecuencia de utilizar un ensamble demasiado pequeño. Dicho efecto puede conducir a la divergencia del filtro, en donde el análisis se aleja totalmente de la realidad. Este problema puede agravarse aún más si el modelo es imperfecto, ya que estimar la matriz de covarianza a partir de un ensamble de pronósticos en donde solo se perturba la condición inicial es equivalente a asumir que el modelo es perfecto. Por lo tanto, la estimación del error a partir de la matriz de covarianza es mucho menor al error real, y en consecuencia el riesgo de que el filtro diverja es mayor.

Existen diversas técnicas para controlar este comportamiento, las cuales se muestran en la Figura 2.1 en su esquina inferior derecha. Por un lado existen técnicas que estiman el efecto del error del modelo a partir de incluirlo en la matriz de covarianza, los que se conocen en general como técnicas de inflación. Otra técnica que puede ser útil es el uso de ensambles multi-modelo, ya que en este caso el error se incluye de forma explícita en la matriz P^b .

Asimismo, existen técnicas que intentan corregir la componente sistemática del error mediante la remoción del bias del campo preliminar. Finalmente, podemos citar la estimación de parámetros como otra técnica para representar los errores del análisis. Las técnicas de inflación consisten en un procedimiento *ad hoc* que aumenta los valores de la matriz de covarianza, ya sea del campo preliminar o del análisis, durante el ciclo del análisis. En rigor, este tipo de procedimiento es análogo a agregar un término de covarianza de error del modelo asumiendo que el modelo es imperfecto, una práctica común en la implementación de los KF. La Figura 2.2 muestra las diversas metodologías de inflación aplicadas a un EnKF, con las ecuaciones que los definen y los parámetros a estimar.

Una forma de incrementar los valores de P^b es aplicar un método híbrido en donde se agrega una matriz de covarianza B proveniente del método variacional 3D-Var a la matriz de covarianza del campo preliminar (Hamill y Snyder, 2000). En términos matemáticos, en este método híbrido la matriz de covarianza $P_{híbrido}^b$ se calcula de la siguiente forma:

$$P_{híbrido}^b = (1 - \alpha)P_{EnKF}^b + \alpha B_{3D-Var} \quad (2.20)$$

En este caso el parámetro α es un parámetro que puede ser ajustado en forma empírica. Valores de α iguales a 0 determina un método EnKF y un valor igual a 1, el método 3D-Var.

Otros métodos aplican un factor de inflación (denotado por α_i^a) a la matriz de covarianza de los errores del campo preliminar, como por ejemplo la inflación multiplicativa (Anderson y Anderson, 1999, Hamill y otros, 2001). Dicho método simplemente multiplica artificialmente a los elementos de la matriz de covarianza de los errores del campo preliminar por un factor constante mayor a 1, como indica la siguiente ecuación:

$$P^b = \alpha_i^a * P^b \quad (2.21)$$

Otro procedimiento comúnmente utilizado es de la inflación aditiva (Mitchell y Houtekamer, 2000), en donde a cada miembro del ensamble de análisis o del campo preliminar se les agregan perturbaciones tomadas de una distribución conocida (generalmente proveniente de una climatología de errores) con media cero.

Este procedimiento suele funcionar mejor que la inflación multiplicativa cuando el error del análisis está dominado por el error del modelo (Whitaker y otros, 2008, Houtekamer y otros, 2009). Por su parte la inflación multiplicativa funciona mejor en situaciones donde el error del análisis está más dominado por los errores de muestreo producido por el número limitado de miembros del ensamble (Whitaker y Hamill, 2012). Este hecho plantea la posibilidad de implementar algoritmos de inflación que utilizan ambas técnicas a la vez. En general lo que hacen estos procedimientos es relajar las perturbaciones del análisis hacia las perturbaciones del campo preliminar (Zhang y otros, 2004). En este caso, la matriz de perturbaciones del análisis X^a , se reemplaza por la siguiente expresión:

$$X^a \leftarrow (1 - \alpha_i^a)X^a + \alpha_i^a X^b \quad (2.22)$$

De esta manera se obtiene una combinación de inflación multiplicativa (vía el término $(1 - \alpha)X^a$) más una inflación aditiva vía el término αX^b , en donde las perturbaciones se toman de las perturbaciones obtenidas del campo preliminar. El parámetro a ajustar en este caso es el valor de α , cuyo valor oscila entre 0 y 1 y determina en qué medida se adopta la inflación multiplicativa o aditiva.

Otra forma de relajar las perturbaciones del ensamble es a partir del valor de desvío estándar del ensamble de análisis, (Whitaker y Hamill, 2012). En términos algebraicos, esto significa:

$$\sigma^a \leftarrow (1 - \alpha_i^a)\sigma^a + \alpha_i^a \sigma^b \quad (2.23)$$

En donde σ^a y σ^b denotan los valores de desvío estándar del ensamble de análisis y campo preliminar, respectivamente. De esta manera, la perturbación de análisis se obtiene como:

$$X^a \leftarrow X^a \left(\alpha_i^a \frac{\sigma^b - \sigma^a}{\sigma^a} + 1 \right) \quad (2.24)$$

Estos procedimientos tienen ciertas desventajas, entre las que podemos destacar dos. Por un lado, el factor de inflación óptimo puede ser espacial y temporalmente variable, lo cual constituye el punto débil de la inflación multiplicativa. Pero la mayor dificultad radica en que en algunos casos se requieren muchas pruebas para obtener un valor de inflación óptimo, lo cual computacionalmente puede ser muy costoso, sobre todo en experimentos con sistemas de muchos grados de libertad como es un modelo atmosférico.

Existen también otras formas de estimar el valor de inflación óptimo en cada tiempo y punto del modelo. A modo de ejemplo podemos citar la técnica de inflación multiplicativa adaptativa (IMA) (Li y otros, 2009) que permite no sólo estimar la inflación óptima, sino también estimar al mismo tiempo el valor de los errores de la observación, algo de suma utilidad cuando se asimila información proveniente de satélites y radares.

Este algoritmo calcula en primer lugar el valor de inflación óptimo α_i^o dada una cantidad p de observaciones y_i^o en el instante i . Para ello se aplica la relación estadística derivada por Desroziers y otros (2005):

$$E[\mathbb{d}_b^o (\mathbb{d}_b^o)^T] = \mathbf{H} \mathbf{P}^b \mathbf{H}^T + \mathbf{R} \quad (2.25)$$

Donde $\mathbb{d}_b^o = y^o - \mathbf{H}(\mathbf{x}^b)$ es el vector de innovaciones de dimensión p . Por su parte, el operador $E[\]$ denota la esperanza matemática, por lo que representa un promedio sobre un cierto número de casos. Esta ecuación sirve

como una herramienta de diagnóstico del grado de optimización del esquema EnKF empleado.

Dado que los términos diagonales de la matriz P^b están subestimados, la matriz $\bar{\alpha}_i^o P^b$ debe satisfacer la ecuación (2.25). Esta condición lleva a que el parámetro de inflación óptimo para las p observaciones asimiladas en el tiempo i deba valer:

$$\alpha_i^o = \frac{tr(dd^T \circ R^{-1}) - p}{tr(HP^bH^T \circ R^{-1})} \quad (2.26)$$

Donde en este caso el operador $\circ$ denota la multiplicación elemento a elemento de las respectivas matrices.

El hecho de que la ecuación (2.25) trabaje sobre la media de las innovaciones significa que no es válida para un tiempo en particular. En efecto, si se pretende estimar el parámetro de inflación óptimo a partir de dicha ecuación en cada tiempo y punto del modelo, se obtienen resultados muy ruidosos que varían fuertemente de un ciclo de asimilación al siguiente. Dicho comportamiento de saltos bruscos en α_i^o es esperable que ocurra dado que el mismo depende en gran medida de las observaciones que ingresan en el ciclo de asimilación y por lo tanto si el número de observaciones cambia de un ciclo al siguiente (como suele ocurrir en muchas aplicaciones reales), el valor de α_i^o se puede modificar sustancialmente.

Para evitar este problema, Li y otros (2009) propusieron aplicar las ecuaciones del Filtro de Kalman para encontrar el valor de inflación óptimo para el nuevo análisis (el cual denotaremos como α_i^a), dada la inflación óptima calculada en el análisis del tiempo anterior (denotado por α_i^b) y el valor de inflación óptimo calculado a partir de (2.26) α_i^o .

Si asumimos que las estimaciones de los parámetros de inflación α_i^a , α_i^b y α_i^o , tienen una distribución gaussiana, con media $\bar{\alpha}_i^a$, $\bar{\alpha}_i^b$ y $\bar{\alpha}_i^o$, y varianza v_i^a , v_i^b y v_i^o , respectivamente; podemos aplicar estimación de máxima probabilidad a

posteriori para obtener una ecuación similar a la (2.8) para el nuevo parámetro de inflación $\bar{\alpha}_i^a$. Por lo tanto, el valor de $\bar{\alpha}_i^a$ será:

$$\bar{\alpha}_i^a = \frac{\bar{\alpha}_i^b v_i^o + \bar{\alpha}_i^o v_i^b}{v_i^o + v_i^b} \quad (2.27)$$

En este punto el problema consiste en estimar los parámetros $\bar{\alpha}_i^b$, v_i^a , v_i^b y v_i^o , dado que el valor de $\bar{\alpha}_i^o$ se estima a partir de (2.26). El valor de $\bar{\alpha}_i^b$ se estima a partir del valor de $\bar{\alpha}_{i-1}^a$ de (2.27). Para la varianza de la estimación de la inflación del análisis, se utiliza una ecuación análoga a la (2.10):

$$v_i^a = \left(1 - \frac{v_i^b}{v_i^b + v_i^o}\right) v_i^b \quad (2.28)$$

De esta forma, sólo se requiere conocer los valores de v_i^b y v_i^o para poder hallar el valor de inflación correspondiente al tiempo i .

Li y otros (2009) asumen un valor constante para v_i^o , igual a 1 basados en Miyoshi (2005), mientras que para v_i^b asumen un comportamiento de persistencia del siguiente tipo:

$$v_i^b = \kappa v_{i-1}^a \quad (2.29)$$

Donde el parámetro κ también es un factor constante igual a 1.03 que genera un pequeño incremento en el error de la estimación de v_i^b a partir del valor de v_{i-1}^a .

Miyoshi (2011) en cambio propone utilizar el teorema central de límite para la estimación de v_i^o . En este caso se considera que los vectores innovación d son muestras al azar obtenidas de una población con media 0 y covarianza $\alpha H P^b H^T + R$. De esta manera, mediante la utilización de dicho teorema se obtiene que:

$$v_i^o = \frac{2}{p} \left[\frac{\alpha \text{tr}(HP^b H^T \circ R^{-1}) + p}{\text{tr}(HP^b H^T \circ R^{-1})} \right]^2 \quad (2.30)$$

El parámetro α en (2.30) utilizado corresponde al valor previo del ciclo anterior $\bar{\alpha}_i^b$. Por su parte, el valor de v_i^b Miyoshi (2011) lo asume en un valor constante y cuyo valor típico es de 0.04².

2.7 Local Ensemble Transform Kalman Filter

2.7.1 Planteo formal del LETKF

Ott y otros (2004) y Hunt y otros (2007) desarrollaron un filtro determinístico alternativo a los mencionados anteriormente. Este filtro se denomina Local Ensemble Transform Kalman Filter, el cual, tal como mencionamos anteriormente en el Capítulo 1, es el que se utiliza en esta Tesis. La característica principal del LETKF es que resuelve las ecuaciones del EnKF en el sub-espacio definido por las perturbaciones del ensamble. Este algoritmo realiza el análisis en forma local, es decir para cada punto del modelo por separado. Esto permite en primer lugar muestrear las perturbaciones en forma local. Al mismo tiempo debido a que los análisis en cada punto del modelo son independientes uno del otro, este algoritmo es paralelizable y por lo tanto es más eficiente computacionalmente. Además, debido a que las observaciones se asimilan simultáneamente y no en forma secuencial, es más fácil incorporar información acerca de las covarianzas de los errores de las observaciones. El planteo formal del LETKF consiste en minimizar una función de costo similar a la planteada en la ecuación (2.6), con la diferencia que en este caso se permite la existencia de un operador de las observaciones no lineal H . Esto nos lleva entonces a plantear una ecuación de la siguiente forma:

$$J(x_i) = [x_i - \bar{x}_i^b]^T (P_i^b)^{-1} [x_i - \bar{x}_i^b] + [y_i^o - H_i(x_i)]^T R^{-1} [y_i^o - H_i(x_i)] \quad (2.31)$$

En este punto planteamos que la matriz de las perturbaciones del ensamble del campo preliminar (X^b) forma un sub-espacio S dado por los miembros del ensamble (cuya dimensión es $k-1$, ya que tenemos $k-1$ vectores linealmente independientes por tratarse de perturbaciones respecto de $\bar{x}_i^b$). Trataremos a X^b como el resultado de una transformación lineal de un espacio de k dimensiones, al cual llamaremos $\tilde{S}$. En este punto podemos reconocer que el algoritmo LETKF resuelve las ecuaciones del Filtro de Kalman trabajando en un espacio que resulta de una transformación lineal respecto del espacio vectorial original. Dado un vector w_i perteneciente al espacio $\tilde{S}$, la minimización de la función costo planteada en (2.31) es similar a plantear la minimización de la función costo en el espacio $\tilde{S}$:

$$\tilde{J}(w_i) = (k-1)w_i^T \left(I - (X^b)^T [X^b (X^b)^T]^{-1} X^b \right) w_i + J(\bar{x}_i^b + X^b w_i) \quad (2.32)$$

Planteada la transformación lineal, el objetivo ahora es encontrar el vector $w_i = \bar{w}_i^a$, tal que minimice la función de costo (2.32). Para alcanzar este objetivo, debemos linealizar al operador H alrededor del estado $\bar{x}_i^b$ mediante el operador lineal $\mathbf{H}$. Debido a que $\mathbf{H}$ se evalúa en el espacio dado por el ensamble, la forma más sencilla de linealizar H es aplicar este operador a cada uno de los miembros del ensamble. De esta manera calculamos una matriz de observaciones dada por cada miembro del ensamble. Esto implica calcular,

$$y_i^{b(k)} = H_i(x_i^{b(k)}) \quad (2.33)$$

De esta forma se puede definir un vector $\bar{y}_i^b$ y una matriz Y^b , cuyas columnas son las perturbaciones respecto de $\bar{y}_i^b$, es decir que el miembro k -ésimo se define como $y_i^{b(k)} - \bar{y}_i^b$. En este punto, realizamos la aproximación lineal:

$$H(\bar{x}_i^b + X^b w_i) \approx \bar{y}_i^b + Y^b w_i \quad (2.34)$$

Y así, la función costo que obtenemos luego de las aproximaciones que aplicamos es la siguiente:

$$\bar{J}^*(w_i) = (k-1)w_i^T w_i + [y_i^o - \bar{y}_i^b - Y^b w_i]^T R^{-1} [y_i^o - \bar{y}_i^b - Y^b w_i] \quad (2.35)$$

Cuyo vector $\bar{w}_i^a$ y matriz $\tilde{P}_i^a$ solución, son las siguientes:

$$\bar{w}_i^a = \tilde{P}_i^a (Y^b)^T R^{-1} (y_i^o - \bar{y}_i^b) \quad (2.36)$$

$$\tilde{P}_i^a = [(k-1)I + (Y^b)^T R^{-1} Y^b]^{-1} \quad (2.37)$$

En el espacio del modelo, estas ecuaciones se traducen en:

$$\bar{x}_i^a = \bar{x}_i^b + X^b \bar{w}_i^a \quad (2.38)$$

$$P_i^a = X^b \tilde{P}_i^a (X^b)^T \quad (2.39)$$

Si bien con las ecuaciones (2.38) y (2.39) tenemos las estimaciones del estado más probable y de su error asociado, no nos sirven para inicializar el ensamble para el próximo ciclo de pronóstico, ya que necesitamos conocer las perturbaciones. Para esto elegiremos una matriz X^a , tal que la igualdad (2.18) sea válida. Una vez obtenida la matriz X^a , sólo necesitamos sumarle a cada columna el vector $\bar{x}_i^a$ para obtener el ensamble de análisis. En este caso las perturbaciones del análisis se definirán de la siguiente forma:

$$X^a = X^b W^a \quad (2.40)$$

En donde la matriz de pesos W^a tiene la siguiente forma:

$$W^a = [(k-1)\tilde{P}_i^a]^{1/2} \quad (2.41)$$

En donde la raíz cuadrada de la matriz simétrica $(k-1)\tilde{P}_i^a$ se refiere a su raíz cuadrada simétrica.

De esta manera, retomando la ecuación (2.38), para cada miembro del ensamble del análisis obtenemos:

$$x_i^{a(k)} = \bar{x}_t^b + X^b w_i^{a(k)} \quad (2.42)$$

2.7.2 Localización en LETKF

En el caso del LETKF, la localización se realiza sobre la matriz R , considerando solamente aquellas observaciones que se encuentran dentro de un rango de distancia utilizando la ecuación (2.19) y que se puede ajustar a elección del usuario. En general, las observaciones utilizadas para el análisis en un determinado punto de retícula serán prácticamente las mismas que las utilizadas para los puntos vecinos. Esto asegura que el ensamble de análisis no cambie repentinamente de un punto de retícula a otro vecino. Simultáneamente, para hacer efectiva la localización, se aplica un peso a las observaciones que se utilizan en el análisis de cada punto de retícula. Esto se hace multiplicando los elementos de la matriz R por la inversa del factor de localización, de forma tal que las observaciones a grandes distancias del punto del análisis tienen un peso muy pequeño en el análisis de dicho punto.

2.7.3 Implementación de la técnica IMA en el LETKF

La implementación de la técnica IMA en el esquema LETKF se realiza utilizando las estimaciones dadas por Miyoshi (2011). En este caso, el parámetro $\bar{\alpha}_i^a$ se calcula en forma simultánea con la matriz de transformación para cada subconjunto de observaciones (R_i) que se utilizan para el análisis en cada punto de retícula del modelo. A la matriz R_i se le aplica la función de peso de localización $\tilde{\rho}$. De este modo la matriz de covarianza de los errores R_i es reemplazada por $\tilde{\rho}^{-1} \circ R$, en donde $\tilde{\rho}^{-1}$ es el factor de localización y cuyo valor oscila entre 0 y 1. Con esta modificación, las ecuaciones (2.26) y (2.30) se reescriben como:

$$\bar{\alpha}_i^o = \frac{tr(dd^T \circ \tilde{\rho} \circ R^{-1}) - tr(\tilde{\rho})}{tr(HP^b H^T \circ \tilde{\rho} \circ R^{-1})} \quad (2.43)$$

$$v_i^o = \frac{2}{tr(\tilde{\rho})} \left[\frac{\alpha tr(HP^b H^T \circ \tilde{\rho} \circ R^{-1}) + tr(\tilde{\rho})}{tr(HP^b H^T \circ \tilde{\rho} \circ R^{-1})} \right]^2 \quad (2.44)$$

De esta manera, una observación lejana es pesada por el peso de localización $\tilde{\rho}_i$, de forma tal que una observación con un peso de localización de 0.2 es contada como 0.2 observaciones, siendo el máximo posible para la observación más cercana al punto en cuestión de 1. Este peso de localización modifica la matriz $\tilde{P}^a$ en la ecuación (2.37), de modo que dicha ecuación queda formulada de la siguiente manera:

$$\tilde{P}^a = \left[(k-1)I/tr(\tilde{\rho}) + (Y^b)^T R^{-1} Y^b \right]^{-1} \quad (2.45)$$

2.8 Verificación de la calidad y consistencia del análisis

La verificación de la calidad del análisis obtenido a partir de un EnKF requiere analizar dos de sus características fundamentales. En primer lugar debemos verificar el error o la distancia del análisis con respecto al estado verdadero del sistema, lo cual nos permite estimar la calidad del análisis. Esto implica medir la bondad del ajuste en términos del primer momento de la distribución de posibles estados del sistema. Sin embargo, verificar solamente el error del análisis significa pasar por alto que el rasgo principal del EnKF es la estimación del error a partir de la dispersión del ensamble. Por lo tanto, el determinar la consistencia de un sistema de análisis basado en un EnKF, requiere verificar en segundo lugar si el error está correctamente representado por la dispersión del análisis. Esto esencialmente es cuantificar la bondad del ajuste en términos del segundo momento de la distribución.

En la Figura 2.3 se muestra un esquema que resume las diferentes métricas del error utilizadas para la verificación de los resultados de los experimentos de esta Tesis. Notemos que las métricas se dividen en dos grandes grupos, el primero relacionado con el error del análisis y el segundo conjunto que mide la

consistencia del análisis en términos de su desvío estándar. De esta manera, en esta sección dividimos la verificación en dos partes.

2.8.1 Verificación del ajuste del primer momento o error del análisis

Dado que en un EnKF lo que se obtiene esencialmente es un ensamble de análisis, al verificar el ajuste del primer momento de la distribución, lo que estamos haciendo es básicamente comparar la media del ensamble de análisis contra algún estado de referencia del sistema considerado como su estado real.

Como el estado del sistema está definido por un vector que incluye diversas variables como viento, temperatura, humedad, presión y otras variables en diferentes niveles y puntos de retícula del modelo, verificar el error del análisis es una tarea sumamente compleja, y a menudo implica verificar cada una de las variables por separado. Esto lleva a que el trabajo pueda volverse engorroso, ya que las diferentes variables pueden tener comportamientos muy diferentes entre sí. Por este motivo, una práctica común es realizar la verificación a partir de variables que engloben diferentes variables del sistema. Una de estas variables es la energía total del sistema, utilizada por diversos autores en diferentes variantes (Zhang y otros, 2002, 2003 y 2007, Tan y otros, 2004, Xu y Zhong, 2009, Bei y Zhang, 2014), y cuyas características fueron estudiadas profundamente por Errico y otros (2004).

En nuestro caso, utilizaremos el Error de Energía Seca (EES), la cual se define para cada punto del modelo (i, j, k) (donde los índices i y j denotan la dimensión horizontal y el índice k la dimensión vertical) y tiempo t como:

$$EES_{i,j,k,t} = \frac{1}{2} \rho_{i,j,k,t} \left(U'_{i,j,k,t}{}^2 + V'_{i,j,k,t}{}^2 + \left(\frac{C_{pd}}{T_r} \right) * T'_{i,j,k,t}{}^2 + \left(R_d * \frac{T_r}{P_{ref}^2} \right) * P'_{i,j,t}{}^2 \right) \quad (2.46)$$

En esta ecuación las variables primadas denotan la diferencia en un dado punto de retícula entre el análisis y el estado de referencia en viento zonal y meridional (U' y V'), temperatura (T') y presión en superficie (P'). El término C_{pd} es el calor específico a presión constante del aire seco igual a 1004 J/Kg K, R_d es la constante del aire seco igual a 287.05 J/Kg; el término T_r es una temperatura de referencia igual a 287 K (siguiendo a Tan y otros, 2004 y a Xu y Zhong, 2009), mientras que el término P_{ref} es la presión de superficie de referencia igual a 1000 hPa. Por su parte, el término ρ representa la densidad del aire en el estado de referencia.

Podemos ver de la ecuación (2.46) que el EES es una métrica de error en energía que incluye la diferencia en energía cinética más energía potencial, la cual a su vez está pesada por la densidad. Al pesar por la densidad, las diferencias en niveles cercanos a la superficie cobran mayor importancia frente a las diferencias en niveles altos. Esto permite evaluar más adecuadamente el error en energía ya que la energía del sistema depende de la masa del mismo.

A fines de comparar el error en energía, en esta Tesis se realiza una integración tanto espacial como temporal del EES. La integración en cualquiera de las 3 dimensiones del espacio o en el tiempo del EES se denomina Error en Energía Total Seca (EETS). Por ejemplo, para cada tiempo t podemos definirla como la suma del EES en todo el dominio, dividido por la masa total del sistema, es decir:

$$EETS_t = \frac{\sum_{i,j,k} EES_{i,j,k,t}}{\sum_{i,j,k} \rho_{i,j,k,t}} \quad (2.47)$$

Otras métricas similares, pero promediando el EES solamente en la horizontal o en la vertical, o bien en el tiempo, se calculan de manera análoga a (2.47), y se denominan igualmente EETS.

El EETS comprende la suma de diferencias en viento, temperatura y presión de superficie elevadas al cuadrado. Teniendo en cuenta que el error cuadrático medio (*mse*) se calcula como:

$$mse = \frac{1}{T} \sum_{it=1}^T (x_{it}^a - x_{it}^t)^2 \quad (2.48)$$

Podemos ver que el EES promediado temporalmente utiliza el error cuadrático medio (*mse*) del viento, la temperatura y la presión, salvo por las constantes que multiplican a las respectivas componentes del EES. Si bien utilizar tanto el EETS como el *mse* es útil para determinar el error medio, es posible extraer mayor información acerca de qué parte del error corresponde a errores sistemáticos y qué partes a errores no sistemáticos. En principio, el error cuadrático medio puede descomponerse en 3 componentes, siguiendo a Hou y otros (2001). Algebraicamente, podemos escribir al *mse* como la suma de 3 términos:

$$mse = mnbias^2 + sdbias^2 + No\ Sist^2 \quad (2.49)$$

El primer término a la derecha de la igualdad en (2.49) (*mnbias*) representa el error sistemático del análisis con respecto al estado de referencia o verdad promediado temporalmente (variables denotadas como $\bar{\bar{x}}^i$), tal como muestra la ecuación (2.50):

$$mnbias = \bar{\bar{x}}^a - \bar{\bar{x}}^t = \frac{1}{T} \sum_{it=1}^T (x_{it}^a - x_{it}^t) \quad (2.50)$$

Por su parte, el *sdbias* mide la diferencia en variabilidad temporal o desvío estándar ($sd(x^i)$) entre el análisis y la verdad. En términos algebraicos, esto es:

$$sdbias = sd(x^a) - sd(x^t) = \sqrt{\frac{1}{T} \sum_{it=1}^T (x_{it}^a - \overline{x^a})^2} - \sqrt{\frac{1}{T} \sum_{it=1}^T (x_{it}^t - \overline{x^t})^2} \quad (2.51)$$

Tanto el *mnbias* como el *sdbias* son las componentes sistemáticas del error, y como tales pueden utilizarse a fines de calibración, ya sea de un análisis como de un pronóstico. Estas variables además pueden ser tanto positivas como negativas, a diferencia el *mse*. El signo de las mismas brinda información acerca del sentido del error sistemático.

Finalmente, en la ecuación (2.49) el último término es el llamado error no sistemático (*No Sist*). El *No Sist* se calcula de la siguiente forma:

$$No\ Sist = \sqrt{2[1 - r(x^a, x^t)] * sd(x^a) * sd(x^t)} \quad (2.52)$$

En la ecuación (2.52) aparece el término $r(x^a, x^t)$, el cual denota el coeficiente de correlación entre el análisis y el estado de referencia, que se escribe como:

$$r(x^a, x^t) = \frac{\sqrt{\frac{1}{T} \sum_{it=1}^T (x_{it}^a - \overline{x^a}) * (x_{it}^t - \overline{x^t})}}{sd(x^a) * sd(x^t)} \quad (2.53)$$

Podemos ver a partir de las ecuaciones (2.52) y (2.53) que el término de error no sistemático depende de la correlación entre el análisis y el estado de referencia y por este motivo este error depende esencialmente de errores de fase entre ondas y/o errores aleatorios.

De esta manera, para cada variable que conforma el análisis, en cada punto y nivel del modelo, podemos calcular las diferentes componentes del error cuadrático medio. Asimismo, también podemos tomar las diferentes componentes del error cuadrático medio de las variables que integran el EES y calcular el aporte que realizan dichas componentes del error al EES. Esto significa que podemos asociar un error de Energía Seca al error cuadrático medio (EES (*mse*)), y calcular la contribución de las componentes del *mnbias* (EES (*mnbias*)), del *sdbias* (EES (*sdbias*)) y de la componente de no sistemática (EES (*No Sist*)). Cada una de dichas componentes se puede calcular para cada punto del modelo de la siguiente forma:

$$EES (mse) = \frac{1}{2} \bar{\rho} \left(U (mse) + V (mse) + \left(\frac{C_{pd}}{T_r} \right) * T (mse) + \left(R_d * \frac{T_r}{P_{ref}^2} \right) * P (mse) \right) \quad (2.54)$$

$$EES (mnbias) = \frac{1}{2} \bar{\rho} \left(U (mnbias)^2 + V (mnbias)^2 + \left(\frac{C_{pd}}{T_r} \right) * T (mnbias)^2 + \left(R_d * \frac{T_r}{P_{ref}^2} \right) * P (mnbias)^2 \right) \quad (2.55)$$

$$EES (sdbias) = \frac{1}{2} \bar{\rho} \left(U (sdbias)^2 + V (sdbias)^2 + \left(\frac{C_{pd}}{T_r} \right) * T (sdbias)^2 + \left(R_d * \frac{T_r}{P_{ref}^2} \right) * P (sdbias)^2 \right) \quad (2.56)$$

$$EES (No Sist) = \frac{1}{2} \bar{\rho} \left(U (No Sist)^2 + V (No Sist)^2 + \left(\frac{C_{pd}}{T_r} \right) * T (No Sist)^2 + \left(R_d * \frac{T_r}{P_{ref}^2} \right) * P (No Sist)^2 \right) \quad (2.57)$$

En las ecuaciones (2.54)-(2.57) aparece el promedio temporal de la densidad en cada punto, en lugar de la densidad a cada instante que tenemos en la ecuación (2.46). Esta diferencia hace que cuando se promedian temporalmente los valores del EES de la ecuación (2.46) no coincidan exactamente con los valores de EES (mse) de la ecuación (2.54). No obstante, las diferencias numéricas entre dichas ecuaciones son muy pequeñas dado que las variaciones temporales de la densidad en niveles de presión constante donde se evalúan estas cantidades, son relativamente pequeñas

Si bien las métricas definidas integran diferentes variables y dan una buena noción del error del análisis, dichas métricas no contemplan las variables de humedad. Para complementar la validez de la verificación de la calidad del análisis, es necesario estudiar los errores en variables tales como la humedad específica o la precipitación acumulada, por ejemplo. En ambos casos es posible calcular para cada punto de retícula las diferentes componentes que conforman el error cuadrático de ambas variables.

Sin embargo, para el caso de la humedad específica (denotado q) se puede resumir la información, teniendo en cuenta que por la naturaleza de dicha variable, los valores más altos se encuentran en los niveles cercanos a la superficie y que esta variable en niveles altos de la troposfera presenta valores mucho menores en comparación con la troposfera baja. Por tal motivo, una vez calculadas cada una de las componentes de la ecuación (2.49) se puede integrar dichas componentes en la vertical de cada punto. De esta manera calculamos las componentes de Error de Humedad Integrada en la Vertical (EHIV), de la siguiente forma:

$$mse(EHIV) = \frac{1}{K} \sum_{k=1}^K (Q(mse) * \Delta H_k) \quad (2.58)$$

$$mnbias(EHIV) = \frac{1}{K} \sum_{k=1}^K (Q(mnbias) * \Delta H_k) \quad (2.59)$$

$$sdbias(EHIV) = \frac{1}{K} \sum_{k=1}^K (Q(sdbias) * \Delta H_k) \quad (2.60)$$

$$No\ Sist(EHIV) = \frac{1}{K} \sum_{k=1}^K (Q(No\ Sist) * \Delta H_k) \quad (2.61)$$

En estas expresiones, el término ΔH_k denota la diferencia promediada temporalmente de altura geopotencial de los niveles verticales del modelo.

2.8.2 Verificación del ajuste del segundo momento o consistencia del análisis

Como mencionamos anteriormente, al estudio de los errores del análisis es necesario agregarle la evaluación de la dispersión del análisis, puesto que la misma es la representación del error de un ensamble. Por tal motivo, un buen ensamble debe permitir identificar correctamente las regiones y tiempos de mayor o menor incertidumbre a partir de la dispersión entre sus miembros.

Algebraicamente, la dispersión del ensamble de análisis (δ) para una dada variable (ui) en un punto y tiempo cualquiera se define de la siguiente forma:

$$\delta^a(ui) = \sqrt{\frac{1}{L-1} \sum_{l=1}^L (ui^{al} - \overline{ui^a})^2} \quad (2.62)$$

También se puede calcular una dispersión en energía seca, combinando las fórmulas (2.46) y (2.62), de forma tal que:

$$\delta^a(EES)^2 = \frac{1}{2}\rho \left(\delta^a(U)^2 + \delta^a(V)^2 + \left(\frac{C_{pd}}{T_r} \right) * \delta^a(T)^2 + (R_d * \frac{T_r}{P_{ref}^2}) * \delta^a(P)^2 \right) \quad (2.63)$$

Mientras que para el EHIV, la dispersión se define de la siguiente forma:

$$\delta^a(EHIV) = \frac{1}{K} \sum_{k=1}^K (\delta^a(Q) * \Delta H_k) \quad (2.64)$$

Una forma de cuantificar la consistencia del análisis es medir el grado de correspondencia temporal entre alguna medida del error, como por ejemplo el error cuadrático de la variable, y la dispersión definida en (2.62). De esta manera, la correlación entre el error y la dispersión se calcula de la siguiente forma:

$$r(\varepsilon^a, \delta^a) = \frac{\sqrt{\frac{1}{T} \sum_{it=1}^T (\overline{\varepsilon_{it}^a} - \overline{\varepsilon^a}) * (\delta_{it}^a - \overline{\delta^a})}}{sd(\varepsilon^a) * sd(\delta^a)} \quad (2.65)$$

En donde el término $\overline{\varepsilon_{it}^a}$ designa al error del análisis, y está dado por:

$$\varepsilon_{it}^a = (\overline{x_{it}^a} - x_i^t)^2 \quad (2.66)$$

Por su parte, el término $\overline{\varepsilon^a}$ en (2.65) denota a la media temporal del error de la media del ensamble, mientras que el término $\overline{\delta^a}$ denota la media temporal de (2.62).

Lo que buscamos con el cálculo de esta correlación es medir el grado de correspondencia entre la dispersión del ensamble y su error. Algunos autores como Hopson (2014) señalan que si bien esta variable es útil para medir la correspondencia entre error y dispersión, la misma está afectada por la elección de las métricas de error y dispersión que se elijan para calcularla. Por otro lado, la relación entre el error y la dispersión del ensamble no es lineal, dado que una mayor dispersión implica que el ancho de la distribución de errores es mayor, pero no necesariamente implica un error mayor. Esto hace que la correlación máxima que se pueda alcanzar en algunos casos pueda ser bastante menor que 1 (Grimit y Mass, 2007). No obstante, esta métrica es igualmente útil para comparar los resultados de los diferentes experimentos, y permite determinar qué experimento es más consistente en términos de error y dispersión del ensamble.

Otra forma de verificar la consistencia de un sistema de análisis-pronóstico es a partir de las observaciones asimiladas. El planteo en este caso consiste en verificar si las matrices de covarianza de los errores del análisis, del campo preliminar y de las observaciones están correctamente determinadas. Para ello, haremos uso de las relaciones derivadas por Desroziers y otros (2005), las cuales proveen una herramienta de diagnóstico a partir de las observaciones asimiladas acerca de la correcta determinación de las matrices de covarianza utilizadas durante el proceso de asimilación. Asumiendo que las matrices P^b y R utilizadas en la asimilación son las verdaderas matrices de covarianza de los errores del campo preliminar y de las observaciones, respectivamente; las siguientes relaciones, junto con la ya definida en la ecuación (2.40), son válidas:

$$E[\mathbb{d}_b^a (\mathbb{d}_b^o)^T] = H P^b H^T \quad (2.67)$$

$$E[\mathbb{d}_a^o (\mathbb{d}_b^o)^T] = R \quad (2.68)$$

$$E[\mathbb{d}_b^a (\mathbb{d}_b^o)^T] = \mathbf{H} \mathbf{P}^a \mathbf{H}^T \quad (2.69)$$

Donde $\mathbb{d}_b^a$, $\mathbb{d}_b^o$ y $\mathbb{d}_a^o$ son las diferencias entre el estado del análisis y el del campo preliminar llevados al espacio de las observaciones, las observaciones y el campo preliminar en el espacio de las observaciones, y las observaciones y el estado del análisis llevado a las observaciones, respectivamente. Puesto en ecuaciones, dichos vectores se escriben como:

$$\mathbb{d}_b^a = H(x^a) - H(x^b) \quad (2.70)$$

$$\mathbb{d}_b^o = y^o - H(x^b) \quad (2.71)$$

$$\mathbb{d}_a^o = y^o - H(x^a) \quad (2.72)$$

Por su parte, el operador $E[\]$ en las ecuaciones (2.67)-(2.69) denota la esperanza matemática, al igual que en la ecuación (2.40). Este tipo de verificación es muy utilizada como herramienta de diagnóstico para chequear la correcta determinación de las matrices de covarianzas, tanto del campo preliminar como de las observaciones.

Capítulo 3: Experimentos idealizados – impacto de las fuentes de error en el sistema de asimilación-pronóstico

3.1 Introducción

En el marco de esta Tesis y de los objetivos propuestos en el Capítulo 1, en el presente capítulo se muestran los resultados de experimentos idealizados utilizando el algoritmo LETKF descrito en el capítulo anterior. Tal como se mencionó en el Capítulo 1, estos experimentos buscan en primer lugar estudiar y cuantificar el impacto de algunas de las fuentes de error que generalmente se encuentran presentes en un sistema regional de asimilación de datos y pronóstico. En particular, se estudia el impacto provocado por las imperfecciones del modelo y por los errores en las condiciones de borde sobre la calidad del análisis resultante.

3.2 Datos y metodología

3.2.1 El sistema LETKF-WRF

Miyoshi y Kunii (2012) implementaron el sistema LETKF-WRF, en el que se acopló el esquema LETKF al modelo WRF, utilizando datos reales. Este algoritmo está disponible libremente en la Web (<https://code.google.com/p/miyoshi/>), lo cual permite que múltiples usuarios puedan documentar fortalezas y debilidades del mismo y así poder mejorarlo continuamente. Este sistema comenzó a ser desarrollado a partir de los trabajos de Miyoshi (2005) y Hunt y otros (2007), hasta incluir localización espacial de covarianzas (Miyoshi y otros, 2007), el tratamiento de observaciones de diferentes tiempos (4D-Enkf, Hunt y otros, 2004) y localización temporal. En particular, la implementación 4D-LETKF permite al sistema asimilar observaciones asincrónicas (es decir que corresponden a tiempos diferentes del momento del análisis). De esta manera el sistema es capaz de asimilar observaciones dentro de una ventana de 6 horas alrededor

del tiempo del análisis. Otras mejoras de este sistema están documentadas en Miyoshi y Yamane, 2007, Miyoshi y otros, 2007 y 2010, incluyendo la implementación de la IMA (Miyoshi, 2011). Este sistema se ha utilizado en diversos estudios de asimilación en modelos atmosféricos, entre los que podemos citar a Miyoshi y Aranami (2006), Miyoshi y Sato (2007) y Saito y otros (2010), entre otros.

La Figura 3.1 muestra el sistema LETKF-WRF con todos los procesos involucrados en un ciclo de pronóstico-asimilación. En el extremo izquierdo de la figura tenemos un ensamble de pronósticos con m miembros en el tiempo t , listos para ingresar en el algoritmo LETKF. Para estudios con datos observados reales, el sistema está preparado para trabajar con datos en formato PREPBUFR (Keyser, 2010), disponibles del servidor del University Corporation for Atmospheric Research (UCAR). El formato PREPBUFR es ampliamente utilizado para la comunicación y almacenamiento de datos obtenidos con diversas plataformas de observación, desde radares y satélites hasta observaciones convencionales. El sistema LETKF-WRF dispone de un decodificador de datos PREPBUFR para generar el vector de observaciones y^o e ingresar al esquema LETKF. En el caso particular en que no se utilicen observaciones reales, será necesario generar el vector de observaciones y^o en el formato adecuado para la posterior utilización del algoritmo LETKF. Este algoritmo genera el ensamble de análisis $x^{a(1)}$ a $x^{a(m)}$, junto con archivos que contienen información de la media y la dispersión del ensamble. Esta información de salida es almacenada en disco en formato binario de 4 bytes.

Una vez obtenido el ensamble de análisis, el paso siguiente consiste en integrar el modelo WRF para cada uno de los miembros del análisis hasta el próximo ciclo de análisis. Para ello se requieren especificar las condiciones de bordes lateral (en casos de modelos regionales) e inferior (temperatura y humedad del suelo, temperatura superficial del mar (SST), topografía, tipo de suelo, etc). Estos datos por lo general se obtienen a partir de análisis globales. En un primer paso estos datos externos son adecuados a la retícula del dominio del experimento mediante los programas de pre-procesamiento del

modelo WRF (programas *geogrid*, *ungrib*, *metgrid* y *real* que conforman el casillero PRE-WRF de la figura). Estos programas generan dos archivos: uno llamado *wrfinput_d01* que contiene el campo inicial tomado de la información del modelo global, y un segundo archivo denominado *wrfbdy_d01*, que posee la información de las condiciones de borde provenientes del modelo global (valores de variables meteorológicas como viento, temperatura, velocidad vertical, geopotencial, espesor de la columna, humedad específica junto con sus derivadas temporales). Estos archivos son luego modificados por los datos de análisis obtenidos previamente del LETKF mediante el proceso MERGE, el cual consiste en una serie de pasos. En un primer paso se modifican los campos meteorológicos iniciales del análisis global y que fueron generados por el proceso PRE-WRF por aquellos provenientes del algoritmo LETKF mediante el programa *init-merge*. El paso siguiente consiste en modificar las condiciones de borde lateral e inferior mediante el programa *da_update.exe* que forma parte del paquete WRF-Var del modelo WRF. Este programa modifica por un lado los valores de tendencia de diferentes variables meteorológicas en los bordes laterales para que sean consistentes con las condiciones iniciales extraídas del análisis. Al mismo tiempo este programa modifica, en este caso, las condiciones de borde inferior, en particular las de temperatura y humedad del suelo, dado que las mismas provienen del sistema de asimilación de superficie del NCEP.

Terminado el proceso de preparación de las condiciones iniciales, se procede a evolucionar cada miembro del ensamble con el modelo WRF hasta el ciclo de análisis siguiente que corresponde al tiempo $t + \Delta t$. Dado que este sistema genera análisis a las 0000, 0600, 1200 y 1800 UTC, los ciclos de análisis son de 6 horas. Como además las observaciones que se asimilan se extienden en una ventana de 6 horas centradas en el tiempo de análisis, los pronósticos realizados con el modelo WRF se extienden por 9 horas. Una vez obtenidos los pronósticos de cada miembro del ensamble para el nuevo ciclo de análisis ($x_{t+1}^{f(1)}$ a $x_{t+1}^{f(m)}$), las salidas son post-procesadas mediante el programa ARWpost (casillero POST-WRF) y almacenadas en disco en datos a niveles de presión. Al mismo tiempo, se ejecuta el proceso CONV (programa nc2grd), el cual

convierte los archivos de pronóstico a formato binario de 4 bytes para ingresar en el algoritmo LETKF y repetir el ciclo de la figura. Al mismo tiempo, dichos archivos en formato binario son almacenados en disco.

El esquema LETKF en este sistema genera análisis de las siguientes variables: viento en 3 dimensiones (u , v y w), temperatura (T), altura geopotencial (ph), humedad específica (qv) y variables condensadas según la elección de parametrizaciones de microfísica, por lo general agua de nube, hielo de nube y agua de lluvia (qw , qi y $qrain$). También se utilizan otras variables en los operadores de observaciones como presión (p), presión en superficie (ps), temperatura y humedad a 2 metros ($t2$ y $q2$). En particular, la corrección en la presión de superficie se obtiene en forma diagnóstica a partir de las modificaciones introducidas en el geopotencial, la temperatura y la humedad en la rutina MERGE.

Existen varios parámetros que se pueden modificar dentro del esquema LETKF según la aplicación o la resolución horizontal del análisis. Entre ellos se pueden elegir los valores de localización horizontal, vertical y temporal. Asimismo, este sistema permite la implementación de diferentes técnicas de inflación: multiplicativa (con un factor de multiplicación a elección del usuario) e IMA.

Este paquete también dispone de un sencillo sistema de control de calidad de las observaciones. Para cada observación, el sistema compara la diferencia entre la observación y la media del campo preliminar llevada al punto de observación, con el error de la observación. Si la diferencia entre la observación y el campo preliminar supera el valor del error de la observación multiplicado por un factor a elección, dicha observación es rechazada.

3.2.2 Diseño experimental

La metodología aplicada en estos experimentos consiste en realizar una simulación de red de observación (OSSE por sus siglas en inglés). En estos experimentos las observaciones son generadas a partir de una Simulación

Verdad (SV) que consiste en una integración numérica con el modelo WRF, la cual es considerada la evolución real del sistema. De esta manera la SV se utiliza también para verificar los resultados obtenidos en cada experimento. La Tabla 3.1 muestra las características de la SV junto con las de los experimentos realizados. La SV se realiza sobre un dominio que abarca Sudamérica (Figura 3.2) con proyección Mercator y se extiende durante el período invernal del año 2010, desde el 1° de junio a las 00 UTC hasta el 29 de septiembre a las 00 UTC. La elección de este período y de este dominio permite incluir en nuestro sistema los efectos de las inestabilidades presentes en el flujo atmosférico: la de las ondas baroclínicas en latitudes medias durante el invierno y la asociada a la convección en latitudes bajas.

El modelo WRF utilizado corresponde al núcleo dinámico ARW en su versión 3.3.1 (WRF-ARW V3.3.1) (Skamarock y otros, 2008). La resolución horizontal utilizada es de 100 km y la cantidad de niveles verticales sigma-p es de 40, con tope en el nivel de 10 hPa. La Tabla 3.2 muestra una correspondencia aproximada entre los niveles sigma de la SV y algunos niveles de presión significativos asumiendo una presión de superficie de 1000 hPa. Si bien la resolución horizontal utilizada es baja considerando la resolución de los modelos de pronóstico regional (que oscila entre los 3 y los 25 km actualmente), esta resolución permite analizar los efectos de las fuentes de error estudiadas en esta Tesis. Por otra parte, existe una razón de índole práctica y es que trabajar con una resolución más baja reduce significativamente el costo computacional asociado a los experimentos, permitiendo realizar una mayor cantidad de experimentos.

Las condiciones iniciales y de borde de la SV son provistas por la base de datos Final Analysis (FNL) de 1° de resolución horizontal. En particular, las regiones del dominio cercanas a los bordes laterales consisten en una zona esponja en donde los campos del modelo WRF son relajados a los valores de las variables en los bordes que provienen del FNL a fin de evitar reflexiones espurias de ondas en los bordes y que degraden la solución en el interior del dominio. En este caso, la región esponja del modelo consta de 4 puntos de retícula del

modelo, lo que es equivalente a 400 km desde los bordes. Con respecto a los bordes inferiores, la SST evoluciona de acuerdo con la información provista por los FNL, debido a que el experimento abarca un período de 4 meses. Las condiciones de temperatura y humedad del suelo de la SV en cambio, evolucionan según la dinámica de suelo del modelo Noah mencionada en la Tabla 3.1.

Resolución	100 km
Niveles verticales	40 (tope 10 hPa)
Condiciones iniciales	FNL
Condiciones de borde	FNL
Período	1/6/2010 00UTC - 29/9/2010 00UTC
Dominio	54°S – 12°N, 94°O-26°O
Microfísica	WSM-5 clases (Hong y otros,. 2004)
Onda larga	RRTM (Mlawer y otros 1997)
Onda corta	Dudhia (Dudhia 1989)
Capa superficie	Monin Obukhov (MM5) (Monin-Obukhov, 1954)
Suelo	Noah (Chen y Dudhia, 2001)
Capa limite	YSU (Hong y otros, 2006)
Convección	Kain-Fristch (Kain y Fristch, 1993)
Localización horizontal	400 km
Localización vertical	0.4 ln p
Dispersión inicial	20%
Inflación	IMA (Miyoshi, 2011)
Inflación inicial	3%

Tabla 3.1: Características parametrizaciones físicas utilizadas en la SV, junto con parámetros utilizados en el LETKF.

Nivel Sigma	Nivel Presión (hPa)
1	1000
10	850
13	700
17	500
23	300
25	200
30	100
34	50
40	10

Tabla 3.2: Correspondencia aproximada entre los niveles sigma en la SV y algunos niveles de presión, asumiendo la superficie a 1000 hPa.

Los experimentos idealizados constan de la generación de análisis cada 6 horas a partir de los cuales se realizan los respectivos pronósticos a 9 horas de plazo. Las ventanas de observaciones que ingresan a cada ciclo de análisis son de 6 horas, comenzando 3 horas antes del tiempo de análisis y finalizando 3 horas después. Por este motivo, el plazo de pronóstico es de 9 horas. La cantidad de miembros del ensamble es de 40 en todos los experimentos. Este número de miembros utilizados es del mismo orden de miembros utilizados en diversos estudios (por ejemplo Miyoshi y Kunii, 2012, Kunii y Miyoshi, 2012, Holt y otros, 2013). Por este motivo consideramos que un valor de 40 miembros en el ensamble es suficiente para representar adecuadamente las posibles direcciones de inestabilidad en el flujo atmosférico para la resolución horizontal con la que estamos trabajando.

La inicialización del ensamble en el tiempo inicial está dado por las condiciones iniciales de la SV (que provienen del FNL) a la que se suman perturbaciones. Cada una de las perturbaciones se obtienen mediante la resta de dos posibles estados de la atmósfera seleccionados al azar de la base de datos del Climate Forecast System Reanalysis (CFSR) (Saha y otros, 2010). Dichos campos corresponden siempre a la misma hora y pertenecen al año 2009. La resta de dichos campos es escalada por un factor constante que en este caso es igual a

0.2. Teniendo en cuenta que los errores de los análisis operativos se estiman en un 10% de la variabilidad climatológica, tomar una dispersión inicial dentro del ensamble del orden del 20% de la variabilidad climatológica provee una estimación realista de la incertidumbre inicial del ensamble. Dicha estimación es adecuada por el hecho de que por un lado la estimación inicial del estado del sistema no resulta lejana al SV y a la vez la dispersión introducida es lo suficientemente grande como para evitar posibles divergencias del filtro durante el experimento. La perturbación obtenida es luego sumada al campo inicial del FNL del 1 de junio de 2010 a las 00 UTC, obteniéndose así la condición inicial para cada miembro del ensamble. En este procedimiento se tiene especial cuidado de no repetir la combinación de campos de CFSR a fin de evitar que dos o más perturbaciones resulten iguales. Finalmente, se realiza un chequeo de las perturbaciones generadas a fin de corroborar que la creación de un número limitado de perturbaciones no introduzca diferencias sistemáticas en el ensamble con respecto a la SV en su inicialización. En líneas generales observamos que las diferencias sistemáticas más importantes en el conjunto del ensamble se dan en zonas puntuales del dominio y que su magnitud máxima es de entre un 10 y un 20% con respecto a la magnitud de la dispersión inicial del ensamble en dichas regiones. Esto nos indica que en líneas generales el ensamble inicial generado está aproximadamente centrado en la SV y que por lo tanto las diferencias sistemáticas iniciales introducidas no deberían influir significativamente en los resultados de los experimentos.

Los parámetros de localización son los mismos que los utilizados en Miyoshi y Kunii 2012. Esto es, 400 km en la horizontal (lo que equivale a un radio de influencia de 1460 km) y de 0.4 en la escala logarítmica de presión lo que equivale a un radio de influencia real de 1,46 en la escala log p. Este radio de influencia vertical implica que para un punto en 500 hPa las observaciones tomadas entre el nivel de 116 hPa y superficie tienen impacto en dicho punto (para un punto en 200 hPa la influencia de las observaciones se extiende entre el nivel de 46 hPa y de 860 hPa).

El método de inflación utilizado en estos experimentos es el de IMA (Miyoshi 2011) adaptado al sistema LETKF-WRF por Miyoshi y Kunii (2012)). Kunii y Miyoshi (2012) documentan resultados satisfactorios en la calidad del análisis al implementar este algoritmo de inflación, cuyo objetivo principal es el de estimar en qué medida se debe incrementar la dispersión del ensamble en cada punto del modelo, a fin de evitar la divergencia del filtro. Sin embargo, para lograr que la IMA alcance un valor óptimo es necesario realizar los experimentos sucesivas veces, lo cual implica entrenar el valor de inflación. A falta de información inicial se asume en el primer análisis una inflación del 3%, y luego se deja que el algoritmo de IMA converja al valor óptimo en los siguientes ciclos. Sin embargo, una sola corrida del experimento no suele ser suficiente para alcanzar el valor óptimo, por lo que se reinicia el experimento tomando como valor de inflación inicial el último valor estimado del experimento anterior. En general, para estos experimentos es necesario repetir este procedimiento unas 4 veces, lo cual traducido en tiempo real de simulación requeriría de unos 16 meses de entrenamiento.

3.2.3 Observaciones

Las observaciones son generadas a partir de la SV cada 6 horas a las 00, 06, 12 y 18 UTC. Las observaciones generadas simulan ser radiosondeos, en donde se observan las siguientes variables: viento en sus componentes zonal y meridional, temperatura, humedad específica y presión en superficie. Los errores, de tipo gaussianos, introducidos a dichas observaciones son de 1 m/s para el viento, 1°C para la temperatura, 1 g/kg para la humedad específica y de 1 hPa para la presión en superficie. La distribución vertical de las observaciones es de 1 observación cada 3 niveles del modelo, dando un total de 13 observaciones de temperatura, humedad y viento en la vertical para cada sondeo. La distribución en la horizontal de las observaciones es al azar y varía de un ciclo de pronóstico al siguiente, con lo que los puntos de observación no son fijos en el tiempo. La densidad de observaciones es de 0.005, lo que es equivalente a tener 28 puntos de observaciones sobre los

5600 puntos de la retícula del modelo. Esto da un total de 364 observaciones de viento zonal y meridional, temperatura y humedad específica, y 28 observaciones de presión en superficie por ciclo de pronóstico. Si bien la cantidad de observaciones se mantiene constante para todos los ciclos de análisis, su distribución horizontal varía de un ciclo al siguiente. Esto asegura que no se produzcan efectos de reducción excesiva de dispersión dentro del ensamble en las zonas de mayor densidad de observaciones, los cuales pueden enmascarar los efectos producidos por las fuentes de error que pretendemos estudiar. Vale destacar además que los puntos de observación no coinciden con puntos del modelo.

La Figura 3.3 muestra la cantidad total de observaciones de viento zonal por capas verticales y de presión en superficie distribuidas en cajas de 5° por 5° a lo largo de todo el experimento. Desde el punto de vista geográfico vemos una mayor cantidad de observaciones en latitudes medias que en regiones tropicales. Este efecto se debe a la proyección Mercator de la retícula, que provoca que en las cajas ubicadas más lejos del Ecuador entre una mayor cantidad de puntos de retícula, y por consiguiente, tengamos una mayor densidad de observaciones. En las diferentes capas verticales observamos que el mayor número de observaciones se concentra en los niveles superiores a los 300 hPa, mientras que la menor cantidad se ubica entre superficie y 800 hPa. Estas diferencias son la consecuencia de haber elegido los niveles sigma de la SV para generar las observaciones. Las mismas comprenden mejor al cotejar la distribución de niveles de la Tabla 3.2, la cual indica que la cantidad de niveles sigma que se ubican entre las diferentes capas verticales consideradas es variable. A partir de esta tabla podemos deducir que para un sondeo cuyo dato de superficie se ubica en 1000 hPa, se generan 4 observaciones por variable entre superficie y 800 hPa, otras 4 observaciones por variable entre 800 y 300 hPa, y 6 observaciones por variable entre 300 hPa y el tope del modelo. Estas diferencias se hacen más notorias en regiones con topografía, dado que si bien el espaciamiento entre niveles sigma es menor cerca de superficie, la cantidad de niveles entre las capas consideradas aumenta especialmente para la ubicada por encima de los 300 hPa. Un detalle final a

tener en cuenta es que en las cajas que lindan con los bordes del modelo, el número de observaciones es mucho menor que en las cajas vecinas. Esto se debe a que las observaciones fueron generadas buscando que la distancia mínima a cualquiera de los bordes sea de 4 puntos de retícula, es decir de unos 400 km. La Figura 3.4 muestra un ejemplo particular de puntos de observación de presión en superficie, en donde se aprecia que algunas regiones son pobremente observadas y otras tienen una cobertura de observaciones mucho mayor en este ciclo en particular.

Esta distribución de observaciones difiere de los sistemas reales de observación, en donde aparecen grandes volúmenes de datos provenientes de satélites a la vez que las observaciones in situ como los radiosondeos en general mantienen los puntos de observación, los cuales se lanzan en regiones continentales. Asimismo, la distribución vertical de las observaciones simuladas en estos experimentos muestra que la mayor cantidad de las mismas se dan en la alta troposfera y estratosfera. Si bien esta distribución vertical para el caso de un radiosondeo no es demasiado realista, guarda cierto parecido con la realidad si consideramos que por lo general las observaciones de satélite suelen presentar un mayor volumen de información proveniente de los niveles superiores de la atmósfera. No obstante esto, se considera que tanto el número como la distribución espacial de las observaciones generadas en estos experimentos es suficiente a los fines de estudiar efectos producidos por las diferentes fuentes de error presentes en el sistema, tal como mostrarán los resultados.

En general, en los diferentes experimentos propuestos, la mayoría de las observaciones generadas ingresan en el ciclo de asimilación, y sólo una pequeña fracción de las mismas es rechazada. De las variables observadas en la vertical, las de viento son las que menor porcentaje de rechazo tienen (en promedio entre 2 y 10 observaciones por ciclo de un total de 364). Las de temperatura y humedad específica son rechazadas en una mayor proporción, oscilando entre 5 y 28 observaciones por ciclo. La cantidad varía principalmente según las fuentes de error que se incluyan en el sistema. Para

el caso de las observaciones de presión en superficie, en general no se registran observaciones rechazadas. Para determinar el rechazo de una observación en estos experimentos se utiliza un factor de multiplicación de 10. Esto significa que una observación será rechazada si la diferencia entre la misma y la media del campo preliminar supera el valor del error de la observación multiplicado por 10.

3.3 Experimentos idealizados: condiciones de Modelo Perfecto y Bordes Perfectos (MPBP)

La primera serie de experimentos supone el entorno más idealizado posible. En el mismo, el modelo WRF utiliza la misma retícula y las mismas parametrizaciones físicas que la SV, constituyendo el caso de modelo perfecto. Al mismo tiempo, las condiciones de borde son provistas por la base de datos FNL, lo cual sumado a las condiciones de borde inferior provenientes de la SV, constituyen las condiciones de bordes perfectos. Por tal motivo, estos experimentos se denominan de Modelo Perfecto y de Bordes Perfectos. Es importante aclarar que en este caso todos los miembros comparten las mismas condiciones de borde y parametrizaciones físicas.

En este conjunto de experimentos se realizan 2 simulaciones. En la primera no se asimilan observaciones y se deja al sistema evolucionar libremente bajo la sola influencia de las condiciones de borde. Esta simulación sin asimilación de observaciones lleva como sufijo NoObs. En la segunda simulación en cambio se asimilan las observaciones generadas a partir de la SV.

Esta serie de experimentos constituye un punto de partida en el cual el sistema de pronóstico-asimilación no tiene fuentes de error fuera de los errores en la condición inicial. Dada esta característica, la utilidad de estos experimentos es doble. Por un lado permiten ver a nivel regional que tan condicionado está el sistema por las condiciones de borde lateral e inferior y evaluar en qué medida la asimilación contribuye a mejorar la estimación de la condición inicial. Al mismo tiempo estos experimentos sirven como punto de comparación para

cuantificar el impacto producido por la presencia de fuentes de error en los bordes y en el modelo en los siguientes experimentos.

En vista de estudiar los errores del sistema analizamos el EETS definido en el Capítulo 2 para las dos simulaciones. La Figura 3.5 a muestra la marcha temporal de EETS del análisis promediado en las 3 dimensiones espaciales. Aquí podemos ver una mejora del experimento con asimilación de observaciones, especialmente en aquellos tiempos donde el experimento sin asimilación de observaciones tiene máximos de error. Estos máximos son consecuencia de inestabilidades del flujo atmosférico que pueden desarrollarse en este dominio, las cuales se manifiestan esporádicamente con mayor o menor intensidad. Por ejemplo, el pico de EETS del experimento MPBP-NoObs de la Figura 3.5 a durante el día 12 de septiembre se debe a errores en la representación de un ciclón en el Atlántico Sur. Las Figuras 3.5 b y 3.5 c muestran el promedio temporal y vertical del EES. Estas figuras muestran esencialmente en qué regiones la asimilación de datos puede tener un mayor impacto dado el control que ejercen las condiciones de borde en la escala sinóptica. Debemos tener en cuenta que, por estar trabajando en un dominio regional, las condiciones de borde perfectas limitan las regiones de desarrollo de inestabilidades y por ende de crecimiento de los errores del análisis. Por lo tanto, la Figura 3.5 b es un buen indicador del alcance que tienen las condiciones de borde al interior del dominio. Podemos ver que en latitudes medias, las condiciones de borde no permiten el crecimiento de errores en la región del Pacífico hasta alcanzar el continente, en donde los errores comienzan a crecer desde los Andes hacia el Atlántico. Esto responde al flujo de los Oestes típico de latitudes medias por donde viajan las perturbaciones de escala sinóptica que, dado que estamos simulando un período invernal, son las mayores responsables de causar inestabilidades en el flujo en esta parte del dominio. En latitudes bajas vemos que la influencia de los bordes es más acotada espacialmente, permitiendo el crecimiento de los errores en zonas más cercanas a los bordes. En esta región el tipo de inestabilidad dominante es la asociada con la convección cuyo desarrollo es más rápido y local. Con todo, no hay que perder de vista el hecho de que la representación de la convección en

estos experimentos es limitada dada la baja resolución del modelo. En la Figura 3.5 c podemos ver que la asimilación de observaciones permite disminuir la magnitud de los errores en todas las regiones, quedando las zonas continentales con los valores de error mayores. En la Figura 3.5 d vemos el promedio temporal del EES promediado horizontalmente para cada nivel sigma del modelo. Vemos que la mayor contribución de los errores proviene de los niveles bajos de la tropósfera, especialmente los pertenecientes a la capa límite atmosférica, y los niveles superiores de la troposfera hasta la tropopausa (niveles sigma 20 a 25 que corresponden a niveles de presión entre 200 y 400 hPa, considerando la superficie a nivel del mar, ver Tabla 3.2).

Dado que el EETS está conformado por los errores en viento, temperatura y presión en superficie, podemos estimar, para cada uno de los términos que conforman el error cuadrático medio de las diferentes variables, su contribución al EETS. La visualización de las diferentes componentes del error integradas en una variable que engloba diversas variables permite pesar la contribución real al error total del sistema de cada una de las componentes. La Figura 3.6 muestra la contribución total en energía de las diferentes componentes del error cuadrático medio según las ecuaciones (2.54) – (2.57) integrada en la vertical y promediada en el tiempo. En este caso las variables mostradas en la figura llevan las contribuciones del error en las diferentes variables que conforman el EES elevadas al cuadrado. En consecuencia, se cumple que la suma de las componentes sistemáticas y no sistemática mostradas es igual al error total mostrado en la primera columna, en virtud de la ecuación (2.49). En lo sucesivo, cuando se muestren las contribuciones al EES de las diferentes componentes se cumplirá esta relación. En esta figura podemos apreciar en líneas generales que casi la totalidad del error se asocia con la componente no sistemática del error cuadrático medio. Las componentes sistemáticas en cambio tienen un peso prácticamente despreciable en el error total en estos experimentos.

Sin embargo, esto no implica que no existan errores sistemáticos en algunas variables y niveles. Esto lo podemos ver por ejemplo en la Figura 3.7 que

muestra la contribución de las diferentes componentes del error para la temperatura en superficie. En este caso particular, debemos aclarar que las componentes mostradas no están elevadas al cuadrado como en la Figura 3.6., De aquí en más cuando se muestren las contribuciones de las componentes al error total para las diferentes variables, dichas contribuciones aparecerán con sus valores sin elevar al cuadrado. La única excepción a esto, tal como mencionamos anteriormente, será para la EES. La ventaja de observar las contribuciones sin elevar al cuadrado radica en el hecho de que podemos preservar el signo de los errores sistemáticos e intentar comprender físicamente los resultados. Podemos observar en esta figura que si bien la componente no sistemática del error es la que domina, también se observa que las dos componentes sistemáticas del error también tienen cierta contribución. Este tipo de resultados también se observan en otras variables como la presión en superficie o el geopotencial, y como veremos más adelante, en las variables relacionadas con la humedad también. Dado que el sistema en ambos experimentos sólo cuenta con errores en la condición inicial, en principio no cabría esperar la presencia de errores sistemáticos.

Cuando se indaga más en el origen de estos errores, reconocemos que los mismos son ajenos al proceso de asimilación. En efecto, los mismos se generan por el hecho de que la SV es una integración de 4 meses sin interrupciones, mientras que los campos del análisis provienen del campo preliminar, el cual es el resultado de una integración de 6 horas. Este simple hecho genera diferencias sistemáticas en el campo preliminar las cuales aparecen a raíz del proceso de inicialización presente en algunas rutinas del modelo WRF (como por ejemplo la inicialización de los parámetros en los que se basa el cálculo de los flujos de calor y humedad en superficie). Estos procesos de inicialización se activan únicamente en el primer paso de integración.

Este tipo de diferencias sistemáticas se puede obtener por ejemplo si se compara una integración del modelo WRF reiniciando el mismo cada 6 horas con una simulación realizada en forma ininterrumpida por un período de

varios meses. Sin embargo, los resultados dependen de qué archivos de salida del modelo WRF se utilicen para reinicializar la simulación. Si se utilizan los archivos de salida *wrfout* se obtienen los errores sistemáticos mencionados. En cambio, si se utilizan los archivos *wrfst* (archivos de salida del modelo WRF que se utilizan para reiniciar una simulación en un tiempo intermedio), estas diferencias desaparecen. Esto se debe al spin-up del modelo que incluye el cálculo de algunos parámetros de superficie, así como la inicialización de las nubes que a través del acople con los procesos radiativos también puede dejar su huella en las variables de superficie. Este hecho agrega una fuente de error en el modelo, aunque de una naturaleza diferente a la que introduciremos en la siguiente sección.

Como ya hemos mencionado anteriormente, el mero análisis de los errores de un análisis obtenido mediante una técnica por ensamble, no es suficiente para analizar la bondad del mismo. Por el contrario, debemos corroborar si dichos errores se encuentran correctamente representados dentro del ensamble. Para ello comparamos el EETS con la energía dada por la dispersión del ensamble, según la ecuación (2.63). En la Figura 3.8 se muestra el EETS junto con la dispersión del ensamble en la energía total seca del análisis y su correlación temporal entre ambos experimentos.

En esta figura observamos en primer lugar que la magnitud de los errores es menor en el experimento con asimilación de datos, lo cual también se evidencia en las figuras previas. Asimismo notamos que los valores de dispersión son claramente mayores en el experimento con asimilación de datos, especialmente en latitudes extra-tropicales y también en zonas puntuales de los trópicos como Colombia. Este hecho es particularmente notable, dado que el efecto de la asimilación de las observaciones es el de disminuir la dispersión del ensamble. En este punto se aprecia por tanto el efecto de la implementación de la técnica IMA en incrementar la dispersión del ensamble y llevarla a valores más cercanos a los del error.

Por otro lado, si comparamos los patrones espaciales de error cuadrático medio (Figura 3.8 a y d) y de dispersión del ensamble (Figura 3.8 b y e), observamos

que hay una mejor correspondencia espacial entre los máximos de ambas magnitudes en el experimento con asimilación de datos. Este hecho da un indicio de que en términos medios la representación de los errores dentro del ensamble en el experimento con asimilación es mejor en el experimento con asimilación de observaciones. Sin embargo, lo que es más importante es que los valores de dispersión indiquen en forma adecuada en qué momentos la incertidumbre, y por ende el error, es mayor, y en cuales es menor. Es por este motivo que verificamos los valores de correlación temporal entre ambas variables. Lo primero que notamos aquí es que en el caso del experimento sin asimilación de observaciones (Figura 3.8 c) la magnitud de la correlación es superior a 0.4 en gran parte del dominio, salvo en zonas continentales de latitudes medias. Esto en gran medida es atribuible a las condiciones de borde perfectas que mantienen al sistema bastante cercano a la realidad, lo cual provoca que la relación entre el error y la dispersión sea relativamente buena. Con todo, cuando se asimilan observaciones, la relación entre error y dispersión mejora notablemente en la mayor parte del dominio (Figura 3.8 f). También es notorio que en este caso la correlación aumenta hacia el este del dominio en latitudes medias especialmente (que sería en la dirección corriente abajo), lo cual implica de alguna manera que es en esa región donde hay un impacto mayor de las observaciones y del sistema de asimilación. Podemos ver además que existe una pequeña región en donde la mejora no es tan notable, la cual corresponde a pequeñas áreas continentales y que se extiende hacia el extremo sudoeste del dominio, lo cual está asociado en gran medida con la utilización de las mismas condiciones de borde lateral e inferior. Al utilizar las mismas condiciones de borde para todos los miembros del ensamble, la dispersión entre los miembros del ensamble disminuye hasta el punto tal que en algunas regiones y niveles verticales su magnitud es muy inferior al error. Para corroborar esto, calculamos la diferencia relativa promediada temporalmente entre el error cuadrático medio y la varianza del ensamble, de la siguiente forma:

$$\frac{\left(\frac{1}{T} \sum_{t=1}^T (mse - \delta^2)\right)}{\frac{1}{T} \sum_{t=1}^T \delta^2} \quad (3.1)$$

Esta diferencia se puede observar en la Figura 3.9 para el EETS, el viento zonal en el nivel sigma 22 que corresponde aproximadamente al nivel de 300 hPa y la temperatura en superficie. Valores positivos y mayores a 1 de esta diferencia indican que el error es mayor que la dispersión del ensamble, de manera que el ensamble como tal resulta sub-dispersivo. Por el contrario, valores en torno a 1 o menores indican que el error y la dispersión son de magnitudes similares. En esta figura podemos observar un claro déficit de dispersión en regiones extra-tropicales especialmente, en donde las condiciones de borde lateral dominan fuertemente el flujo atmosférico, lo cual es apreciable en las 3 variables mostradas. Las condiciones de borde inferior también generan en este caso una sub-dispersión del ensamble en la variable de temperatura en superficie, especialmente en regiones continentales. Esto se genera a causa de que los valores de dispersión del ensamble en dichas regiones tenderán a ser muy pequeños por el hecho de utilizar las mismas condiciones de borde. Sin embargo, otros efectos como los asociados al spin-up del modelo que mencionamos anteriormente, podrían ayudar a la sub-dispersión del ensamble, vía un aumento del error. A pesar de estos problemas generados por la configuración de condiciones de borde utilizadas, la asimilación de datos y la aplicación de la técnica de IMA ayudan a mitigar al menos parcialmente este problema, dado que los déficits de dispersión disminuyen en este caso, aunque no lo resuelven por completo.

A fin de comparar el grado de mejora del análisis del experimento MPBP en relación al experimento MPBP-NoObs, se calcula la reducción relativa de las diferentes componentes del error en valores porcentuales. Dicha mejora se calcula integrando los errores en todo el dominio del modelo. En términos matemáticos, se calcula la reducción de cada componente del error de un dado experimento con respecto a un experimento control de la siguiente forma:

$$RMSE\%: \frac{100 * \left(\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} (RMSE(Exp)_{i,j,k} - RMSE(Control)_{i,j,k}) \right)}{\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} RMSE(Control)_{i,j,k}} \quad (3.2)$$

$$MNBIAS\%: \frac{100 * \left(\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} (|MNBIAS(Exp)|_{i,j,k} - |MNBIAS(Control)|_{i,j,k}) \right)}{\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} |MNBIAS(Control)|_{i,j,k}} \quad (3.3)$$

$$SDBIAS\%: \frac{100 * \left(\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} (|SDBIAS(Exp)|_{i,j,k} - |SDBIAS(Control)|_{i,j,k}) \right)}{\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} |SDBIAS(Control)|_{i,j,k}} \quad (3.4)$$

$$No\ SIST\%: \frac{100 * \left(\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} (No\ SIST(Exp)_{i,j,k} - No\ SIST(Control)_{i,j,k}) \right)}{\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} No\ SIST(Control)_{i,j,k}} \quad (3.5)$$

En donde los índices I , J y K denotan el número de puntos de retícula del modelo en las direcciones zonal, meridional y vertical, respectivamente. En el caso particular del *mnbias* y el *sdbias*, la diferencia se calcula con el módulo, debido a que estas variables conservan su signo. De esta manera, al calcular el grado de mejora o de degradación del índice, sólo se computa la reducción del valor absoluto y se ignora si hubo un cambio de signo.

En este caso, como mencionamos anteriormente, compararemos los errores del experimento con asimilación de datos con los valores del experimento sin asimilación de datos, que hará las veces de experimento control. De esta manera, valores negativos en las ecuaciones (3.2)-(3.5) implican que hay una reducción del error o una mejora en la calidad del análisis en relación al experimento sin observaciones asimiladas, mientras que valores positivos indican que el análisis se degrada con respecto al experimento sin asimilación de observaciones.

Cabe destacar en este punto que para el caso particular del EETS, las variaciones tanto en el error total como en sus diferentes componentes

involucran las diferencias al cuadrado de las diferencias en viento, temperatura y presión en superficie, según se desprende de las ecuaciones (2.54)-(2.57). Por este motivo, la ecuación (3.2) para el EETS se computa tomando las diferencias en el error cuadrático medio en lugar del RMSE. Por su parte, para las componentes de error sistemático, la reducción del error se puede computar mediante la resta de los términos sin tomar el módulo, ya que los mismos son siempre positivos. De manera análoga, para la dispersión del ensamble se calcula el grado de aumento o disminución relativa con respecto al experimento MPBP-NoObs, de la siguiente manera:

$$\delta\%: \frac{100 * \left(\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} (\delta(Exp)_{i,j,k} - \delta(Control)_{i,j,k}) \right)}{\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} \delta(Control)_{i,j,k}} \quad (3.6)$$

En este caso, valores positivos (negativos) implican que la dispersión es mayor (menor) en el caso del experimento MPBP en comparación con el experimento sin observaciones asimiladas.

Finalmente, para la correlación se calcula la variación absoluta promediada en todo el dominio entre los experimentos; es decir:

$$\Delta Corr: \left(\frac{1}{I * J * K} \sum_{i,j,k=1}^{I,J,K} (Corr(Exp)_{i,j,k} - Corr(Control)_{i,j,k}) \right) \quad (3.7)$$

En la Tabla 3.3 se muestra el porcentaje de mejora del análisis del experimento MPBP con respecto al experimento MPBP-NoObs, integrando las diferencias en todo el dominio para el EETS y algunas variables particulares. Tanto en el EETS como en las variables de viento, temperatura, presión y geopotencial observamos una clara mejora del experimento con asimilación de observaciones, aunque el grado de mejora es diferente. Vemos que el EETS

una mejora del orden del 40%, mientras que las variables individuales la mejora ronda el 20%. Esto se debe a que el EETS es el resultado de sumas de diferencias al cuadrado, y en consecuencia las mejoras tanto en el error total como en sus diferentes componentes se amplifican.

Cuando posamos la mirada sobre las diferentes componentes del error, notamos que hay una mejora relativa en todas ellas. Sin embargo, debemos tener en cuenta que las componentes sistemáticas en estos experimentos explican un porcentaje muy pequeño del error total. En ese sentido, la componente no sistemática es la más importante a la hora de analizar la reducción de los errores, ya que es la que tiene mayor impacto en la reducción del error total. De todos modos, tanto las componentes del *mnbias* como del *sdbias*, también muestran una reducción, lo cual es un hecho destacable si tenemos en cuenta que estas componentes están explicadas por errores vinculados con la integración numérica del modelo. Esto indica que la asimilación de observaciones ayuda a reducir los errores del modelo. Dicha reducción podemos corroborarla por ejemplo en la Figura 3.7, que muestra que en general los errores sistemáticos disminuyen con la asimilación en las regiones más problemáticas, a pesar de que la temperatura en superficie es una variable sub-dispersiva, tal como se observa en las Figuras 3.9 c y 3.9 f .

Por el lado de la dispersión del ensamble observamos un aumento sustancial en el experimento con asimilación de observaciones en variables de viento, temperatura y presión, lo cual es producido principalmente por el efecto de la IMA, dado que el efecto producido por asimilar observaciones es el de disminuirla. En general, los aumentos de dispersión oscilan entre el 20 y el 40% aproximadamente. Al mismo tiempo, la mejora en la correlación temporal entre error y dispersión sólo es apreciable en la EETS y en menor medida en la temperatura, más no así en las variables cinemáticas o de masa que incluso muestran cierta desmejora, como en el caso de la presión de superficie.

	Total	MNBIAS	SDBIAS	No SIST	Dispersión	Correlación
EETS	-42,24	-30,64	-29,02	-43,26	31,34	0,082
U	-23,87	-21,22	-23,00	-23,99	20,44	0,000
T	-17,76	-15,79	-11,26	-18,38	24,10	0,017
PSFC	-19,48	-24,25	-27,90	-17,94	37,18	-0,007
Geopot.	-20,74	-17,13	-32,97	-20,75	32,77	0,000
EHIV	-14,23	-12,47	-2,03	-14,59	48,95	0,012
PP	-0,71	0,00	-0,72	-0,94	30,60	0,003

Tabla 3.3: Porcentaje de reducción de errores y de dispersión en el ensamble, junto con aumento de correlación entre RMSE y dispersión del experimento MPBP con respecto al experimento MPBP-NoObs. Valores negativos indican reducción y positivos incremento en las diferentes variables.

Hasta aquí analizamos los errores de los análisis asociados a variables que no incluyen a la humedad. Para completar el análisis de los resultados de los experimentos, verificamos los errores en variables como la humedad específica y la precipitación. Comenzamos con los errores en humedad específica integrados en la vertical (EHIV) hasta el nivel sigma 30 según las ecuaciones (2.58)-(2.61). La integración se realiza solamente hasta el nivel 30, que corresponde aproximadamente al nivel de presión de 100 hPa por el hecho que el grueso del contenido de humedad de la atmósfera se encuentra concentrado en los niveles más bajos. La Figura 3.10 muestra las diferentes componentes del EHIV. En esta variable notamos en primer lugar un bias húmedo sobre el continente al este de los Andes entre 10°S y 35°S en ambos experimentos (Figura 3.10 b y f). También se observa un bias negativo en el *sdbias* en zonas continentales del trópico (que implicaría que la amplitud de los ciclos de la humedad integrada en la vertical en ambos experimentos es menor que en la SV), aunque de menor magnitud que el *mnbias* (Figura 3.10 c y g). Ambos bias también están asociados a problemas de spin-up, tal como mencionamos anteriormente. De todos modos, a pesar de la presencia de los errores sistemáticos, la componente no sistemática es la que domina en el error total, y en general se aprecia una disminución del error en el experimento con asimilación de observaciones. Esto se ve corroborado en la Tabla 3.3 que muestra una reducción del error, aunque de menor magnitud en comparación con las variables analizadas anteriormente, con valores en torno del 15%. Las

componentes sistemáticas en cambio, no evidencian una mejora tan marcada como en las variables que analizamos anteriormente. Cuando analizamos la dispersión del ensamble en la humedad integrada en la vertical (Figura 3.11) observamos un aumento de casi el 50% de la magnitud de la dispersión. Este hecho es particularmente notable en el caso del experimento con asimilación de observaciones, pues la humedad integrada muestra valores de dispersión mayores a los del error en latitudes tropicales desde el este de los Andes hacia el borde oeste (Figura 3.11 b y e). Espacialmente notamos que hay una mayor correspondencia entre las áreas de mayor error y mayor dispersión en el experimento con asimilación de observaciones. Cuando se analiza el campo de correlación temporal entre el error y la dispersión (Figura 3.11 c y f) se observan pocos cambios entre ambos experimentos. En general, los mayores cambios se aprecian hacia el este del continente y el Océano Atlántico en latitudes medias, en una zona de desarrollo de ondas baroclínicas y relativamente alejada de la influencia de los bordes, y en una estrecha franja al este de los Andes entre 10 y 20°S. Esta variable tiene ciertas particularidades, ya que muestra por ejemplo una zona de altas correlaciones sobre el Pacífico subtropical en ambos experimentos. Esta zona es una región dominada por la subsidencia asociada al anticiclón del Pacífico Sur, y en consecuencia sumamente estable desde el punto de vista convectivo y con escasa humedad. Al mismo tiempo este sistema tiene una variabilidad temporal bastante larga en comparación con la extensión del ciclo de asimilación. Si a esto le sumamos el hecho de que el modelo no tiene errores en este caso, no es de extrañar que aun en el caso en que no se asimilen observaciones, el sistema no tenga grandes inconvenientes en representar adecuadamente el error en esta región. En zonas de convección activa en cambio, como por ejemplo en la Zona de la Convergencia Intertropical (ZCIT) ubicada al norte del Ecuador en el período del experimento, las correlaciones son menores debido a que la convección actúa en escalas temporales más cortas que los ciclos de asimilación. Con todo, debemos tener en cuenta que la escala horizontal con la que estamos trabajando es muy gruesa para representar correctamente la convección. En consecuencia, es posible que las

correlaciones temporales obtenidas aquí (que rondan entre 0.3 y 0.5) sean más altas de lo que se obtendría si trabajáramos con una resolución horizontal mayor. Otro punto que debemos tener en consideración con respecto a la humedad, es que a diferencia de variables como temperatura o viento, las condiciones de linealidad que asume el KF no son tan válidas. Por lo tanto, no sería de extrañar que la mejora exhibida en el experimento con asimilación de datos no sea tan marcada como en otras variables. De hecho, de todas las variables para las cuales se asimila información, es la que muestra la menor reducción del error, a pesar de que es una de las que muestra un mayor incremento de la correlación temporal entre error y dispersión.

En los campos de error de la precipitación (Figura 3.12), notamos que en general aparecen bias secos en todo el dominio. Dichos bias se maximizan especialmente en zonas de convección activa, en la región del ZCIT, hasta el punto tal de tener una magnitud similar a la de los errores no sistemáticos. Esto da indicio de un inicio tardío en la convección en los experimentos comparado con la SV, lo cual es común a todos los experimentos. En otras regiones de precipitación como en la región baroclínica que se extiende desde el sudeste de Sudamérica en 30°S hacia el Océano Atlántico o en la región de precipitación orográfica que se ubica sobre el sur de Chile también observamos bias negativos, pero con una magnitud menor en comparación con los errores no sistemáticos presentes allí. Nuevamente, estos bias también aparecen debido a que el modelo es integrado en intervalos de tiempo cortos en comparación con la SV. Este resultado no es sorprendente si tenemos en cuenta que la precipitación es la variable que más debería estar afectada por problemas de spin-up. La Tabla 3.3 corrobora esta información, arrojando valores que indican que no hay una mejora apreciable en el caso del experimento con asimilación de observaciones. Debemos tener en cuenta no obstante, que en este caso estamos verificando el impacto en la precipitación a plazos de 6 horas, en donde la precipitación está fuertemente afectada por el spin-up del modelo. Esto no implica que necesariamente no pueda haber una mejora en un pronóstico a plazos de 24 o 48 horas por ejemplo. Este aspecto

particular, si bien no ha sido explorado en este trabajo, será abordado a futuro.

De todos modos, hay un hecho de gran importancia que ayuda a explicar la falta de mejoras en esta variable y es el hecho de que no estamos asimilando información de precipitación. Este resultado sugiere que la precipitación en un análisis puede verse afectada por errores en el modelo si no se la intenta acercar a las observaciones. Sin embargo, futuros resultados mostrarán que puede ocurrir que una variable como la precipitación evidencie una mejora en su representación a través de una mejora en otras variables. No obstante, algunos trabajos como el de Lien y otros (2013) indican que la asimilación de la precipitación redundante en una mejora tanto de la calidad del análisis como de los pronósticos derivados a partir del mismo. Finalmente, observamos de la Tabla 3.3 que la dispersión del ensamble en el experimento con asimilación de observaciones aumenta un 30 %, y que apenas si hay cambios en la correlación temporal entre el error y la dispersión.

3.4 Experimentos idealizados: condiciones de Modelo Imperfecto y Bordes Perfectos (MIBP)

En este experimento consideramos el caso en el cual el modelo es imperfecto. La imperfección del modelo es una fuente de error presente siempre en las situaciones reales y reconoce orígenes muy diversos. Una de las fuentes de error típicamente presente en los modelos numéricos es la representación de los procesos de escala menor a la resuelta explícitamente. En nuestro caso introducimos el error del modelo en la representación de los procesos de escala sub-reticular. Para ello modificamos las parametrizaciones de convección, microfísica y capa límite en los diferentes miembros del ensamble con respecto a las utilizadas en los experimentos MPBP y la SV. Junto con esto también introducimos un error en la discretización temporal de las ecuaciones, tal como se explica más adelante. Las condiciones de borde continúan siendo dadas por los datos del FNL, con lo que la única fuente de error en nuestro sistema de

asimilación proviene del modelo solamente. Por lo tanto, debido a que sólo el modelo es imperfecto, el nombre de estos experimentos es el de Modelo Imperfecto y Bordes Perfectos.

En este experimento de modelo imperfecto se utilizan las parametrizaciones ETA-Ferrier (Rogers y otros, 2001) para la microfísica, Betts-Miller-Janjic (BMJ, Janjic, 1994) para la convección y Medium Range Forecast (MRF, Hong y Pan, 1996). El resto de la parametrizaciones físicas se mantiene igual a las indicadas en la Tabla 3.2. Junto con esto, se implementa además una inicialización de los miembros del ensamble para cada ciclo de pronóstico sin fase condensada, lo que comúnmente se conoce como inicialización “cold-start”. Motiva esta implementación el hecho de que al utilizar la parametrización de la microfísica de ETA-Ferrier se producen problemas de inestabilidad numérica, que son consecuencia de incompatibilidades entre la forma en que se definen y calculan las variables condensadas en el esquema utilizado en este caso y el obtenido en los análisis LETKF. Por este motivo, al imponer un valor de 0 en los campos iniciales de qw , qi y q_{rain} , dicha incompatibilidad desaparece. Es de esperar que este hecho imponga un bias seco en los campos de precipitación acumulada de estos experimentos que se sumará al ya encontrado en los experimentos MPBP. Finalmente, como mencionamos anteriormente, se agrega una fuente de error adicional en el paso temporal del modelo, implementando un paso temporal de 120 segundos, en lugar de 300 segundos utilizado en la SV.

En este experimento se realiza, al igual que en el caso del experimento MPBP, un entrenamiento de la IMA. En este caso se parte de la inflación obtenida en el último tiempo del experimento MPBP y se entrena la inflación realizando este experimento 2 veces, lo cual equivale a entrenar la inflación por un período de 8 meses.

Comenzamos analizando los errores de este experimento a partir de la Figura 3.13 que muestra el EETS para los experimentos MPBP y MIBP con asimilación de observaciones en ambos casos. Como es de esperar, el haber agregado una fuente de error en el modelo repercute en un evidente aumento del EETS en el

experimento MIBP en comparación con el MPBP. A nivel geográfico se observa que las zonas de mayor error corresponden a las regiones de convección activa como la ZCIT en los trópicos y la de desarrollo baroclínico en latitudes medias y subtropicales sobre y al este del continente. Estas regiones son las mismas que aparecían en los experimentos MPBP, en donde las inestabilidades dinámicas del flujo, sumadas a errores en los procesos microfísicos, de convección y de capa límite maximizan los errores del campo preliminar y por ende del análisis. También se observa una pequeña y estrecha región de mayor error al este de los Andes, especialmente entre 20 y 30°S. En este caso, y a pesar de la influencia de los bordes, los errores crecen más rápidamente a medida que nos movemos desde los bordes hacia el interior del dominio en comparación con el experimento MPBP. Esto se evidencia especialmente sobre el Océano Pacífico en donde los errores crecen notablemente cerca del borde oeste. El perfil vertical de los errores muestra que el mayor impacto producido por las imperfecciones del modelo se produce mayormente en los niveles bajos del modelo, especialmente en los niveles pertenecientes a la capa límite.

Si analizamos las diferentes componentes del EETS que se muestran en la Figura 3.14, notamos en primer lugar que el crecimiento de los errores dado por las imperfecciones del modelo tiene su mayor impacto en las regiones ecuatoriales sobre el continente donde la convección es importante, y también en latitudes medias donde se desarrollan las ondas baroclínicas. Entre las diferentes componentes del error se observa que la no sistemática es la más importante. Sin embargo, la componente sistemática también crece de manera notable, especialmente la relacionada con las diferencias entre medias (*mnbias*), sobre el océano en zonas tropicales, y en partes del Océano Pacífico. En el caso del *sdbias* también se registra un aumento, pero el mismo es de una magnitud más pequeña que en el caso del *mnbias* y sólo es comparable a este último en algunas variables, regiones y niveles particulares, como por ejemplo en temperatura y viento en superficie. Debido a que sólo tiene peso en ciertos niveles, al integrarse en la vertical en las diferentes variables que componen el EES, su influencia queda muy desdibujada en comparación con el *mnbias*. Este

resultado puede confirmarse al observar la Figura 3.15, en donde se muestran los perfiles verticales de las componentes del error promediadas horizontalmente para las variables geopotencial (Figura 3.15 a-d) , temperatura (Figura 3.15 e-h) y viento zonal (Figura 3.15 i-l). Esta figura muestra el aumento del error como consecuencia de las imperfecciones del modelo, siendo la componente sistemática del *mnbias* la que acusa el mayor incremento con respecto al experimento MPBP. Esta información se puede corroborar también en la Tabla 3.4, en donde se observa que de las diferentes componentes del error, la que más crece es la del *mnbias*, con crecimientos de entre 3 y 5 veces y media. En el caso de la energía, teniendo en cuenta que el incremento se calcula para las variables al cuadrado, el incremento de la componente del *mnbias* es de más de 20 veces. No obstante esto, y tal como se observa en la Figura 3.15, la componente no sistemática es la que domina en el error total. En el caso particular de la componente no sistemática los incrementos son más moderados, cercanos al 150% en las diferentes variables.

	Total	MNBIAS	SDBIAS	No SIST	Dispersión	Correlación
EETS	655,26	2321,90	811,70	537,56	158,75	-0,299
U	174,01	417,30	235,26	158,56	63,02	-0,141
T	185,91	551,20	236,86	155,24	61,03	-0,225
PSFC	185,92	325,70	163,05	138,65	80,17	-0,139
Geopot.	198,60	432,77	260,30	150,56	82,83	-0,175
EHIV	175,29	341,47	74,01	153,01	82,09	-0,214
PP	13,34	-0,04	35,65	16,94	66,22	-0,021

Tabla 3.4: Porcentaje de reducción de errores y de dispersión en el ensamble, junto con aumento de correlación entre RMSE y dispersión del experimento MIBP con respecto al experimento MPBP. Valores negativos indican reducción y positivos incremento en las diferentes variables.

Analizando los errores de cada variable por separado podemos notar que en el geopotencial tenemos un máximo negativo cerca del nivel de la tropopausa (nivel sigma 25) (Figura 3.15 b), el cual también está acompañado por una componente negativa en el viento zonal en el mismo nivel (Figura 3.15 j). La

temperatura por su parte muestra un bias positivo en la capa límite, seguido de bias negativos en la atmósfera libre (Figura 3.15 f). En este aspecto se aprecia que hay una relación entre los errores sistemáticos de temperatura y de geopotencial, ya que el bias de temperatura es proporcional a la derivada con respecto de la vertical del bias en geopotencial. De esta manera se observa que para el experimento MIBP tenemos un bias positivo de geopotencial en el nivel sigma igual a 7 (cerca del tope de la capa límite), coincidente con bias positivos de temperatura en niveles inferiores, y que más arriba se tornan negativos hasta el tope de la troposfera en respuesta a los bias negativos de temperatura en la atmósfera libre.

A continuación analizamos la representación de los errores del análisis en base a la dispersión de su ensamble. Por ello en la Figura 3.16 se muestra el EETS junto con su dispersión en el ensamble y las correlaciones entre ambas variables. Vemos aquí que la mayor dispersión del ensamble se da en regiones tropicales, en especial en la región del ZCIT, que experimenta el mayor incremento de la dispersión. También se observa un crecimiento importante de la dispersión en toda la franja tropical, extendiéndose hacia el sudeste de Sudamérica y el Océano Atlántico. Este crecimiento de la dispersión también se corrobora en la Tabla 3.4, con crecimientos entre el 60 y el 160%. Dado que la técnica IMA es la única forma que estamos utilizando para compensar la falta de dispersión causada por el error del modelo, en este caso es la responsable de incrementar la dispersión del análisis. A juzgar por los valores de dispersión obtenidos, que son claramente sub-dispersivos en comparación con los errores, tenemos un primer indicio de que la IMA no está siendo del todo capaz de representar el efecto del error del modelo. De todos modos notamos que existe una buena correspondencia espacial entre los máximos de error y de dispersión.

Por su parte, la correlación entre el error y la dispersión del ensamble presenta valores razonables en comparación con el experimento MPBP sobre el continente en regiones tropicales y sobre el Atlántico en latitudes medias, con valores entre 0.3 y 0.6. Al mismo tiempo, algunas zonas del Océano Pacífico y

el nordeste de Brasil presentan una seria degradación de la representación del error del ensamble, dado que las correlaciones se vuelven cercanas a 0 o incluso negativas. Dichas zonas dan cuenta de la mayor degradación en la calidad del análisis según la combinación de parametrizaciones elegidas en este caso para representar el error del modelo. Esta degradación de la correlación también se ve reflejada en la Tabla 3.4, con caídas en la correlación entre 0.14 y 0.3 para las diferentes variables.

Si consideramos las variables de humedad, observamos que por un lado la humedad específica presenta un comportamiento similar en términos de crecimiento de los errores y de la dispersión del ensamble a las demás variables, según la Tabla 3.4. La precipitación por su parte tiene un comportamiento bastante particular, dado que si bien se registra un aumento tanto del error como de la dispersión, su magnitud es claramente menor en comparación con las demás variables. La mayor diferencia de impacto se encuentra en las componentes sistemáticas, especialmente la del *mnbias*, que son prácticamente iguales que en el experimento MPBP. Esto también se puede observar en la Figura 3.17 b y f. Este resultado sugiere que el efecto de inicializar el modelo sin condensado en cada ciclo de asimilación no provoca grandes cambios en esta variable si lo comparamos con el efecto de interrumpir la integración del modelo cada 6 horas que discutimos anteriormente. O dicho de otro modo, los problemas de spin-up del modelo son más importantes que el efecto del “cold-start” impuesto en este caso. Donde sí se observa un cambio interesante de destacar es en la componente del *sdbias* sobre la región oceánica de la ZCIT (Figura 3.17 c y g), que muestran una mayor amplitud de la variabilidad temporal de la precipitación para el caso de modelo imperfecto. No obstante esto, la componente no sistemática es la que domina el error total, la cual exhibe su mayor incremento en la región de la convergencia intertropical.

Dado que nos encontramos en condiciones de modelo imperfecto es interesante analizar el comportamiento de la IMA en este caso, dado que la implementación de dicha técnica busca a partir de las innovaciones determinar

el valor de inflación óptimo para incrementar convenientemente la dispersión del ensamble durante el proceso de asimilación. La IMA nos indica de alguna manera en qué regiones los errores del análisis no están pudiendo ser representados óptimamente por el ensamble, y que por lo tanto deben ser incrementados mediante el algoritmo de inflación.

En la Figura 3.18 se muestran los valores de IMA para los experimentos MPBP y MIBP. Podemos apreciar en primer lugar que tal como es de esperar, la inclusión de errores en el modelo obliga a un aumento de la IMA, que tiende a aumentar conforme progresa el experimento en el caso de modelo imperfecto. Este aumento reconoce su origen en el hecho de que el valor de inflación utilizado al comienzo del experimento (valor de $\bar{\alpha}_t^b$ de la ecuación (2.27)) es muy alto para la dispersión del campo preliminar en el primer ciclo de análisis. Esto se debe a que la magnitud del campo preliminar en el primer ciclo es muy similar a la magnitud de las perturbaciones iniciales generadas. En consecuencia, al asimilarse las observaciones se genera una caída importante de la dispersión del ensamble, y junto con ello el valor de inflación resultante luego de la asimilación ($\bar{\alpha}_t^a$ en (2.27)) es mucho menor que el valor de inflación inicial. Esta caída no se aprecia en la Figura 3.18 a, ya que lo que se muestra aquí son los valores de $\bar{\alpha}_t^a$. Luego de la caída en el primer ciclo de asimilación, la IMA progresivamente aumenta en el transcurso del experimento. Asimismo, este comportamiento de la inflación podría explicar el comportamiento del EETS visto en la Figura 3.13a, en donde se aprecia que el error es mayor al comienzo del experimento que al final del mismo. De todos modos, podría haber otras causas detrás de este comportamiento, como por ejemplo un cambio en la predictibilidad del flujo a lo largo del experimento, que hace que sea más o menos fácil representar el comportamiento del mismo.

A nivel espacial se aprecia un aumento sostenido de la inflación en la región de los Andes entre 20 y 30°S, que se da principalmente en niveles bajos, y que coincide con la región de máxima inflación en la Figura 3.18c. De hecho, tanto en el experimento MPBP como en el experimento MIBP la IMA no termina de converger en dicha región, y esto es consecuencia principalmente de un déficit

de dispersión en el ensamble del campo preliminar. En otras regiones del dominio se observa un aumento importante de la IMA en el experimento MIBP, en comparación con el MPBP. Por ejemplo, sobre el Atlántico al sur de 20°S, la IMA en el experimento MIBP es de aproximadamente del doble del experimento MPBP. Otro aspecto interesante a destacar es el aumento de la IMA en la vertical. Si bien se aprecia un aumento notable en toda la troposfera, notamos que el mayor aumento se da en los niveles correspondientes a la troposfera baja, es decir a la capa límite atmosférica (Figura 3.18d).

Para poder comprender un poco más en profundidad cómo se comporta el ensamble en representar los errores del sistema, a continuación calculamos para las variables U, V, T, q y PSFC, las diferencias relativas porcentuales de las trazas de las matrices de la ecuación (2.67) en las cajas de 5° por 5° y las capas de atmósfera que se muestran en la Figura 3.3. Algebraicamente, lo que estamos calculando dentro de cada una de las cajas es lo siguiente:

$$100 * \frac{\left(\sum_{i=1}^T \frac{n(i) * \text{tr}(H(x_i^a) - H(x_i^b) * (y_i^o - H(x_i^b))^T)}{N} - \sum_{i=1}^T \frac{n(i) * \text{tr}(HP_1^b H^T)}{N} \right)}{\sum_{i=1}^T \frac{n(i) * \text{tr}(HP_1^b H^T)}{N}} \quad (3.8)$$

Para cada una de las cajas los $n(i)$ representan el número de observaciones asimiladas en cada ciclo de asimilación, mientras que N es el número total de observaciones asimiladas en todo el período de verificación. De esta manera, estamos calculando las diferencias relativas por observación.

Debemos notar que en la estimación de los términos de la ecuación (2.67) realizada mediante la ecuación (3.8), se está intercambiando una esperanza matemática de los vectores innovación (término $E[\mathbb{d}_b^a (\mathbb{d}_b^o)^T]$ de la ecuación (2.67)) por una media temporal de vectores innovación (término $\sum_{i=1}^T \frac{n(i) * \text{tr}(H(x_i^a) - H(x_i^b) * (y_i^o - H(x_i^b))^T)}{N}$ de la ecuación (3.8)). Esto significa que

estamos reemplazando una expresión que refiere a la esperanza que es válida para un tiempo dado y que varía en los diferentes ciclos, dado que las matrices de covarianza varían en cada ciclo, por una estimación tomada de una media temporal de los vectores innovación. Desde el punto de vista matemático, la utilización de la ecuación (3.8) no es una forma lícita de realizar la estimación de los términos que intervienen en la ecuación (2.67). Sin embargo, como para cada ciclo de análisis contamos con una única realización para estimar estos valores, sólo podemos echar mano de una media temporal para estimar estos términos, asumiendo que la magnitud de los mismos no se modifica sustancialmente en el transcurso del experimento. Por lo tanto, los valores que se obtengan mediante (3.8) tendrán un valor de incertidumbre asociado y sólo se deberán tener en consideración aquellos valores que tengan cierta coherencia espacial y sean diferenciables de ruido.

Valores positivos en (3.8) nos indican que la matriz de covarianza del campo preliminar contiene valores de error demasiado pequeños en función de la corrección aplicada en la asimilación, mientras que valores negativos indican que los errores asumidos son excesivamente grandes. Para tener una noción acerca del grado de sobre o sub-dispersión del ensamble, dividimos dichas diferencias por la traza promediada temporalmente de la matriz de covarianza del campo preliminar. De esta forma obtenemos un error relativo que nos indica en qué medida la dispersión del ensamble se acerca al valor óptimo. Podemos ver de esta ecuación además, que las diferencias están pesadas por el número de observaciones asimiladas en cada ciclo de asimilación. Esto se hace de este modo, ya que el número de observaciones generadas a partir de la SV puede variar fuertemente de un ciclo al siguiente en cada una de dichas cajas. En consecuencia, si se promediara temporalmente sobre todos los ciclos de asimilación sin tener en cuenta el número de observaciones de cada ciclo, los resultados pueden verse fuertemente afectados.

El cálculo de estas diferencias se realiza sobre cajas de 5° por 5° para las observaciones asimiladas en los últimos 3 meses de los experimentos. Esto lo hacemos por un lado para evitar los primeros 30 días del experimento en

donde la matriz de covarianza estimada por el filtro se está acomodando a las inestabilidades del flujo, dado que inicialmente dicha matriz no contiene información acerca de los errores del día. Asimismo, debido a que la cantidad de observaciones asimiladas es bastante pequeña en comparación con casos reales (ver Figura 3.3), agrupamos las observaciones de diferentes variables en las diferentes capas de la atmósfera por cajas de 5° por 5°, para así obtener una estadística más robusta. Dividimos la verificación en niveles bajos (observaciones asimiladas entre superficie y 800 hPa), niveles medios (entre 300 y 800 hPa) y niveles altos (niveles por encima de los 300 hPa). La elección de los niveles para separar las observaciones en estas capas es arbitraria.

El motivo de haber elegido la ecuación 2.67 en lugar de la ecuación 2.43 que es en la que se basa la técnica IMA es que en estos experimentos ya conocemos el valor real de la matriz R y que la misma está correctamente determinada, por lo que sabemos que la falta de dispersión proviene de deficiencias en la determinación de la matriz P^b . Por otro lado, es cierto que para estudiar la dispersión del campo preliminar, podríamos utilizar la ecuación (3.1) para el campo preliminar, lo cual nos permitiría obtener una mejor noción de cuán sub o sobre-dispersivo es dicho campo, ya que estaríamos utilizando los puntos de retícula del modelo. Sin embargo, el utilizar la ecuación (3.8) nos permite comprender mejor el comportamiento de la IMA. Al mismo tiempo nos permite evaluar el funcionamiento de esta herramienta de diagnóstico en este entorno de trabajo idealizado, dado que este tipo de herramienta suele utilizarse para estimar los valores de la matriz R en los casos reales. De todos modos, no debemos perder de vista que los valores de IMA son consecuencia de los valores de dispersión en el ensamble, y a su vez los mismos son consecuencia de los valores de IMA en los análisis de los ciclos anteriores.

En la Figura 3.19 se muestran los valores de la ecuación (3.8) para los experimentos MPBP y MIBP en cada caja. Las variables elegidas en este caso son el viento zonal entre 300 y 800 hPa y la temperatura y la humedad específica entre superficie y 800 hPa. En el caso de la humedad específica se

elige mostrar la ecuación (3.8) sin dividir por la covarianza media, dado que como se tratan de valores pequeños, la división arroja diferencias porcentuales extremadamente grandes. Si bien se podrían mostrar las diferencias para otros niveles y variables, se eligen los mostrados aquí, ya que son los que arrojan las diferencias más importantes.

Las diferencias en esta ecuación muestran un déficit de dispersión del campo preliminar en el viento zonal en la región de los Andes entre 20°S y 40°S en ambos experimentos (Figura 3.19 a y d). También se observa corriente arriba de la cadena montañosa cierto déficit de dispersión en ambos experimentos. Este último hecho está relacionado con la utilización de las mismas condiciones de borde en todo el dominio, lo cual provoca que la dispersión del ensamble sobre la región del Océano Pacífico al sur de 30°S sea pequeña. Dicho problema de sub-dispersión sobre la esquina sudoeste del dominio se acentúa cuando se introducen errores en el modelo (Figura 3.19 d).

Si bien las dos regiones de sub-dispersión (cordillera de los Andes y Océano Pacífico) parecen estar relacionadas, cada una de ellas obedece a causas diferentes. La región del Pacífico presenta valores bajos de dispersión por el hecho de utilizarse las mismas parametrizaciones físicas y las mismas condiciones de borde. En el caso del experimento MPBP este hecho no tiene consecuencias tan dramáticas, puesto que el error del análisis no es importante y por lo tanto la IMA no crece substancialmente. En cambio, en el caso del experimento MIBP el error del modelo obliga a un aumento de la IMA para compensar los bajos valores de dispersión. La región de los Andes por su parte presenta déficits de dispersión del campo preliminar en ambos experimentos. Si bien la utilización de las mismas condiciones de borde o de parametrizaciones físicas puede incrementar la sub-dispersión del ensamble en esta región, la dinámica de la misma presenta particularidades que son muy poco conocidas. Para poder comprender más profundamente este resultado desde el punto de vista conceptual sería necesario realizar experimentos con modelos más simples que busquen explicar cómo funciona la dinámica de la dispersión allí. Un aspecto posible a indagar sería medir la dimensión local del

sub-espacio inestable, utilizando por ejemplo la técnica de Patil y otros (2001) y que Miyoshi (2005) aplicó en su tesis doctoral. En nuestro caso, sería posible utilizar las perturbaciones del KF para aplicar esta metodología. Esto nos ayudaría a comprender si el número de miembros del ensamble es suficiente para describir las posibles direcciones de inestabilidad del flujo en esta porción del dominio.

En el caso de la temperatura entre superficie y 800 hPa (Figura 3.19 b y e) encontramos mayores diferencias entre los experimentos MPBP y MIBP. En el caso del experimento MPBP (Figura 3.19 b) sólo vemos déficits de dispersión en algunas zonas continentales, especialmente sobre los Andes, mientras que en el resto del dominio vemos que las diferencias entre la dispersión del campo preliminar y las correcciones se mantienen bastante cercanos entre sí. En este punto, también podríamos aventurar que el hecho de utilizar las mismas condiciones de borde inferior genera un déficit de dispersión, aunque de una magnitud inferior a la que generan las condiciones de borde lateral. Cuando se agregan los errores del modelo (Figura 3.19 f), los déficits se extienden a otras regiones, principalmente a los océanos cerca de los bordes.

Finalmente, la humedad específica (Figura 3.19 c y f) presenta un comportamiento bastante particular. Si nos detenemos a observar el caso del experimento MPBP (Figura 3.19c), notamos que esta variable presenta excesos de dispersión en regiones tropicales, especialmente hacia el oeste del dominio, junto con otras zonas con cierto déficit, dentro de un patrón un tanto ruidoso. Este hecho coincide con lo que discutimos anteriormente cuando analizamos el EHIV en el experimento MPBP (Figura 3.11 e). Este comportamiento particular es bastante difícil de comprender y requiere de un análisis más detallado, aunque vale la pena destacar que este es prácticamente el único caso en el que el ensamble muestra sobre-dispersión. Cuando introducimos el error en el modelo (Figura 3.19f), en la región ecuatorial y hacia el este del continente aparecen déficits de dispersión, debido a que el error en la banda de convección activa de la ZCIT aumenta. Asimismo, sobre el Océano Pacífico, al sudoeste de la región de sobre-dispersión mencionada anteriormente,

encontramos otra zona de déficit de dispersión. Este comportamiento está relacionado con un aumento del error en la región del anticiclón semipermanente del Pacífico.

Estos resultados muestran la necesidad de la técnica IMA de adoptar valores mayores de inflación, los cuales ayudan a explicar la mayor dispersión que muestra el análisis en el experimento de modelo imperfecto. Desde este punto de vista, la IMA realiza un buen trabajo en el sentido de que reacciona del modo correcto ante la aparición de una fuente de error en el sistema. Sin embargo, dado que a pesar del aumento de dispersión el análisis es mucho más sub-dispersivo que en el experimento sin error del modelo, la IMA no es suficiente para compensar completamente el efecto producido por el error del modelo. Otra conclusión que se puede desprender del análisis de la inflación y de las diferencias relativas de la ecuación (3.8) es que tal vez el valor óptimo de inflación depende de las variables, por lo que el algoritmo de IMA debiera quizás aplicarse separadamente para las diferentes variables del sistema. Sin embargo, tal implementación podría ser particularmente difícil de llevar a cabo, entre otros motivos porque podría alterar la relación física existente entre las diferentes variables dentro del análisis y llevar a desbalances en el campo inicial que podrían eventualmente provocar problemas de inestabilidad numérica al integrar el modelo para el siguiente ciclo de asimilación.

3.5 Experimentos idealizados: condiciones de modelo perfecto y bordes imperfectos (MPBI)

Este experimento contempla la situación en la cual las condiciones de borde lateral son imperfectas, mientras que el modelo es perfecto. Es un hecho ampliamente documentado en la literatura desde hace ya más de 2 décadas que en los sistemas de pronóstico regionales, la calidad del pronóstico puede verse degradada por la presencia de errores en las condiciones de borde lateral (Vukicevic y Errico, 1990, Vukicevic y Paegle, 1989, Warner y otros, 1989). Si bien en los experimentos anteriores las condiciones de borde no constituían

una fuente de error en el sistema, en los sistemas reales de asimilación-pronóstico regionales son uno de los grandes limitantes a la hora de mejorar la calidad, tanto del análisis como del pronóstico resultante. Esta es la principal motivación para estudiar el impacto de la imperfección en las condiciones de borde.

Para simular el efecto de los errores producidos por las condiciones de borde lateral utilizamos una base de datos diferente a la utilizada en la SV para forzar al modelo. En este caso utilizamos la información provista por los pronósticos operativos del modelo Global Forecasting System (GFS) a plazos de 9 horas con una resolución horizontal de 1° para forzar lateralmente al modelo, mientras que se utilizan las mismas parametrizaciones físicas de la SV. Asimismo, tanto el paso temporal de la integración como la inicialización de las variables condensadas son iguales al caso del experimento MPBP. Cabe aclarar que en este experimento todos los miembros comparten las mismas condiciones de borde. Por este motivo, estos experimentos se llamarán de Modelo Perfecto y Bordes Imperfectos (MPBI).

Para evaluar el impacto de la imperfección de las condiciones de borde comenzamos comparando el EETS para los experimentos MPBP y MPBI que se muestra en la Figura 3.20. Podemos apreciar en la marcha temporal cómo el EETS tiene una variabilidad temporal mucho más rápida en el experimento MPBI en comparación con el experimento MPBP (Figura 3.20 a). Esto es provocado por los errores en los sistemas sinópticos que ingresan al dominio desde los bordes. Geográficamente notamos que el mayor impacto de los errores en las condiciones de borde se produce principalmente en latitudes medias, mientras que en latitudes bajas no hay variaciones importantes entre ambos experimentos (Figura 3.20 c). Esto se puede explicar por el hecho de que en latitudes medias los sistemas de escala sinóptica dominan la variabilidad del flujo, los cuales tienen una fuerte variabilidad temporal y una gran amplitud, y en consecuencia la información que proveen las condiciones de borde influye más fácilmente en este sector del dominio. En los trópicos en cambio la amplitud de las perturbaciones es mucho menor, por lo que la

influencia de las condiciones de borde es más acotada. Al mismo tiempo en esta región domina la inestabilidad asociada a procesos de convección, la cual actúa en forma local, y que impacta más fácilmente en los casos donde el modelo es imperfecto. Si observamos la distribución del EETS en la vertical notamos que el aumento del error se da en toda la troposfera, con un máximo relativo en niveles cercanos al tope de la capa límite, y el máximo absoluto en la troposfera alta (Figura 3.20 d).

A continuación analizamos las contribuciones de las diferentes componentes del error en el EETS que se muestran en la Figura 3.21. Podemos apreciar aquí que el incremento del error observado en la mitad sur del dominio se debe principalmente a errores en la componente no sistemática, lo cual da indicio de que la fuente de los errores en este caso se debe a errores en la representación de los sistemas sinópticos que se propagan por esta porción del dominio. Las componentes sistemáticas en este caso no crecen demasiado en comparación con el experimento MPBP, aunque sí se mantienen los errores asociados al spin-up del modelo. Esto se puede observar al comparar la magnitud de aumento de las diferentes componentes del error de la Tabla 3.5 en las diferentes variables, excepto la precipitación. Esta tabla muestra en líneas generales que el aumento del error por introducir imperfecciones en las condiciones de borde lateral es del mismo orden de magnitud que en el caso del modelo imperfecto, más la componente del error que explica el aumento del mismo en este caso es la no sistemática. Sólo para las variables de masa (presión en superficie y altura geopotencial) se aprecia un aumento importante de la componente sistemática (especialmente la asociada al *sdbias*), asociado al hecho de que el error proveniente de los bordes impacta fuertemente en la profundidad de los sistemas baroclínicos de gran escala que ingresan al dominio. En el caso particular de la precipitación, no se aprecian grandes cambios, y en este sentido se comporta como una variable más independiente de las demás, tal como sucede en los experimentos anteriores.

Con todo, debemos tener en cuenta que los errores en las condiciones de borde también podrían contribuir a un incremento importante en las

componentes sistemáticas del error total. Esto ocurriría en el caso de que el modelo que provee las condiciones de borde tenga errores sistemáticos respecto del FNL. En este caso estamos utilizando las condiciones de borde provenientes de los pronósticos operativos del GFS, que es el modelo que se utiliza para generar el FNL. En consecuencia, el incremento que se observa en las componentes sistemáticas en este experimento es de menor intensidad de lo que cabría esperar si se utilizaran por ejemplo los pronósticos operativos del ECMWF como condición de borde para el experimento MPBI.

	Total	MNBIAS	SDBIAS	No SIST	Dispersión	Correlación
EETS	693,91	50,98	83,20	640,58	146,19	-0,283
U	207,27	117,06	98,05	188,06	75,48	-0,192
T	171,44	78,93	58,09	159,68	71,95	-0,210
PSFC	456,27	31,72	457,12	521,92	81,19	-0,210
Geopot.	380,15	102,87	253,13	364,51	87,01	-0,187
EHIV.	106,59	36,30	18,31	111,92	50,61	-0,162
PP	0,64	0,00	11,77	0,11	27,32	0,027

Tabla 3.5: Porcentaje de reducción de errores y de dispersión en el ensamble, junto con aumento de correlación entre RMSE y dispersión del experimento MPBI con respecto al experimento MPBP. Valores negativos indican reducción y positivos incremento en las diferentes variables.

En cuanto a la representación del error por parte del ensamble, observamos en la Figura 3.22 que debido a utilizar las mismas condiciones de borde, el patrón de dispersión en energía total seca guarda ciertos parecidos con la representación dada por el experimento MPBP. Sin embargo, si lo comparamos con los patrones espaciales de errores en el caso del experimento MPBI, notamos que dicha representación no es buena (Figura 3.22e). En efecto, en latitudes medias el patrón espacial de incertidumbre dado por el ensamble no guarda semejanza con el de error, a pesar de que la IMA incrementa los valores de dispersión, lo cual también se ve reflejado en la Tabla 3.5. En cambio, en latitudes tropicales, desde el paralelo de 10°S hacia el norte, tenemos una mayor correspondencia espacial entre los máximos de error y de dispersión. Por otro lado, cuando analizamos la correlación temporal entre el

error y la dispersión, notamos que en general en regiones tropicales y hacia el Sudeste de Sudamérica no hay una gran degradación con respecto al experimento MPBP (Figura 3.22 c y f). Sin embargo, hacia los bordes oeste, sur y norte del dominio nos encontramos con una seria degradación de la correlación, con valores que caen incluso por debajo de 0. Este hecho se ve claramente reflejado en las caídas de correlación de la Tabla 3.5 e indica que las regiones de influjo se ven seriamente afectadas por los errores de las condiciones de borde. Estos resultados nos dan indicio de que la sola utilización de la técnica IMA no es suficiente para compensar adecuadamente el incremento del error en el análisis causado por el error en las condiciones de borde.

A continuación analizamos el comportamiento de la IMA, cuyos valores se muestran en la Figura 3.23. Para este experimento, al igual que en el caso MIBP, se entrenó la IMA durante un período de 8 meses, partiendo del valor de inflación final del experimento MPBP. En esta figura podemos apreciar que entre 30°S y el borde sur del dominio los valores inflación se incrementan notablemente en comparación con el experimento MPBP, y que el patrón espacial adopta una forma de L, con los máximos extendiéndose a lo largo del borde sur del dominio. Asimismo, la región de los Andes también evidencia valores de inflación que son incluso más altos que en el experimento de modelo imperfecto. Por su parte, las regiones tropicales muestran pocos cambios con respecto al experimento de modelo imperfecto. En la vertical observamos un aumento sustancial de la inflación en todos los niveles (Figura 3.23 d). La marcha temporal de la IMA por su parte muestra un ligero aumento en el tiempo (Figura 3.23 a), lo cual es causado principalmente por un aumento sostenido hacia la esquina sudoeste. Esto es indicio de que los valores de IMA no terminan de converger en dicha región. Gran parte de la distribución espacial de la IMA se puede explicar a partir de la Figura 3.24 que muestra la ecuación (3.8) para los experimentos MPBP y MPBI. En particular, si analizamos el viento zonal (Figura 3.24 d) notamos un claro déficit de dispersión sobre el borde oeste y sur, atribuible al hecho de utilizar las mismas condiciones de borde, siendo que los mismos ahora constituyen una fuente de

error. Dado que estas son regiones por donde ingresa el flujo al dominio, cabe esperar que los valores de dispersión sean relativamente bajos, como se comprueba en la Figura 3.22e. Hacia la esquina sudeste del dominio en cambio no observamos grandes déficits de dispersión, lo cual puede explicarse a partir del hecho de que en dicha región el flujo suele salir del dominio, por lo que la IMA ha incrementado su valor de dispersión. Desde este punto de vista, podríamos afirmar que la técnica IMA incrementa adecuadamente la dispersión del ensamble en este sector del dominio. También es interesante notar que en este caso la región de los Andes sigue presentando falta de dispersión aunque en una menor magnitud que en el caso del experimento MPBP (tanto en viento como en temperatura) (Figura 3.24 a y d, y 3.24 b y e). En este caso posiblemente el mayor valor de inflación ayude a que el déficit de dispersión sea menor que en el caso MPBP. Por su parte, la humedad específica muestra un patrón espacial similar entre ambos experimentos (Figura 3.24 c y f). La diferencia que más salta a la vista son los mayores excesos de dispersión sobre la costa oeste de Sudamérica en la franja tropical en el experimento MPBI (Figura 3.24 f).

3.6 Experimentos idealizados: condiciones de modelo y bordes imperfectos (MIBI)

Este experimento representa condiciones más realistas en donde tanto el modelo como las condiciones de borde lateral tienen errores. Por tal motivo, estos experimentos se llamarán de Modelo Imperfecto y Bordes Imperfectos. Con todo, este experimento no deja de tener sus idealizaciones, ya que por ejemplo las condiciones de borde inferior continúan siendo perfectas, y además no estamos considerando los errores debidos a la discretización horizontal del modelo.

La representación de los errores tanto del modelo como de las condiciones de borde es similar a los casos de los experimentos MIBP y MPBI, respectivamente. Esto significa que para generar los errores en el modelo,

adoptamos la misma configuración de parametrizaciones y discretización temporal, junto con las condiciones iniciales de condensado igual a cero en el análisis, del experimento de modelo imperfecto. Mientras que para simular los efectos de los errores en las condiciones de borde lateral, utilizamos las mismas condiciones de borde provistas por el modelo GFS, tal como se realiza en el experimento de bordes imperfectos. Al igual que en dichos experimentos, todos los miembros del ensamble comparten la misma configuración del modelo y las mismas condiciones de borde.

Como hemos hecho previamente, comenzamos analizando el impacto simultáneo de las dos fuentes de error mediante el EETS que se muestra en la Figura 3.25. Los resultados muestran que el patrón espacial de los errores aparenta reproducir un patrón que se parece bastante a una suma entre el error del experimento MIBP y el del experimento MPBI, dado que los máximos de errores se observan en la zona de convección activa de la ZCIT, asociados a la imperfección del modelo, y en latitudes medias cerca de los bordes debido a la imperfección de las condiciones de borde lateral. A esto también se le agrega una pequeña región que corresponde a los Andes, que también se observa en el experimento MIBP (Figura 3.25 c). Este patrón de tipo suma de errores también se puede observar en el perfil vertical (Figura 3.25 d). En efecto, en este perfil observamos un máximo de niveles bajos que es el resultado del error del modelo, y que también se observaba en el experimento MIBP (Figura 3.13 d), sumado a los errores de las condiciones de borde que son relativamente similares en todos los niveles de la troposfera (Figura 3.20 d). La marcha temporal (Figura 3.25 a) por su parte muestra una característica similar a la mostrada en el caso del experimento MIBP (Figura 3.13 a), y es el hecho de que el error es menor en la segunda mitad del experimento en comparación con la primera mitad. Este comportamiento también se observa, aunque en menor medida en el experimento MPBI (Figura 3.20 a). Esto, como ya mencionamos anteriormente, podría estar relacionado con el aumento progresivo de la IMA hacia valores más óptimos en la segunda mitad del experimento.

Analizando por componentes de EETS (Figura 3.26), notamos nuevamente que el error reproduce aproximadamente la suma de los errores de los casos individuales de modelo imperfecto y bordes imperfectos. Esto lo notamos por ejemplo en la componente sistemática del *mnbias* que esencialmente reproduce la misma componente del caso de modelo imperfecto (Figura 3.14 f). Por su parte, la componente no sistemática es la dominante, en donde aparecen representados los errores asociados a la imperfección de los bordes laterales en latitudes medias (Figura 3.21 h), y los errores debidos a la imperfección del modelo en latitudes bajas (Figura 3.14 h), asociados principalmente a errores en la representación de los procesos de convectivos. Observando la dispersión del ensamble (Figura 3.27), notamos que en magnitud la representación de la incertidumbre en las regiones tropicales se acerca bastante al error del sistema, más en latitudes medias la representación del error es bastante pobre, al igual que en el caso MPBI (Figuras 3.22 e y 3.27 e). En consecuencia no es de extrañar que la correlación temporal entre error y dispersión muestre serios problemas cerca de los bordes oeste y sur. Asimismo, también se reproducen características del caso MIBP en el campo de correlaciones temporales (Figura 3.16 f), como por ejemplo en el nordeste de Brasil o en la costa del Pacífico entre 10 y 20°S, en donde aparece una fuerte degradación en comparación con el caso MPBP (Figura 3.27 f).

Otra forma de corroborar el hecho de que los errores sistemáticos provienen de los errores del modelo es observar las componentes de los errores por variables individuales para los experimentos MIBP y MIBI, que se muestran en la Figura 3.28. En esta figura notamos en primer lugar que las componentes sistemáticas entre el experimento de modelo imperfecto y el de modelo y bordes imperfectos son muy parecidas. Sólo en el geopotencial se aprecian diferencias mayores entre ambos experimentos. Del análisis de esta figura podemos concluir que agregar la imperfección de los bordes genera un aumento en la componente no sistemática. En consecuencia, podemos deducir que en este caso las dos fuentes de error se comportan de manera bastante independiente entre sí, y a interactuar entre ellas de forma aditiva. También podemos apreciar en la Tabla 3.6 cómo impactan ambas fuentes de

incertidumbre en el sistema en el aumento del error total. Vemos por ejemplo que el EETS aumenta unas 12 veces, mientras que en variables individuales como la presión o la temperatura, el aumento del error es de entre unas 2 y 5 veces en comparación con el experimento MPBP. En este caso notamos que el aumento del error total está explicado por el aumento tanto de las componentes sistemáticas (especialmente del *mnbias*) como no sistemáticas del error. Este comportamiento se observa en todas las variables de la tabla, a excepción de la precipitación acumulada, que apenas experimenta cambios en la magnitud del error, aunque sí evidencia un aumento de la dispersión.

	Total	MNBIAS	SDBIAS	No SIST	Dispersión	Correlación
EETS	1217,10	2014,40	843,46	1056,00	375,08	-0,333
U	296,87	401,08	277,68	267,35	146,67	-0,202
T	285,76	544,80	252,04	245,30	142,58	-0,271
PSFC	510,12	332,72	609,08	538,43	167,33	-0,189
Geopot	454,25	319,61	407,82	416,05	177,83	-0,226
EHIV.	230,33	279,03	60,53	215,70	128,22	-0,236
PP	13,24	-0,06	35,02	16,80	104,64	-0,005

Tabla 3.6: Porcentaje de reducción de errores y de dispersión en el ensamble, junto con aumento de correlación entre RMSE y dispersión del experimento MIBI con respecto al experimento MPBP. Valores negativos indican reducción y positivos incremento en las diferentes variables.

Dados los errores de este experimento que son mayores que en los casos anteriores y dado que la dispersión del ensamble en latitudes medias especialmente es claramente menor al error, el parámetro de IMA resultante muestra valores por encima del 100 % en un vasto sector del dominio (Figura 3.29 c). En este caso la IMA fue entrenada durante 2 períodos completos (aproximadamente 8 meses) partiendo del último valor estimado del experimento MPBI. Este hecho, sumado al aumento del error en todo el sistema, pone en evidencia que por más que la IMA adopte valores cada vez más grandes, no es capaz por sí mismo de compensar la falta de dispersión del ensamble provocada por la presencia de las fuentes de error del sistema, y que por lo tanto es necesario adoptar estrategias adicionales que mitiguen este

efecto. Por un lado, el hecho de que los errores sistemáticos persistan en el sistema con valores muy similares a los del experimento MIBP muestra nuevamente que este tipo de errores requieren de algún tratamiento adicional como la implementación de técnicas de reducción de bias por ejemplo. Si observamos el campo horizontal de la IMA, notamos un patrón de L similar al experimento MPBI, con valores más elevados y con el máximo de inflación desplazado hacia el sur (Figura 3.29 c), mientras que sobre los Andes persiste un eje de inflaciones más altas. En el perfil vertical observamos un claro aumento en toda la vertical, rasgo en común con el experimento MPBI, y también que el máximo crecimiento se da en niveles bajos, lo cual también sucede en el experimento MIBP (Figura 3.29 d). Al igual que en el caso del experimento MPBI, el aumento de la inflación ayuda a mitigar el déficit de dispersión del campo preliminar hacia el borde este en latitudes medias, pero no hacia el borde oeste. Esto se puede corroborar en la Figura 3.30 para el caso de viento zonal. Con todo, podemos ver que tanto para el viento zonal en niveles medios (Figura 3.30 d) como para la temperatura en niveles bajos (Figura 3.30 e), el déficit de dispersión en el experimento MIBI es menor en comparación con el experimento MIBP. Dado que ninguna de las fuentes de error está siendo representada en el diseño del ensamble en estos experimentos, podemos atribuir esta diferencia al mayor valor de IMA en este experimento. En el caso de la humedad específica (Figura 3.30 f) encontramos rasgos muy similares al caso del experimento MIBP. Esto es, déficits de dispersión en la región de convección activa de la ZCIT, y en la región del Anticiclón semipermanente del Pacífico. También se observan déficits en la región del Atlántico en latitudes medias. Al mismo tiempo, se observa el rango distintivo de exceso de dispersión sobre los Andes y hacia el borde oeste en latitudes bajas.

Capítulo 4: Experimentos idealizados – implementación de técnicas para la representación de las fuentes de error en el sistema

4.1 Introducción

En el Capítulo 3 se estudiaron los efectos producidos sobre la calidad del análisis por la presencia de diferentes fuentes de error en el sistema de asimilación. En particular, se estudió el caso de errores en el modelo de pronóstico y de errores en las condiciones de borde lateral. En ambos casos se encontró que el impacto de dichas fuentes de error sobre la calidad de un análisis regional es sumamente importante y que por lo tanto es necesario implementar alguna técnica adicional, aparte de la IMA, para representar dichas fuentes de error en el ensamble. Es por este motivo que en el presente capítulo se estudia el impacto de implementar otras técnicas complementarias con el objetivo de representar adecuadamente la incertidumbre asociada a las fuentes de error del sistema, y de esta manera lograr un análisis más cercano a la SV. A fines de representar la incertidumbre asociada al error del modelo, se empleará la técnica de ensamble físico. Por su parte, el error en las condiciones de borde será representado mediante la técnica de perturbación de las condiciones de borde lateral.

Los resultados de este capítulo se presentan en 3 partes. En la primera se considera la situación en la que solamente el modelo es imperfecto. En la segunda se estudia el caso en el que la fuente de error la constituye únicamente las condiciones de borde lateral. Finalmente, en el tercer y último caso analizamos la situación en donde la imperfección está dada tanto en la configuración del modelo como en las condiciones de borde.

4.2 Experimentos de Modelo Imperfecto

En estos experimentos retomamos la situación del capítulo anterior, en donde sólo consideramos las imperfecciones en la representación de los procesos de

escala sub-reticular, junto con errores asociados a la discretización temporal y a la condición inicial sin fase condensada. En dicho experimento se consideraba que todos los miembros del ensamble compartían las mismas parametrizaciones físicas, de forma tal que la imperfección del modelo solo era tomada en cuenta a través de la IMA estimada. Dicho experimento, que denominamos MIBP, constituye ahora nuestro experimento de base.

Existen en la práctica diversas técnicas para representar la incertidumbre dada por la imperfección en la representación de los procesos de menor escala. Dichas técnicas son implementadas tanto en los pronósticos operativos por ensamble a corto plazo como en las predicciones de escenarios futuros de cambio climático. Entre algunas de las técnicas más utilizadas podemos citar los modelos dinámicos estocásticos (Palmer, 2001), las perturbaciones en las tendencias físicas (Buizza y otros, 1999), el empleo de múltiples parametrizaciones (Murphy y otros, 2004, Meng y Zhang, 2008 a y b), las variaciones en diferentes parámetros dentro de las parametrizaciones físicas (Stainforth, 2005) y las perturbaciones estocásticas controladas por la dinámica como en el Energy Backscatter (Shutts y otros 2005) y la Stochastic Total Tendency Parameterization (STTP) (Hou y otros, 2008) utilizada en el NCEP. Otras estrategias empleadas incluyen el uso de diferentes modelos numéricos (Houtekamer y otros, 1996, Krishnamurti y otros 2000; Hagedorn y otros 2005; Peña y van den Dool, 2008, Kirtman y otros, 2014, Otsuka y Miyoshi, 2015).

En nuestro caso, emplearemos diferentes parametrizaciones físicas dentro del ensamble. Debido a que esta implementación es sencilla de llevar a cabo, la misma fue escogida entre todas las posibilidades para este experimento. Dado que al utilizar diversas parametrizaciones lo que esencialmente estamos construyendo es un ensamble físico, este experimento se denominará de Modelo Imperfecto y Bordes Perfectos con Ensamble Físico (MIBP EF). Esta técnica de ensamble físico fue implementada en diversos trabajos de asimilación de datos, entre los cuales podemos citar los de Meng y Zhang (2008 a y b) y el de Dillon y otros (2016). En dichos trabajos se mostraron las

claras ventajas de utilizar un ensamble físico para la mejora de la representación del error dentro del ensamble y en consecuencia para un mejor funcionamiento de un EnKF.

Dado que en el diseño del experimento MIBP del Capítulo 3, el error del modelo principalmente está dado en el tratamiento de la convección, la microfísica y la capa límite, utilizamos 2 esquemas diferentes para cada uno de los procesos para generar el ensamble físico. En este caso no tenemos en cuenta las fuentes de error dadas por la discretización temporal ni las condiciones iniciales sin condensado. De esta manera tenemos 8 combinaciones diferentes de configuraciones del modelo en el ensamble físico de 40 miembros. Para realizar la selección de parametrizaciones que se utilizan en el ensamble físico, se realiza en primer lugar una serie de experimentos de asimilación de 3 semanas probando diferentes combinaciones de parametrizaciones físicas. En cada uno de estos experimentos se utilizan siempre 8 combinaciones de parametrizaciones diferentes dentro del ensamble de 40 miembros, de forma tal de representar las condiciones de los experimentos a llevar a cabo. Asimismo, cada una de las pruebas consta de dos experimentos paralelos. En el primero de ellos no se asimilan las observaciones y en el segundo las mismas son asimiladas. Este procedimiento está motivado por varias razones. La primera de ellas radica en que en el experimento sin asimilación de observaciones, cada una de las combinaciones es independiente de las demás. Es decir, que los errores de cada una de ellas no impactan en el resto de las configuraciones. Esto no ocurre en el caso del experimento con asimilación de observaciones, ya que en el proceso de asimilación los errores de cada uno de los miembros del ensamble influyen en el resto de los miembros, de forma tal que los errores propios de cada uno de ellos son combinados. Desde esta perspectiva, para obtener un ensamble físico en el que cada configuración de parametrizaciones mantenga su identidad, la asimilación debiera realizarse por separado para cada grupo de miembros que tengan las mismas parametrizaciones. Sin embargo, dado nuestro diseño experimental en el que las observaciones se asimilan para todos los miembros al mismo tiempo, es necesario realizar el experimento adicional asimilando las

observaciones. De esta manera podemos estar seguros de elegir combinaciones de parametrizaciones cuyos errores sean similares y no construir un ensamble en donde haya combinaciones que sean mucho mejores que otras. Para corroborar esto, se calcula el EETS medio con respecto a la SV de cada una de las combinaciones en cada experimento.

De los diferentes experimentos se seleccionan las combinaciones de parametrizaciones mostradas en la Tabla 4.1. Las parametrizaciones elegidas son las siguientes: para la microfísica ETA-Ferrier y Purdue-Lin (Chen y Sun, 2002), para la convección Betts-Miller-Janjic (BMJ, Janjic, 1994) y Grell-Devenyi (Grell y Devenyi, 2002), y para la capa límite Mellor-Yamada-Janjic (MYJ, Janjic, 2002) y Medium Range Forecast (MRF, Hong y Pan, 1996).

Configuración	Microfísica	Convección	Capa Límite	EETS (no-obs)	EETS (obs)
1	Purdue-Lin	BMJ	MYJ	7,90	3,41
2	Purdue-Lin	Grell-Devenyi	MYJ	6,35	3,23
3	Purdue-Lin	BMJ	MRF	7,87	3,17
4	Purdue-Lin	Grell-Devenyi	MRF	7,18	2,88
5	ETA-Ferrier	BMJ	MYJ	8,57	3,36
6	ETA-Ferrier	Grell-Devenyi	MYJ	7,23	3,12
7	ETA-Ferrier	BMJ	MRF	8,59	3,21
8	ETA-Ferrier	Grell-Devenyi	MRF	8,38	2,91

Tabla 4.1: Configuraciones de parametrizaciones utilizadas dentro del ensamble de 40 miembros junto con el EETS promedio en los experimentos con y sin asimilación de datos. En verde se muestra la combinación utilizada para el experimento MIBP.

Podemos ver de esta tabla que las diferentes configuraciones de parametrizaciones presentan diferentes niveles de error. Por ejemplo, para el caso de la microfísica notamos que la parametrización de Purdue-Lin obtiene menores errores que la ETA-Ferrier en el caso de no asimilar observaciones. Sin embargo, el hecho que más se destaca de la tabla es que la mejor combinación del experimento sin asimilación de observaciones (la combinación 2) no es la mejor en el caso de que se asimilen observaciones. Es decir, que el orden de las combinaciones en términos de errores se modifica dependiendo

de si se asimilaran o no observaciones. Esto está explicado, como mencionamos anteriormente, por el hecho de que al asimilar las observaciones para todos los miembros a la vez, los errores de cada miembro influyen sobre los demás, haciendo que pueda cambiar el error de cada uno de ellos y por ende se modifique el orden.

Esto genera un dilema a la hora de escoger la combinación de parametrizaciones que se utilizan para generar el experimento MIBP del Capítulo 3. Para generar dicho experimento lo mejor es elegir aquella configuración cuyo error sea cercano al promedio de los errores de las diferentes configuraciones. De esta forma se evita favorecer por un lado al experimento sin ensamble físico si se elige una configuración con errores pequeños, y por el otro favorecer al experimento con ensamble físico si se escoge una configuración con errores muy grandes. Es de destacar que en este último caso no estaríamos seguros, en caso de encontrar una mejora en el experimento MIBP-EF con respecto al MIBP, de que dicha mejora se deba a la forma en cómo se construye el ensamble y no a la mejor calidad individual de las diferentes configuraciones de parametrizaciones que conforman el ensamble. Sin embargo, dado que el orden de las configuraciones se modifica según se asimilaran o no observaciones, no resulta sencillo elegir la combinación adecuada. En este caso basamos nuestra elección en el experimento con asimilación de datos, por lo que tomamos en cuenta los valores de la columna de la extrema derecha de la Tabla 4.1. De los valores de EETS de dicha columna, tomamos la configuración 7 dado que dicha configuración tiene valores de EETS cercanos al promedio de todo el conjunto de configuraciones. Cabe destacar no obstante que si nos basamos en el experimento sin asimilación de observaciones, dicha configuración resulta ser la de peor performance en términos de EETS.

Al igual que en el Capítulo 3, analizamos el impacto de implementar un ensamble físico a partir del EETS. En la Figura 4.1 se muestra el EETS para los experimentos MIBP y MIBP EF. En esta figura notamos que el hecho de tener en cuenta el error del modelo en el caso del experimento con ensamble físico,

resulta en una reducción del error, lo cual se evidencia tanto en el promedio total (Figura 4.1 a), como en el promedio vertical (Figuras 4.1 b y c) y horizontal (Figura 4.1 d). A nivel geográfico se observa que las zonas de mayor error son las que experimentan la mayor reducción del mismo. Esto se nota especialmente en la región del ZCIT y sobre el Atlántico Sur. Si observamos el perfil vertical (Figura 4.1 d) notamos que la reducción del error es más notable en niveles bajos, es decir en los niveles correspondientes a la capa límite planetaria. Un detalle interesante que revela la marcha temporal del error (Figura 4.1 a) es que en el caso del experimento MIBP-EF no se observa una tendencia hacia el decrecimiento de los errores tan clara como en el caso del experimento MIBP. Este hecho coincide con la menor tendencia que presenta la IMA en este caso, cuyo comportamiento analizaremos más adelante.

El análisis de las diferentes componentes del EETS para ambos experimentos de modelo imperfecto (Figura 4.2) muestra una importante reducción en la componente del *mnbias* en la región de la ZCIT en el experimento con ensamble físico (Figura 4.2 b y f). En otras regiones del dominio, como en latitudes medias, dicha componente se reduce de forma notable. Por su parte, la componente del *sdbias*, no tiene mayor injerencia en el error total (Figura 4.2 c y g). De esta manera, la componente no sistemática queda como la más importante en todo el dominio, aunque la misma también se reduce en el experimento con ensamble físico (Figura 4.2 d y h). Cuando evaluamos la representación del error mediante la dispersión del ensamble (Figura 4.3), notamos que en el experimento con ensamble físico la magnitud de la dispersión disminuye en bajas latitudes, posiblemente debido a una disminución de la IMA en esta región, mientras que en latitudes medias, especialmente cerca de los bordes, se observa un aumento (Figura 4.3 b y e). Este cambio en la dispersión del ensamble resulta en una mejor correspondencia espacial con el error en el caso del ensamble físico, especialmente en latitudes bajas. Por otro lado, también se observa una mejora en la correlación entre el RMSE y la dispersión del ensamble, especialmente en las regiones donde el experimento MIBP muestra correlaciones cercanas a 0 (Figura 4.3 c y f). Esto es en las zonas más áridas

del dominio, como el nordeste de Brasil y el Pacífico subtropical en la región del anticiclón semipermanente. Es interesante notar que el patrón espacial de la correlación temporal para el experimento MIBP-EF muestra sus máximos en zonas de mayor inestabilidad, es decir sobre la región del ZCIT (asociado a convección), el Sudeste de Sudamérica hacia el Atlántico y sobre latitudes medias desde el paralelo de 30°S hacia el sur (en donde se manifiesta la inestabilidad baroclínica y esporádicamente la convectiva). Esto sugiere que la implementación de ensamble físico mejora la representación de los procesos asociados a la generación de precipitación, dado que la misma es consecuencia de la inestabilidad del flujo. Por otro lado, en las zonas más áridas tenemos una menor correlación temporal.

La Tabla 4.2 que muestra la reducción del error del experimento MIBP EF con respecto al MIBP, evidencia estos cambios positivos tanto para el EETS, como para diferentes variables individuales. La mayor mejora se observa en las variables de viento y temperatura, en donde tanto las componentes sistemáticas como no sistemáticas presentan una disminución importante. El geopotencial y la humedad por su parte no responden tan bien a la técnica de ensamble físico, en donde sólo se observan mejoras sustanciales en la componente no sistemática del error, mientras que la componente sistemática del *mnbias* presenta un aumento de su magnitud. Este resultado es sumamente interesante y a primera vista anti-intuitivo, ya que dado que estamos combinando diferentes parametrizaciones dentro del ensamble, cada una de las cuales tiene diferentes bias respecto de la SV, es de esperar que el error sistemático disminuya al promediar todos los miembros del ensamble por una simple compensación de errores sistemáticos. Esto podría explicar por ejemplo la reducción del *mnbias* en EETS, viento y temperatura. Pero por otro lado, también puede ocurrir que el ensamble físico introduzca una covarianza sistemática entre diferentes variables. Por ejemplo, podría ocurrir que un aumento de temperatura en capa límite en los miembros que utilicen la parametrización YSU esté acompañado por una disminución de la humedad específica en la capa límite para los miembros que utilizan la parametrización MYJ. De esta manera, es posible que algunas variables vean reducido su error

sistemático a partir de otras variables a través de un aumento de la correlación entre dichas variables. Sin embargo, cuando esto no ocurre entre diferentes variables, puede que no se registre reducción alguna en las componentes del error. Este es un punto que merece ser explorado en mayor profundidad para poder determinar el origen de la reducción del error sistemático. De todos modos, para poder cumplir con las hipótesis del Filtro de Kalman es necesario en primer lugar remover las componentes sistemáticas del error antes de proceder a asimilar las observaciones. En ese sentido, dado que en nuestro ensamble estamos utilizando diferentes configuraciones de parametrizaciones, lo recomendable es remover el bias de las diferentes configuraciones por separado y luego realizar la asimilación.

Cuando analizamos el comportamiento de la dispersión del ensamble, notamos un aumento en casi todas las variables, excepto las vinculadas con la humedad. De todos modos, el aumento de la misma es disímil entre las diferentes variables, ya que la que mayor aumento evidencia es la temperatura, seguida del geopotencial. Sin embargo, como veremos más adelante, este aumento está más explicado por utilizar un ensamble físico, ya que la IMA es más pequeña con respecto al experimento MIBP. Con todo, lo que es más importante de esta tabla es que la correlación temporal entre el error y la dispersión del ensamble aumenta para todas las variables.

	Total	MNBIAS	SDBIAS	No-SIST	Dispersión	Correlación
EETS	-38,00	-54,31	-42,09	-33,68	5,89	0,184
U	-17,89	-29,09	-22,48	-16,47	0,75	0,056
T	-19,28	-31,67	-32,60	-15,07	16,58	0,068
PSFC	-0,21	16,08	-0,24	-14,47	1,54	0,059
Geopot.	-2,68	19,74	-29,28	-15,16	9,89	0,053
EHIV	-18,12	19,98	-9,68	-17,12	-0,09	0,085
PP	-8,28	0,02	6,28	-11,53	-6,55	0,050

Tabla 4.2: Porcentaje de reducción de errores y de dispersión en el ensamble, junto con aumento de correlación entre RMSE y dispersión del experimento MIBP-EF con respecto al experimento MIBP. Valores negativos indican reducción y positivos incremento en las diferentes variables.

Para conocer en mayor detalle cómo se comporta el error en la vertical, en la Figura 4.4 se muestran los perfiles verticales de las diferentes componentes del error para las variables de geopotencial, temperatura y viento. Vemos aquí que, tal como indica la Tabla 4.1, no se aprecia una gran mejora del error en el experimento con ensamble físico en el geopotencial (Figura 4.4 a), y que incluso se aprecia un aumento del error sistemático en la mayor parte de la columna atmosférica (Figura 4.4 b). En temperatura y en viento zonal en cambio la mejora es más evidente (Figura 4.4 e, 4.4 i), y en particular notamos la reducción del error sistemático en temperatura que explica la mayor mejora en niveles bajos del EETS visto en la Figura 4.1 d (Figura 4.4 f), junto con la mejora en la componente no sistemática (Figura 4.4 h). Para el viento zonal también notamos dicha reducción en el *mnbias* en los niveles altos de la troposfera (Figura 4.4 j), junto con una clara mejora en la componente no sistemática (Figura 4.4 l). Por su parte, la componente del *sdbias* es poco importante en las tres variables (Figura 4.4 c, g, k), lo cual explica su escaso impacto en el EETS (Figura 4.2 c y g).

En el caso de la precipitación, vemos que la Tabla 4.2 refleja una mejora cuya magnitud es comparable con la de las demás variables. Observando más detenidamente en las diferentes componentes, notamos que la componente que explica dicha reducción del error es la no sistemática. En la Figura 4.5 se muestran los errores en esta variable para los dos experimentos MIBP. Encontramos precisamente una fuerte reducción de la componente no sistemática en la región de la ZCIT, especialmente en zonas marítimas (Figura 4.5 d y h). Asimismo, también se observan reducciones de la componente del *sdbias* en dicha región (Figura 4.5 c y g). Sin embargo, debido a otros errores del modelo, especialmente los relacionados con el spin-up del mismo, la componente del *mnbias* no experimenta cambios de importancia. Si observamos la dispersión en esta variable (Figura 4.6), encontramos una reducción importante en la región de la ZCIT (Figura 4.6 e). Dado que dicha disminución de la dispersión va acompañada por una reducción del error, podemos ver que en esta región de convección activa la utilización del ensamble físico es sumamente valiosa. Cuando se analizan las correlaciones

temporales entre error y dispersión, por lo general encontramos pocos cambios en esta región (Figura 4.6 f). Con todo, esta variable tiene sus particularidades, dado que es más esperable tener correlaciones altas entre error y dispersión en comparación con otras variables. Esto se da porque en las situaciones donde la precipitación es abundante, es esperable tener mayores errores y que al mismo tiempo el ensamble tenga mayor dispersión. En cambio, en latitudes medias, hacia la esquina sudoeste del dominio, encontramos un aumento de la correlación. Este comportamiento de la precipitación es digno de mencionarse ya que como mencionamos anteriormente, es la única variable que no se asimila en estos experimentos. Sin embargo, gracias a la mejora en la representación de otras variables, la precipitación experimenta una mejora, a pesar de que no se puede librar de los errores sistemáticos. Este es un ejemplo de cómo la mejora en diferentes variables puede repercutir en una mejora en otra, sin hacer intento alguno por acerca a esta variable a las observaciones.

Estos resultados muestran que la implementación de la técnica de ensamble físico es exitosa en reproducir al menos parcialmente la incertidumbre asociada a la fuente de error presente en el sistema y complementar el algoritmo IMA en la optimización de la dispersión del análisis. Cabe destacar que la IMA requirió en este caso de un entrenamiento de 4 meses a partir del valor final de IMA del experimento MIBP. La Figura 4.7 que muestra los valores medios de inflación para los experimentos MIBP y MIBP-EF nos permite apreciar la ventaja de aplicar la técnica de ensamble físico. En dicha figura podemos ver que los valores de inflación en general son menores para el experimento con ensamble físico que en el experimento sin ensamble físico. Geográficamente la mayor reducción se da en latitudes bajas (Figura 4.7 c), en donde encontramos grandes mejoras por ejemplo en variables como la precipitación y la energía total seca, junto con una reducción de la dispersión. En el resto del dominio también se observa una disminución de la IMA, aunque en menor medida que en los trópicos. En la vertical podemos reconocer que la mayor reducción de la IMA se da en los niveles bajos (Figura 4.7 d). Asimismo, notamos que la tendencia de la IMA a incrementarse en el tiempo es menos

marcada en el experimento MIBP-EF en comparación con el MIBP (Figura 4.7 a). Esto da indicio de que la IMA está más cerca de converger en el caso del ensamble físico en comparación con el experimento sin ensamble físico. Este hecho se ve reforzado si se tiene en cuenta que se requirió un período de 4 meses de entrenamiento de la IMA, partiendo de los valores finales del experimento MPBP, a diferencia del caso sin ensamble físico en el que se utilizaron 8 meses de entrenamiento.

Podemos reconocer cómo el ensamble físico aumenta claramente la dispersión del ensamble de pronósticos a partir de la Figura 4.8, que muestra el valor de la ecuación (3.8). Aquí podemos apreciar claramente cómo se reduce notablemente el déficit de dispersión en el experimento MIBP EF con respecto al experimento MIBP. Sólo en la región de los Andes y en latitudes medias cerca del borde sur del dominio en el viento zonal (Figura 4.8 d) se aprecia que aún persiste cierta falta de dispersión, al igual que en la temperatura en niveles bajos sobre el continente en la franja de 10°S (Figura 4.8 e). Esto es consistente con lo visto en las Figura 4.3 d y 4.3 e, en donde se observa un mayor acuerdo entre el error y la dispersión en energía. En la humedad específica en particular se observa una sobre-dispersión en la mayor parte del dominio, aunque el patrón espacial es un tanto ruidoso en algunos sectores (Figura 4.8 f). Estos resultados muestran que la técnica de ensamble físico ayuda en el tratamiento del error del modelo. En particular, la implementación de esta técnica junto con la IMA es más eficiente en representar la incertidumbre asociada al error del modelo que utilizar solamente la técnica IMA para ello. No obstante las mejoras observadas (tanto en la reducción del error como en la representación del mismo), aun se observa que el ensamble es sub-dispersivo. Esto es indicativo de que la implementación del ensamble físico en conjunto con la técnica IMA no resuelve totalmente el problema de la representación del error cuando el modelo tiene imperfecciones.

4.3 Experimentos de Bordes Imperfectos

En esta sección estudiamos los efectos de implementar una técnica para representar la incertidumbre asociada a los errores en las condiciones de borde lateral. En el Capítulo 3 encontramos que cuando se introducen errores en las condiciones de borde, la calidad de un análisis regional puede verse seriamente afectada, especialmente en regiones donde flujo atmosférico es dominado por sistemas de gran escala que se propagan desde regiones remotas. También encontramos que bajo tales condiciones, el utilizar las mismas condiciones de borde para todos los miembros del ensamble obliga al algoritmo de inflación a incrementar la dispersión del ensamble, sin por ello obtener una buena representación del error. Esto ocurre esencialmente porque al utilizar las mismas condiciones de borde para todos los miembros, estamos ignorando las inestabilidades del flujo de mayor escala que pueden darse fuera del dominio y que sólo podemos representar a partir de las condiciones de borde lateral. Respecto a este punto, Nutter y otros (2004 a y b) mostraron que en pronósticos por ensamble regionales es necesario perturbar las condiciones de borde para evitar que la dispersión del ensamble decaiga demasiado a medida que aumenta el plazo de pronóstico. Este resultado pone de manifiesto la necesidad de incluir la incertidumbre de las condiciones de borde.

El trabajo de Torn y otros (2006) constituye quizás uno de los trabajos más importantes en lo que respecta al tratamiento de los errores en las condiciones de borde lateral en un ensamble regional, ya sea a fines de generar un análisis o de generar un pronóstico por ensamble. En este trabajo los autores proponen una serie de métodos para generar perturbaciones en las condiciones de borde lateral de forma tal de poder representar más adecuadamente la magnitud de los errores provistos por las mismas, los cuales revisaremos a continuación.

El método más natural que se puede proponer es el de utilizar las condiciones de borde provistas por un ensamble global, asignando para cada uno de los miembros del ensamble regional las condiciones de borde proveniente del respectivo miembro del ensamble global. A primera vista implementar esta técnica es más que ventajosa ya que los errores que se introducen desde los

bordes en el ensamble regional provienen de una estimación cuyos errores varían con el estado del flujo y por lo tanto reflejan las incertidumbres presentes fuera del dominio regional. Vié y otros (2011), por ejemplo, estudiaron el impacto de las condiciones de borde en modelos de escala convectiva (~ 2.5 km de resolución), utilizando esta metodología para representar los errores en las condiciones de borde en el ensamble regional. Sin embargo, esta metodología tiene algunas desventajas, entre las cuales la principal es de índole práctica. En centros de pronóstico regional como puede ser el SMN por ejemplo, es difícil tener disponible en tiempo real la información necesaria de un ensamble global para inicializar el ensamble regional. Un ejemplo práctico de este tipo de situación se puede encontrar en el trabajo de Saito y otros (2011). En dicho estudio los autores utilizan información de un ensamble global para perturbar los bordes de su sistema regional, pero debido a que no disponen de la información del ensamble global en tiempo real, utilizan el ensamble de una inicialización previa, lo cual requiere luego aplicar una metodología adicional para ajustar temporalmente la amplitud de las perturbaciones.

Otra metodología posible es la de obtener las perturbaciones tomando al azar series temporales de una climatología, como puede ser un reanálisis por ejemplo. En este caso para cada miembro se genera una serie temporal de estados del sistema atmosférico, a los cuales se les resta la serie media del ensamble y luego se multiplica la serie de anomalías de cada miembro por un escalar. Este método tiene la ventaja de no tener mayores costos computacionales, a la vez que provee una estimación de errores climatológicos de las condiciones de borde que a su vez están balanceados geostrófica e hidrostáticamente. Sus desventajas principales son dos, la primera es que la estimación de los errores laterales no depende del estado del flujo en este caso, y la segunda es que el valor del factor escalar de las perturbaciones es empírico. Esta metodología fue implementada por Dirren y otros (2007).

Un tercer abordaje consiste en seleccionar unos pocos puntos de los bordes para perturbarlos mediante un método auto-regresivo. En un segundo paso se

ajustan los restantes puntos de los bordes para mantener un balance físico en las condiciones de borde. Este método se puede implementar a partir de un ensamble global o a partir del mismo ensamble regional, en cuyo caso este método no requeriría de información adicional para implementarlo. Este método puede utilizarse para proveer nuevas perturbaciones en caso de que el número de miembros del ensamble global sea menor al del ensamble regional. La principal ventaja de este método cuando se utiliza un ensamble global es que estima una varianza del error que depende del estado del sistema. En contrapartida, este método puede sufrir de errores de muestreo a la vez que requiere asumir coeficientes de auto-correlación. Una última alternativa es la de crear perturbaciones a partir de relaciones prefijadas en los campos de error de los bordes. A diferencia del método anterior que construye las perturbaciones a partir de un número limitado de puntos, en este método las perturbaciones se generan a partir de relaciones prefijadas para todos los puntos y variables. Para eso se construyen perturbaciones al azar de tipo gaussiano con media cero y varianza P^b , que es fija y que se puede obtener de algún sistema de asimilación variacional. Al mismo tiempo, se asumen que las perturbaciones evolucionan temporalmente mediante un proceso auto-regresivo. La ventaja de este método es que no requiere almacenar grandes volúmenes de información, aunque se pierde la dependencia temporal del flujo. Técnicas de este tipo han sido implementadas por ejemplo en Torn y Hakim (2008 a, b) y Torn y Hakim (2009 a, b).

Los resultados encontrados en el trabajo de Torn y otros (2006) muestran que la mejor opción, aunque muchas veces difícil de implementar, es utilizar un ensamble global para proveer las condiciones de borde apropiadas. Sin embargo, las alternativas mencionadas anteriormente, a pesar de sus limitaciones y debilidades propias, brindan resultados razonables en términos de errores.

En esta sección implementaremos la técnica de perturbación de las condiciones de borde lateral, aplicadas a la situación en la que las mismas constituyen una fuente de error. De esta manera, estudiaremos el impacto de implementar

dicha técnica con respecto al experimento MPBI del capítulo anterior. El experimento con perturbación de bordes se denominará experimento de Modelo Perfecto y Bordes Imperfectos con Bordes Perturbados (MPBI BP). Por su parte, el algoritmo IMA requiere de un período de 8 meses de entrenamiento para lograr una convergencia a valores cercanos a los óptimos. El entrenamiento se lleva a cabo tomando como valor inicial el valor final de IMA del experimento MPBI.

Tal como mencionamos anteriormente, la utilización de las condiciones de bordes dadas por el modelo operativo GFS de 1° de resolución horizontal en lugar del FNL constituyen la única fuente de error del sistema en ambos experimentos. En el experimento MPBI BP se introducen perturbaciones a las condiciones de borde lateral provenientes del modelo GFS. La metodología empleada para generar dichas perturbaciones es similar a la técnica de perturbaciones al azar tomadas de una climatología que introdujimos anteriormente, aunque como veremos a continuación, no es exactamente igual. En nuestro caso las perturbaciones se obtienen a partir de la base de datos del CFSR correspondientes a los años 2008 y 2009 con una resolución de 2.5°, tomando dos campos de fechas diferentes al azar, para luego restarlos y escalarlos por un factor de 0.1. Este es un valor de factor de escala muy similar al utilizado por Torn y otros (2006) en su implementación de perturbaciones a partir de una climatología (que es del orden de 0.11), cuyo valor fue estimado buscando que la varianza temporal de las variables en los bordes coincidiera con la varianza de un ensamble global. En este caso también se toma la precaución de no repetir las mismas fechas para generar las perturbaciones de cada miembro del ensamble. Dado que en este caso se requieren condiciones de borde perturbadas para todos los ciclos de pronóstico y asimilación, las perturbaciones evolucionan temporalmente junto con los ciclos de asimilación. Esta evolución temporal se obtiene realizando la resta de los campos del CFSR correspondientes a las fechas sub-siguientes a las elegidas para generar la perturbación de bordes en el primer ciclo. De esta manera se obtienen perturbaciones cuya evolución temporal emulan la variabilidad temporal del flujo atmosférico. Esta forma de generar las

perturbaciones tiene la principal ventaja respecto de la técnica mencionada previamente es que al evolucionar temporalmente, las perturbaciones resultantes guardan una consistencia temporal. Al mismo tiempo se respeta la frecuencia temporal de la incertidumbre de los bordes y no se introducen frecuencias espurias en el forzado lateral. En contrapartida, y como ya hemos mencionado, esta forma de perturbar los bordes no tiene en cuenta las incertidumbres del día producidas por las inestabilidades de escala mayor a la representada en nuestro dominio regional, sino que sólo tenemos una estimación climatológica de la incertidumbre proveniente del exterior del dominio.

En la Figura 4.9 se muestra el EETS para los experimentos MPBI y MPBI BP. Vemos aquí que perturbar las condiciones de borde, aun sin reproducir los errores del día, repercute en una mejora del análisis desde el punto de vista global (Figura 4.9 a), dado que los errores del experimento MPBI-BP son menores que los del experimento MPBI. Geográficamente notamos que la mayor mejora se produce en latitudes medias, en regiones relativamente alejadas de los bordes, como era de esperar, dados los resultados del capítulo anterior (Figura 4.9 c). Si observamos la distribución del EETS en la vertical notamos que las mejoras por introducir perturbaciones en los bordes, son prácticamente similares en toda la troposfera (Figura 4.9 d).

Separando las diferentes componentes del error en energía (Figura 4.10), la mejora se da especialmente en la componente no sistemática, tal como se podía esperar, ya que en este caso la componente dominante del error es la no sistemática (Figura 4.10 d y h). Sin embargo, a lo que se debe prestar especial atención en estos casos es a la mejora de la representación del error por parte del ensamble. Esto lo podemos ver en la Figura 4.11, que muestra un claro aumento de la dispersión en latitudes medias, y cuyo patrón espacial se hace más parecido al del error en el experimento con perturbación de bordes (Figura 4.11 e). Sin embargo, la magnitud de los valores de dispersión continúan siendo menores a los del error. La correlación temporal evidencia que hay una mejora en la representación del error en esta región, incluso en zonas muy

cercanas al borde oeste (Figura 4.11 f). Este hecho puntual es digno de mencionarse, dado que en este caso no estamos representando los errores del día del flujo.

En la Tabla 4.3 se muestran las reducciones/amplificaciones relativas de error y dispersión, junto con la mejora en la correlación temporal para el experimento MPBI BP con respecto al experimento MPBI. Podemos ver aquí que la mejora en lo que a errores respecta se da en todas las variables mostradas en la tabla (excepto la precipitación), siendo la componente no sistemática la que mayor aporte realiza a dicha mejora. Sin embargo, el aporte más notorio de la perturbación de las condiciones de borde se observa en el aumento de la dispersión del ensamble, que muestra valores en torno del 20 al 30 % para variables como la energía, el viento zonal y la temperatura, mientras que para las variables de masa como la presión en superficie y el geopotencial, el incremento es del 150%. También observamos una mejora de la correlación temporal, que comparado con los experimentos de modelo imperfecto de la sección anterior, vemos que son del mismo orden de magnitud. El EHIV por su parte muestra una mejora con respecto al error, que se evidencia en latitudes medias por la componente no sistemática (no se muestra). Las componentes sistemáticas por el contrario, muestran cierta degradación a juzgar por los valores de la Tabla 4.3. No obstante esto, la correlación de la dispersión con el error muestra una mejora, la que geográficamente se evidencia en latitudes medias, en regiones cercanas a los bordes oeste y sur (no se muestra). La precipitación por su parte, tal como ocurrió en el capítulo anterior cuando analizamos el impacto de introducir el error en los bordes con respecto al caso perfecto, no muestra una gran sensibilidad en lo que se refiere a errores. No obstante, muestra cierto aumento de la dispersión y sobre todo una mejora en la correlación entre el error y la dispersión.

	Total	MNBIAS	SDBIAS	No-SIST	Dispersión	Correlación
EETS	-22,47	-4,21	-2,15	-25,72	21,68	0,120
U	-9,28	-5,84	5,08	-9,98	33,90	0,066
T	-8,65	-3,01	-2,07	-9,36	32,89	0,054
PSFC	-13,13	-2,90	-8,09	-13,28	156,83	0,066
Geopot	-8,92	-5,09	0,87	-10,53	141,25	0,040
EHIV	-8,26	6,33	8,42	-8,36	5,62	0,020
PP	0,40	0,01	-1,19	0,55	4,20	0,041

Tabla 4.3: Porcentaje de reducción de errores y de dispersión en el ensamble, junto con aumento de correlación entre RMSE y dispersión del experimento MPBI-BP con respecto al experimento MPBI. Valores negativos indican reducción y positivos incremento en las diferentes variables.

A la luz de estos resultados, podemos afirmar que la perturbación de las condiciones de borde mejora la representación espacial en el ensamble de la incertidumbre. El análisis de la IMA en estos experimentos que se muestra en la Figura 4.12 apunta en la misma dirección. Aquí se aprecia la clara reducción de la IMA en el experimento con bordes perturbados (Figura 4.12 a). Desde el punto de vista geográfico notamos la reducción de la inflación en todo el dominio, especialmente en latitudes medias. Sólo persiste el máximo asociado a la incertidumbre en la región de los Andes, aunque incluso en esta región la disminución de la IMA es notable en comparación con el experimento sin perturbación de bordes (Figura 4.12 c). Notamos también que la IMA en el experimento MPBI-BP tiene valores similares en los bordes este y oeste, a diferencia de lo que ocurre en el experimento MPBI (Figura 4.12 b y c). En la vertical encontramos que la reducción de la IMA se da en la mayor parte de la columna atmosférica, aunque la mayor reducción la encontramos en los niveles superiores de la troposfera (Figura 4.12 d).

Esta clara reducción de la IMA se puede comprender más fácilmente al observar la Figura 4.13 que muestra los valores de la ecuación (3.8). Se aprecia aquí la disminución del déficit de dispersión en el experimento con perturbación de bordes en comparación con el experimento sin perturbación, especialmente en el viento zonal (Figura 4.13 d). Sólo en la región de los Andes subtropicales persiste el déficit, aunque claramente es mucho menor que en otros experimentos, como por ejemplo el MPBP. También en la

temperatura sobre el continente (Figura 4.13 e) y en la humedad específica (Figura 4.13 f) sobre el Atlántico se aprecia que la falta de dispersión del ensamble es menor que en el caso sin perturbación de bordes.

Por lo tanto, la perturbación de las condiciones de borde redundará en una clara mejora de la calidad del análisis, ya que al representar más adecuadamente en el ensamble la fuente de error, el peso dado a las observaciones durante el proceso de asimilación es mayor y esto permite que la calidad del análisis sea mayor. Sin embargo, no debemos perder de vista que la técnica de perturbación de bordes implementada aquí sólo considera incertidumbres climatológicas en las condiciones de borde. Es decir, en este caso no estamos teniendo en cuenta los errores del día en las condiciones de borde, y este es quizás el mayor limitante de la técnica implementada aquí. No obstante esto, es notable que aun con esta debilidad del método implementado, la mejora en la calidad del análisis haya sido importante.

4.4 Experimentos de Modelo y Bordes Imperfectos

En esta sección retomamos el experimento MIBI del capítulo anterior para evaluar el impacto de incluir la incertidumbre en el modelo y en las condiciones de borde cuando ambas fuentes de error están presentes simultáneamente. Esto es, se introducen en el experimento MIBI del capítulo anterior las técnicas de ensamble físico y de perturbación de bordes al azar utilizados en las secciones previas. De esta manera, el experimento con inclusión de fuentes de error se denominará de Modelo Imperfecto y Bordes Imperfectos con Ensamble Físico y Bordes Perturbados (MIBI EF BP), el cual se compara con el experimento MIBI del Capítulo 3. En este caso, la técnica de IMA requiere de un período de entrenamiento de 4 meses a partir del valor final del experimento MIBI.

Los errores en Energía Total Seca de ambos experimentos (Figura 4.14) muestran que en este caso es sumamente ventajoso implementar simultáneamente la técnica de ensamble físico y perturbación de bordes.

Podemos ver que muchas de las regiones afectadas por estas fuentes de error ven reducidos sustancialmente sus errores, tanto en la región de convección activa en el norte del dominio como la región de los Oestes de latitudes medias y en particular la región de orografía compleja de los Andes (Figura 4.14 c). También se observa que la mejora es mayor en los niveles bajos del modelo (Figura 4.14 d), lo cual está asociado a la reducción de los errores provenientes del modelo, tal como se observa en la Figura 4.1. Asimismo, las componentes del EETS (Figura 4.15) también evidencian la mejora tanto en la componente sistemática del *mnbias* (Figura 4.15 b y f) como de la componente no sistemática (Figura 4.15 d y h). Tal como ocurría en los experimentos anteriores, el aporte del *sdbias* en este caso es insignificante (Figura 4.15 c y g). Sin perder de vista lo más importante, la reproducción del error del sistema a partir de la dispersión del ensamble muestra una mejora en la Figura 4.16 del experimento MIBI-EF-BP, si bien su magnitud es aún menor en comparación con el error. Esta mejora la podemos apreciar especialmente en la correlación temporal en latitudes medias cerca de los bordes sur y oeste (Figura 4.16 f).

Estos resultados se pueden corroborar también en la Tabla 4.4, que muestra la comparación de errores relativos del experimento MIBI EF BP con respecto al experimento MIBI. Todas las variables mostradas aquí muestran una reducción importante del error. No obstante, también se evidencian aumentos de la componente del *mnbias* en las variables de masa y humedad, algo que también observábamos cuando analizamos el caso de modelo imperfecto (ver Tabla 4.2). Al mismo tiempo se observa un aumento en la dispersión del ensamble (salvo para la energía), la cual está explicada principalmente por la perturbación en las condiciones de borde. Incluso se aprecia que las variables de masa son las que más aumentan su dispersión, y las que muestran un aumento del error sistemático, lo cual se debe a la implementación de la técnica de ensamble físico, tal como encontramos anteriormente. Por su parte, la correlación entre el error y la dispersión del ensamble aumenta en todas las variables en una magnitud similar al caso de los experimentos de modelo imperfecto.

	Total	MNBIAS	SDBIAS	No-SIST	Dispersión	Correlación
EETS	-28,54	-51,73	-36,43	-25,72	-14,93	0,132
U	-13,38	-25,09	-14,74	-13,25	6,67	0,061
T	-14,87	-28,35	-27,96	-12,43	15,67	0,061
PSFC	-8,75	21,55	-2,08	-13,93	77,61	0,052
Geopot	-5,58	34,48	-16,70	-11,26	77,72	0,054
EHIV	-15,84	28,15	-0,10	-15,09	-7,17	0,060
PP	-7,96	0,06	6,75	-11,54	-17,98	0,051

Tabla 4.4: Porcentaje de reducción de errores y de dispersión en el ensamble, junto con aumento de correlación entre RMSE y dispersión del experimento MIBI-EF-BP con respecto al experimento MIBI. Valores negativos indican reducción y positivos incremento en las diferentes variables.

Finalmente, analizamos el comportamiento de la IMA en estos experimentos (Figura 4.17). En este caso se aprecia cómo la implementación de la técnica de ensamble físico y perturbación de las condiciones de borde lateral resulta en una reducción notable de la inflación, lo cual es indicativo de que tales técnicas realizan un buen trabajo en busca de representar adecuadamente el error del análisis. En efecto, la disminución de la inflación lleva a que el experimento MIBI EF BP tenga valores de IMA inferiores incluso a los del experimento MPBP (Figura 4.17 c). En el perfil vertical se aprecia que la disminución de la inflación se da en prácticamente toda la columna atmosférica, con la mayor disminución en la tropósfera alta (Figura 4.17 d). Por su parte la Figura 4.18 muestra que el marcado déficit de dispersión en viento zonal que evidencia el experimento MIBI (Figura 4.18 a) se ve prácticamente eliminado en todo el dominio en el experimento MIBI EF BP (Figura 4.18 d). La temperatura en niveles bajos por su parte muestra que aún persiste cierta falta de dispersión en zonas continentales en latitudes tropicales y especialmente sobre los Andes subtropicales (Figura 4.18 e). La humedad específica en cambio muestra que con la implementación simultánea del ensamble físico y de la perturbación de los bordes pasamos de tener falta de dispersión en la región ecuatorial a excesos de dispersión, siempre dentro de un patrón espacial un tanto ruidoso (Figura 4.18 f).

Los resultados obtenidos para este experimento muestran que la implementación del ensamble físico y de perturbación de bordes es muy útil. En particular muestran que ayudan a representar de manera más adecuada las fuentes de error dentro del sistema y en consecuencia permiten que la técnica IMA no deba adoptar valores extremadamente altos en pos de compensar la falta de dispersión en el ensamble. Dado que estas condiciones de modelo y borde imperfectos son las más realistas de los experimentos propuestos, es claro que cualquier sistema de análisis-pronóstico regional necesariamente debe adoptar tales estrategias para poder obtener una representación adecuada tanto del estado del flujo atmosférico como de su incertidumbre asociada. Con todo, estas estrategias son factibles de ser mejoradas y en ese sentido se pueden aplicar otras técnicas complementarias.

Capítulo 5: Sensibilidad del análisis y del pronóstico a la resolución horizontal del modelo: Experimentos con observaciones reales

5.1 Introducción

Este capítulo está dedicado a los experimentos diseñados para la evaluación de la sensibilidad del análisis a la resolución del modelo, utilizando datos reales. El primer objetivo de este capítulo es el de cuantificar el grado de mejora de la calidad del análisis al incrementar la resolución horizontal del modelo. Como objetivo secundario, se busca cuantificar, dada la mejora del análisis, en qué medida se incrementa la calidad del pronóstico. Dentro del objetivo secundario, haremos especial hincapié en la mejora del pronóstico de eventos de convección organizada.

Estos experimentos complementan los experimentos idealizados de los capítulos 3 y 4, ya que se concentran en un aspecto clave de cualquier sistema de análisis – pronóstico que es la capacidad del modelo en representar los procesos de diferentes escalas. Este punto guarda relación con los experimentos de modelo imperfecto de los capítulos anteriores en los que la fuente de error estaba en la representación de los procesos de escala sub-reticular. En dichos experimentos encontramos que los errores en dichos procesos pueden provocar un aumento importante del error del análisis, y que es necesario adoptar alguna estrategia para mitigar sus efectos. Una posibilidad que exploramos fue la implementación de la técnica de ensamble físico junto con la IMA, la cual ayuda a reducir el error del análisis. En estos experimentos en cambio el camino a recorrer es diferente, ya que lo que se busca es mejorar la representación de los procesos de menor escala a partir de un aumento de la resolución horizontal del modelo. Sin embargo, no debemos perder de vista que estos experimentos utilizan información real, mientras que los anteriores son idealizados, lo cual limita la comparación de los resultados entre ambos conjuntos de experimentos. Un último punto destacar de los experimentos de este capítulo es el hecho de que a partir de los mismos podemos tener una primera noción acerca de en qué medida la resolución del

modelo influye en la calidad del análisis en comparación con otros factores no estudiados explícitamente en esta Tesis como por ejemplo la cantidad de información asimilada.

El presente capítulo está dividido en 3 partes: en la primera describimos el diseño experimental, en la segunda parte se estudia la mejora de la calidad del análisis, y finalmente en la tercera y última se analiza la mejora en la calidad del pronóstico.

5.2 Diseño experimental

Para la realización de estos experimentos se utiliza el algoritmo LETKF acoplado al modelo WRF-ARW en su versión 3.4, sobre un dominio que abarca el Pacífico Noroeste (ver Figura 5.1). Las diferencias de la versión del modelo WRF-ARW utilizado en este capítulo con respecto a los capítulos previos y que pueden afectar a los experimentos de esta Tesis son menores. La diferencia más importante entre ambas versiones y que afecta a nuestros experimentos radica en la modificación de algunos parámetros de la parametrización YSU. En estos experimentos se generan dos análisis, con una frecuencia de asimilación de datos de 6 horas, cuyas resoluciones son de 60 (LETKF 60K) y de 20 km (LETKF 20K), respectivamente. La cantidad de niveles verticales sigma-p en ambos análisis es de 40, con tope en el nivel de 10 hPa. Las parametrizaciones físicas utilizadas se detallan en la Tabla 5.1 y son las mismas para todos los miembros del ensamble. Los experimentos comienzan a las 00 UTC del 7 de agosto de 2008 y se extienden hasta las 00 UTC del 30 de septiembre de 2008.

Microfísica	WSM-5 clases
Onda larga	RRTM
Onda corta	Dudhia
Capa superficie	Monin Obukhov
Suelo	Noah
Capa limite	YSU
Convección	Kain-Fristch

Tabla 5.1: Parametrizaciones físicas utilizadas en los experimentos de asimilación de datos reales.

La cantidad de miembros utilizados para el LETKF es de 40 miembros, al igual que en los experimentos idealizados discutidos en los capítulos 3 y 4. Los parámetros de localización horizontal son de 400 km (1460 km de radio de influencia) para el LETKF 60K (la misma escala de localización de los experimentos idealizados) y de 133 km (radio de influencia de 485 km) para el LETKF 20K. Este procedimiento se realiza por el hecho de que la covarianza entre las variables decae más rápidamente con la distancia a medida que se resuelven escalas menores, y por lo tanto para filtrar eficientemente correlaciones espurias es necesario reducir la escala de localización espacial (Zhang, y otros, 2009, Miyoshi y Kondo, 2013). Para la localización vertical se utiliza la misma escala para ambos sistemas, es decir un valor de 0.4 en la escala logarítmica de presión, que es la misma que la utilizada en los experimentos idealizados. Asimismo, se utiliza la técnica IMA en ambos experimentos. En ninguno de los dos experimentos se entrena la IMA. En el caso del LETKF 60K se utilizan los valores de IMA del trabajo de Miyoshi y Kunii (2012b), mientras que para el LETKF 20K los valores de IMA iniciales se reducen a una tercera parte de los valores iniciales del LETKF 60K. Esta reducción del valor inicial de la IMA en el experimento LETKF 20K se realiza debido a que la utilización de los mismos valores de IMA del experimento LETKF 60K produce inestabilidades numéricas. Es importante remarcar que

dado que estamos utilizando las mismas parametrizaciones físicas para todos los miembros del ensamble, sólo tenemos la técnica IMA para compensar la falta de dispersión del ensamble.

Ambos análisis son alimentados por las mismas observaciones las cuales provienen de diversas fuentes, como radiosondeos, perfiladores de viento, estaciones de superficie, boyas, barcos, aviones, estimaciones de viento en superficie provenientes del Advanced Scatterometer (ASCAT) y estimaciones de temperatura provenientes del Atmospheric Infrared Sounder (AIRS). No se incluyen datos de radianzas de satélite, que en los sistemas de asimilación operativos de los centros mundiales de pronóstico, constituyen buena parte del volumen de información satelital asimilada (del orden del 50%). La base observacional utilizada en estos experimentos es la de Miyoshi y Kunii (2012b), y esencialmente el experimento LETKF 60K coincide en su configuración con el de dicho trabajo. En la Figura 5.2 se muestra el número total de observaciones asimiladas de viento zonal, temperatura y humedad específica en cajas de 5° por 5° discriminadas por capas verticales entre superficie y 800 hPa, entre 800 y 300 hPa y por encima de 300 hPa. En esta figura podemos apreciar que la distribución espacial de observaciones claramente no es homogénea. Vemos en primer lugar que las observaciones tienden a aparecer más abundantemente sobre áreas continentales, en donde se cuenta con mayor número de estaciones de superficie y de radiosondeos. Asimismo notamos una gran cobertura de datos de temperatura por encima del nivel de 300 hPa, asociados principalmente a las estimaciones satelitales de los AIRS. Las estimaciones del AIRS en los niveles cercanos a la superficie no se han tenido en cuenta en este caso dado que sus errores son mayores (Ho y otros, 2007). Los datos de viento por su parte muestran áreas puntuales de mayor concentración sobre el continente en los niveles altos. También encontramos un gran número de observaciones de viento en el océano lejos del continente en niveles bajos que corresponden a estimaciones ASCAT. Podemos ver entonces, que a diferencia de los experimentos idealizados, esta distribución espacial de observaciones típica de un sistema real es irregular tanto espacial como temporalmente.

Las condiciones iniciales y de bordes de los respectivos experimentos provienen de la base de datos del FNL. Para generar las perturbaciones iniciales de los respectivos ensambles se aplica la técnica de perturbaciones al azar utilizando para ello campos del FNL correspondientes al mes de julio de 2008, eligiendo la resta de dos campos para luego escalarlas por un factor de 0.2 y sumarlas al campo del FNL correspondiente al 7 de agosto. Asimismo, todos los miembros de los ensambles utilizan las mismas condiciones de borde, por lo que no se tienen en cuenta en este caso las fuentes de incertidumbre asociadas a los errores provenientes del exterior del dominio, que como ya vimos en los capítulos previos, tienen una gran influencia en latitudes medias especialmente.

A partir de ambos sistemas de análisis, para cada ciclo de asimilación se realizan pronósticos a 72 horas utilizando la retícula del LETKF 20K. Para los pronósticos inicializados con el LETKF 60K se realiza una interpolación horizontal del análisis de 60 km a la retícula de 20 km utilizando el sistema de pre-procesamiento WPS del modelo WRF (ver Figura 3.1, casillero PRE-WRF). En este caso se escriben los campos de análisis LETKF 60K en formato binario y se los procesa con los programas *metgrid* y *real* interpolándolos a la retícula del LETKF 20K. En ambos casos, se realiza una única corrida determinística a partir de la media del ensamble de análisis. Las parametrizaciones físicas utilizadas en la generación de los pronósticos son las mismas de la Tabla 5.1.

A fines de comparar la calidad de los pronósticos obtenidos a partir de los dos análisis LETKF con los análisis GDAS, se realiza una serie de pronósticos con el modelo WRF utilizando la información de los análisis provenientes del GDAS como condición inicial, utilizando la misma configuración de retícula y parametrizaciones de los pronósticos inicializados a partir de los análisis LETKF. Estos pronósticos serán referidos en este capítulo como pronósticos GDAS. La resolución original de los análisis operativos GDAS para el período del experimento es de 35 km. Sin embargo, la resolución horizontal de los análisis GDAS utilizados en este caso es de 1°, la cual es menor que la de los experimentos LETKF. Al igual que para los pronósticos inicializados con los

análisis LETKF 60K, se utiliza el sistema WPS para interpolar los análisis GDAS a la retícula del LETKF 20K. En los 3 casos, el modelo WRF es forzado en los bordes con los pronósticos operativos del modelo GFS con una resolución horizontal de 1°.

El período de verificación tanto de los análisis como de los pronósticos abarca desde las 00 UTC del 20 de agosto hasta las 00 UTC del 30 de septiembre. De esta manera, eliminamos las primeras dos semanas de los experimentos, para evitar incluir el período de spin-up de los mismos en la verificación. Por lo tanto, la cantidad total de análisis verificados es de 165. Sin embargo, existe un faltante de pronósticos, el cual abarca desde las 18 UTC del 13 de septiembre hasta las 18 UTC del 14 de septiembre, inclusive. Este bache se produce por la falta de pronósticos de la base de datos del modelo GFS en estas fechas, lo que no permite especificar las condiciones de borde para forzar al modelo. Esto reduce por lo tanto el número total de pronósticos disponibles, verificándose una cantidad total de 160 pronósticos.

5.3 Verificación de la calidad del análisis

Analizamos en primer lugar la calidad del análisis de los experimentos LETKF 60K y LETKF 20K, con el objetivo de estudiar el grado de mejora del análisis al aumentar la resolución horizontal del modelo. En este caso, como se trata de un experimento realista no se conoce la verdadera evolución de la atmósfera como ocurría en los casos de los experimentos idealizados de los Capítulos 3 y 4. Por este motivo, para realizar un análisis similar necesitamos utilizar un análisis que a priori podamos considerar que se aproxima más a la realidad para utilizar como referencia. En este caso utilizamos como referencia el análisis operativo GDAS. Si bien se sabe que el GDAS, como cualquier otro análisis operativo, sufre de diferentes errores y que es tan sólo una estimación de la condición real de la atmósfera; la cantidad de información observacional incluida en dichos análisis supera largamente a la cantidad de observaciones utilizadas para la generación de los análisis LETKF 60K y LETKF 20K. La

principal diferencia, como ya se mencionó anteriormente, proviene de la información de radianza medida por satélites.

Otro punto a tener en cuenta en lo que se refiere a la verificación de la calidad del análisis, es que tanto el análisis GDAS como el LETKF 20K son interpolados a la retícula del análisis LETKF 60K, mediante una interpolación lineal. Esto se hace así para realizar la comparación utilizando la misma retícula y llevar los análisis a una escala en la que ambos son comparables.

Comenzamos la verificación mediante el análisis del EETS, que se muestra en la Figura 5.3. Aquí notamos que en el promedio espacial hay una mejora en el análisis de 20 km (Figura 5.3 a), como así también en el promedio temporal (Figuras 5.3 b, c y d). La distribución geográfica nos muestra dos regiones de máximo error: en latitudes medias en la franja de paralelos entre 35 y 45°N, y en una amplia zona del océano en la banda de latitudes entre 10 y 25°N, cuyos errores crecen gradualmente a medida que nos movemos hacia el oeste, hasta alcanzar los máximos absolutos cerca del continente. El origen de los errores en latitudes medias obedece a la actividad de las ondas baroclínicas típica de esta banda de latitudes, en donde alcanzan su mayor profundidad y se propagan rápidamente a través del dominio. En latitudes tropicales en cambio, el error está explicado por procesos convectivos y en especial por la actividad de los ciclones tropicales. El perfil vertical de errores (Figura 5.3 d) muestra por su parte que la mayor mejora en el análisis de 20 km se da principalmente en los niveles inferiores de la troposfera, aunque también encontramos otra zona de mejora en los niveles altos de la troposfera. También se aprecia el máximo de error en ambos sistemas en el nivel de 800 hPa, el cual está explicado principalmente por diferencias sistemáticas con el análisis GDAS, como veremos más adelante.

A fines de reconocer las fuentes de error encontrados en las diferentes regiones, en la Figura 5.4 se muestran los errores en energía divididos por componentes. Aquí notamos que en general los errores no sistemáticos son los que dominan en ambos análisis (Figura 5.4 g y h), los cuales se maximizan en latitudes medias asociados al pasaje de las ondas baroclínicas y en latitudes

tropicales frente al continente, relacionados con los ciclones tropicales registrados en esta región durante el período experimental. En regiones tropicales, especialmente sobre áreas oceánicas, notamos también que la componente sistemática del *mnbias* es de gran importancia (Figura 5.4 c y d). La del *sdbias* en cambio es de menor magnitud, salvo en áreas continentales, donde cobra cierta relevancia y está asociada a diferencias en la amplitud de la oscilación diaria de viento en la capa límite y de presión en superficie en casos de ciclones tropicales entre los modelos GFS y WRF (Figura 5.4 e y f). A fin de reconocer con mejor detalle el comportamiento de las diferentes variables, en la Figura 5.5 se muestran las diferentes componentes de error para el viento (Figura 5.5 a-c), la temperatura (Figura 5.5 d-f), la presión en superficie (Figura 5.5 g-i) y la humedad integrada en la vertical (Figura 5.5 k-l) en el experimento LETKF 60K. Aquí reconocemos nuevamente que la componente no sistemática del error es la más importante en todas las variables, la cual domina en latitudes medias especialmente. Asimismo se resalta la componente sistemática del *mnbias* sobre áreas oceánicas (Figura 5.5 d, y g), que explica la mayor parte del error en dicha región, especialmente en la temperatura y la presión de superficie. La componente del *sdbias* se vuelve importante sólo para la presión en superficie en dos bandas estrechas que rodean a la isla de Taiwán (Figura 5.5h), la cual se asocia a diferencias entre los análisis en la profundidad de los tifones que circulan por esta región.

Para estudiar la distribución vertical de las diferentes componentes del error, la Figura 5.6 muestra las componentes del error promediadas horizontalmente para el geopotencial, la temperatura, el viento zonal y la humedad específica. Podemos apreciar aquí que tanto el geopotencial como la temperatura presentan buena parte del error total en las componentes sistemáticas. Se aprecia que para el geopotencial, el análisis de 60 km presenta menores diferencias con el GDAS que el de 20 km en todas las componentes del error a lo largo de la vertical. Algo similar ocurre con la temperatura, aunque las diferencias son más evidentes en los niveles altos. En niveles bajos en cambio, domina la componente sistemática, la cual se maximiza en 800 hPa, y es la que explica el máximo de error en energía total seca en dicho nivel (Figura 5.3

d). En la componente zonal del viento en cambio, vemos que la mayor parte del error corresponde a la componente no sistemática y que en esta variable, junto con la de viento meridional que no se muestra, es donde se aprecia la mejora del análisis de alta resolución. Para la humedad específica (Figura 5.6 m-p), notamos una reducción del error en el análisis de 20 km con respecto al de 60 km. Con todo, en esta variable también observamos que las componentes sistemáticas son importantes, especialmente la relacionada con la diferencia entre medias (*mnbias*). Aquí observamos un bias positivo en superficie, que se da sobre las áreas oceánicas, mientras que hacia el tope de la capa límite (niveles entre 800 y 850 hPa), dicho bias se vuelve negativo.

Para determinar la significancia de los resultados obtenidos, en la Tabla 5.2 se muestran los porcentajes de reducción y/o aumento del RMSE para el viento, la temperatura, la altura geopotencial, la humedad específica y la presión en superficie, a excepción del EETS que está expresada por el error cuadrático medio. En negrita se muestran aquellos valores significativos para un nivel de significancia del 1%, utilizando un método bootstrap (Wilks, 2006). El método de bootstrap es aplicado para los valores de RMSE de las diferentes variables, promediando en el espacio para cada tiempo de verificación. Para llevar a cabo el test de significancia se generan 10000 réplicas de las marchas temporales de los errores del análisis LETKF 60K en cada una de las variables, de forma tal de obtener los diferentes percentiles de la distribución de errores del análisis de 60 km. En el paso siguiente se comparan los errores del análisis LETKF 20K con los percentiles estimados previamente, para luego determinar si la diferencia entre ambos análisis es significativa.

Los resultados de la Tabla 5.2 indican que las mejoras del análisis LETKF 20K son significativas en EETS, en viento y en humedad específica principalmente. Para las variables de masa en cambio notamos una fuerte degradación del análisis de 20 km, con valores significativos. En temperatura finalmente, notamos una ligera mejora, aunque la misma no es significativa.

EETS	U	V	T	PH	Q	PSFC
10.34	10.32	9.72	0.98	-25.72	12.91	-20.13

Tabla 5.2: Porcentaje de reducción del error cuadrático medio para el EETS y de RMSE para diferentes variables del análisis LETKF 20K con respecto al análisis LETKF 60K. Valores positivos indican reducción y negativos incremento en las diferentes variables. En negrita se indican los valores estadísticamente significativos con una significancia del 1%.

Estos resultados pueden ser explicados a partir de la teoría del ajuste geostrófico. De acuerdo con esta teoría, las observaciones asimiladas de las variables de masa tendrán mayor impacto en escalas espaciales mayores a las del radio de deformación de Rossby. Para nuestro dominio, el radio de deformación de Rossby oscila entre los 3000 km en el borde norte del dominio y los 6000 km en la latitud de 20°N, considerando un espesor de atmósfera de 10 km. Por su parte, las observaciones de viento tendrán un mayor impacto en escalas espaciales menores al radio de deformación de Rossby (ver Kalnay, 2003 y Žagar y otros 2004). Cuando en el análisis de mayor resolución se reduce la escala de localización de las observaciones, se reduce la escala horizontal de las correcciones introducidas en el análisis y por ende se incrementa el impacto de la corrección sobre las variables de viento. Las correcciones sobre las variables de masa en cambio tenderán a perderse más rápidamente, al proyectarse mayormente en modos de ondas gravito-inerciales en lugar de ondas de Rossby de mayor escala. Este comportamiento explicaría entonces por qué no se observa una mejora sobre dichas variables al reducir la escala de localización. Si bien en ambos análisis la localización utilizada es menor que el radio de deformación de Rossby, en el caso del LETKF 20K la escala horizontal es mucho menor que en el análisis LETKF 60K. Por lo tanto, el reducir la escala de localización del análisis de 20 km es más eficiente en reducir errores en las variables de viento, pero no en las de masa.

En las regiones tropicales en cambio, la teoría de balance geostrófico no es válida, por lo que la mejora tanto en el viento como en la humedad específica

puede explicarse por el hecho de que la escala espacial de variabilidad es menor para estas variables que para las variables de masa. Por lo tanto, el reducir la escala de localización genera una mejora tanto en viento como en humedad específica. En variables como presión o temperatura en cambio, al disminuir la escala de localización se pierde información del flujo de mayor escala, que es la que mejor describe la variabilidad de estas variables. En consecuencia, el análisis de 60 km es mejor para describir a estas variables.

Las conclusiones que podemos extraer hasta aquí de los errores de los respectivos análisis es que en términos globales, incrementar la resolución del modelo resulta en una mejora de la calidad del análisis. Esto se observa en variables como la energía, cuya mejora responde especialmente a la mejora en el viento. Esta variable, junto con la humedad específica constituyen las variables que reflejan la mejora del análisis de 20 km. No obstante, debido a que estamos realizando la verificación utilizando un análisis operativo, en donde también hay errores presentes, la validez de nuestra verificación es hasta cierto punto limitada. De todos modos, en la próxima sub-sección en la cual se verificará la calidad de los pronósticos a partir de las observaciones asimiladas, podremos darle mayor validez a la verificación realizada hasta aquí.

Un punto que hasta ahora no hemos abordado en esta verificación y que permite verificar en qué medida el ensamble es capaz de representar la incertidumbre en la estimación de las condiciones iniciales, es la comparación de los errores del análisis con la dispersión del análisis. La Figura 5.7 nos muestra el error, junto con la dispersión en EETS y la correlación temporal entre ambas variables para los dos análisis. En la Figura 5.8 se muestran los valores medios de dispersión para el viento, la temperatura y la presión en superficie. La primera diferencia que resalta en las figuras es que la dispersión entre los miembros del ensamble es marcadamente mayor en el análisis de mayor resolución. En general los aumentos en dispersión oscilan entre el 100 y el 500 % para las diferentes variables. Este aumento de la dispersión podemos atribuirlo principalmente a la mayor capacidad del modelo de 20 km en

representar tasas mayores de crecimiento del error. Asimismo, el menor radio de influencia de las observaciones también contribuye a incrementar la dispersión, ya que en cada punto de retícula del modelo se utiliza información de un número menor de observaciones. En consecuencia, el efecto de reducción de la dispersión del ensamble dado por la asimilación de las observaciones es menor. Otro aspecto a notar en la dispersión del análisis de 20 km, son los mínimos puntuales y relativos de dispersión ubicados en zonas oceánicas, los cuales coinciden con zonas donde hay un mayor número de observaciones (ver Figura 5.2). Finalmente, se observa que los máximos de dispersión se dan lejos de los bordes, lo cual está asociado a estar utilizando las mismas condiciones de borde y que es consistente con lo encontrado en los experimentos sin perturbación de bordes en los capítulos 3 y 4.

La correlación entre error y dispersión (Figura 5.7 e y f) muestra que no hay grandes mejoras en el análisis de 20 km en comparación con el de 60 km. Por el contrario, promediando horizontalmente la correlación de las figuras mencionadas, se observa una caída de 0.05 en la correlación temporal en el análisis de mayor resolución. Esto lo podemos apreciar por ejemplo en las regiones donde la correlación es negativa en el análisis de 60 km, dado que en las mismas se observa también que la correlación del análisis de 20 km es aun más negativa. Por otro lado, cuando se analizan las diferentes variables por separado, se observa que hay una mejora en la correlación (de 0.038 para el viento zonal, de 0.053 para la temperatura y de 0.028 para la altura geopotencial), salvo para la humedad integrada en la vertical que muestra una degradación de 0.04 en el análisis de 20 km y la presión en superficie que no muestra cambios. Es notable por tanto que a pesar de que las diferentes variables que componen el error en energía muestren una mejora por separado, dicha mejora no se refleje al integrarlas. Este resultado sugiere entonces que desde un punto de vista integral, incrementar la resolución del análisis no es suficiente para lograr una mejor representación de la incertidumbre del análisis. Esto ocurre a pesar de que el modelo en este caso es capaz de representar más adecuadamente el crecimiento de los errores causados por las inestabilidades del sistema, tal como muestra el aumento de

la dispersión. Sin embargo, al comparar las figuras 5.7 e y 5.7 f, observamos que las distribución espacial de las regiones de mayor y menor correlación coinciden. Estos resultados sugieren que un aumento de la resolución del modelo ayuda a reducir el error del análisis y a incrementar la dispersión del ensamble, pero no genera una mejor correspondencia temporal entre ambas variables. Finalmente, analizamos el comportamiento de la IMA que se muestra en la Figura 5.9. En primer lugar, observamos un ciclo diario en el valor de IMA, lo cual se debe al hecho de que la cantidad de observaciones disponible es variable con la hora del día, y esto lleva a fuertes variaciones temporales en el número de observaciones asimiladas. En este caso el valor de inflación para cada ciclo de pronóstico se obtiene a partir del ciclo correspondiente a la misma hora del día anterior. Esto significa que el valor preliminar de inflación para el ciclo de las 00UTC se obtiene a partir de la inflación entrenada del ciclo anterior de las 00UTC. La distribución geográfica de la IMA muestra que los máximos de inflación tienden a ubicarse en las zonas con mayor densidad de observaciones. Esta distribución es consistente con el hecho de que en las regiones con mayor cantidad de observaciones es necesario incrementar la dispersión del ensamble, ya que de lo contrario las observaciones pueden tener un efecto de disminución muy marcado en la dispersión y provocar eventualmente la divergencia del filtro. También se observa que el patrón espacial de IMA guarda cierto parecido a una forma de L invertida similar a la obtenida en los experimentos idealizados sobre Sudamérica, con las regiones de máximos en zonas donde se da el influjo desde los bordes.

5.4 Verificación de la calidad del pronóstico

En esta sección analizamos los errores de los pronósticos inicializados a partir de la media del ensamble de los análisis LETKF 60K y LETKF 20K. Junto con ellos, también verificamos la calidad de los pronósticos inicializados a partir del análisis operativo GDAS. Estos últimos nos permiten poner en contexto la mejora relativa proveniente de incrementar la resolución horizontal del análisis. En este caso como los pronósticos están realizados en la retícula del

LETKF 20K, la verificación de los pronósticos se realiza sobre dicha retícula de 20 km de resolución. Al igual que en la sección anterior realizamos primeramente la verificación utilizando los análisis GDAS como referencia.

En la Figura 5.10 se muestran los errores en energía a 24, 48 y 72 horas de los pronósticos LETKF 60K, LETKF 20K y GDAS. En esta figura podemos apreciar cómo la calidad del pronóstico se degrada a medida que aumenta el plazo de pronóstico. En particular se observa que la magnitud de los errores es mayor en latitudes medias y altas. En efecto, en latitudes mayores tenemos el pasaje de perturbaciones sinópticas que se propagan de oeste a este, cuya amplitud es mayor que en latitudes bajas, y por lo tanto el error crece más rápidamente en este sector del dominio. Solamente un pequeño sector tropical, al este del continente entre 10 y 30°N presenta errores de magnitud similar a los de latitudes medias. Esta zona corresponde, al igual que cuando analizamos la calidad del análisis, a la región en donde se registra el pasaje de ciclones tropicales durante el período del experimento. Si bien son perturbaciones que aparecen en forma esporádica a lo largo del experimento, su magnitud es lo suficientemente grande como para dejar una señal en el campo de errores promediados temporalmente. El patrón espacial de errores presenta también máximos en los bordes, lo cual probablemente esté asociado a errores de las condiciones de borde impuestas cada 6 horas. Otra posible explicación de este hecho es que el modelo global GFS haya tenido una peor performance que el modelo WRF para este período, aunque dicha posibilidad es poco probable, ya que la experiencia general muestra que los modelos globales tienen mejor performance que los modelos regionales cuando la resolución de los mismos es comparable.

Otro aspecto que se observa en la Figura 5.10 es una reducción de los errores en los pronósticos LETKF 20K en comparación con los del LETKF 60K, y a su vez los pronósticos GDAS presentan el menor error entre los 3 sistemas de pronóstico. Esto lo podemos comprobar en la Figura 5.11 que muestra el porcentaje de reducción del EETS promediado verticalmente para los pronósticos LETKF 20K y GDAS con respecto al pronóstico LETKF 60K. En dicha

figura los valores negativos implican una reducción del error del pronóstico. Aquí observamos porcentajes de reducción mayores en el pronóstico GDAS en comparación con el LETKF 20K. Esto es esperable, dado que estamos verificando los pronósticos a partir del análisis GDAS, por lo que esta verificación por sí sola tenderá a favorecer a los pronósticos GDAS. Es interesante notar que las regiones tropicales son las que conservan por mayor tiempo la mejora en la calidad del pronóstico a partir de incrementar la calidad del análisis. En latitudes mayores a 30°N en cambio, la mejora en la calidad del pronóstico se pierde más rápidamente, comenzando a degradarse primero por las esquinas noroeste y noreste, de manera tal que a las 48 horas ya no tenemos grandes diferencias en el error del pronóstico LETKF 20K con respecto al pronóstico LETKF 60K. Para el pronóstico GDAS la mejora en esta región, lejos de los bordes, se mantiene por un poco más de tiempo, aunque a las 72 horas de plazo el área donde la mejora es más evidente se ve muy reducida.

Podemos observar en la Tabla 5.3 el porcentaje de reducción del RMSE en viento, temperatura y presión en superficie de los pronósticos LETKF 20K y GDAS con respecto al pronóstico LETKF 60K. Esta tabla, al igual que la 5.2, está construida utilizando los RMSE promediados espacialmente para cada tiempo, de forma tal de poder utilizar la técnica de bootstrap con 10000 réplicas y una significancia del 1% a fines de testear la significancia de las mejoras encontradas. Para el caso particular de la EETS se muestra la reducción en error cuadrático medio. Los resultados indican que, para las diferentes variables, hay una mejora en la calidad del pronóstico al aumentar la resolución del análisis de 60 a 20 km. Sin embargo, el grado de mejora depende de la variable elegida, dado que los valores más altos se observan en variables como el viento y la energía, los cuales son estadísticamente significativos. En cambio, si bien la temperatura y la presión en superficie muestran una mejora a pesar de que en el análisis los mismos no mostraban una reducción del error, la misma no es significativa. Al mismo tiempo se observa que la mejora del LETKF 20K es significativa sólo a plazos de 24 horas. Por su parte los pronósticos GDAS muestran una mejora que es entre 2 y 4 veces mayor que la del LETKF 20K según la variable verificada. Como

consecuencia de esto, la significancia de las mejoras persiste por mucho más tiempo, llegando hasta las 72 horas en la energía y el viento. En cambio, las variables de temperatura y presión en superficie tienen una mejora cuya significancia no va más allá de las 48 horas de plazo.

Los resultados encontrados para los pronósticos LETKF 20K en comparación con los pronósticos LETKF 60K pueden explicarse a partir la escala de variabilidad de las diferentes variables. En efecto, tal como mencionamos previamente, variables como el viento o la humedad tienen una escala de variabilidad más corta, de manera que el aumento de la resolución en la condición inicial ayuda a representar mejor dichas variables. Esto no ocurre con las variables de masa, que tienen escalas de variabilidad más largas, y por lo tanto la mayor resolución del análisis producido con una escala de localización menor, no permite obtener una mejora significativa en dichas variables.

Un último punto a destacar de esta verificación es el hecho que a medida que aumenta el plazo de verificación los errores crecen en todos los pronósticos. Esto significa que las mejoras en la condición inicial de los pronósticos LETKF 20K y GDAS se ven desdibujadas por el crecimiento de las diferentes fuentes de error, asociadas por ejemplo a las imperfecciones del modelo y/o de las condiciones de borde.

	EETS		U		V		T		PSFC		PH		Q	
Plazo	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS
24	5.64	22.19	5.31	21.14	4.72	19.19	2.44	20.03	2.93	20.17	0.14	12.71	9.74	29.75
48	2.85	10.02	2.17	8.91	2.62	9.79	1.91	7.45	1.81	8.48	1.34	4.92	5.29	13.68
72	1.64	5.74	1.46	5.41	1.16	5.28	1.25	2.62	2.16	5.61	1.26	1.10	2.60	5.47

Tabla 5.3: Ídem Tabla 5.2 para los pronósticos LETKF 20K y GDAS con respecto a los pronósticos LETKF 60K a 24, 48 y 72 horas, tomando el análisis GDAS como referencia. Valores negativos indican reducción y positivos incremento en los errores de las diferentes variables. En negrita se indican los valores estadísticamente significativos con una significancia del 1%.

La verificación de los pronósticos que hemos realizado hasta aquí tiene la ventaja que permite verificar la calidad de los mismos para cualquier variable en todos los puntos del modelo. Sin embargo, esta verificación tiene dos desventajas que son importantes. La primera es que estamos verificando tomando un análisis operativo como referencia, que si bien se la considera como más cercana a la realidad, no deja de tener errores, tal como mencionamos en la verificación de la calidad del análisis. La segunda gran desventaja es que esta verificación tenderá a favorecer a los pronósticos GDAS, dado que los mismos son inicializados a partir de dichos análisis. En consecuencia, dichos pronósticos partirán con un error inicial de 0 según esta verificación. Por lo tanto, podría ocurrir que la mejora encontrada en los pronósticos GDAS en comparación con los pronósticos LETKF esté al menos parcialmente aumentada por el análisis de referencia que estamos utilizando. De hecho, en la bibliografía se encuentra que si se realiza el ejercicio verificar la calidad de un conjunto de pronósticos con respecto a un análisis operativo, es muy probable que el mejor pronóstico resultante sea aquel que fuera inicializado con el análisis que se utiliza para verificar.

Este hecho nos pone entonces en la necesidad de complementar la verificación realizada mediante la comparación de los pronósticos con respecto a una base de datos independiente. En nuestro caso, sólo tenemos disponibles las observaciones que se utilizan para la asimilación. De esta manera, podemos aprovechar el hecho de que al verificar pronósticos, las observaciones contra las cuales se compararán los mismos aún no han sido utilizadas para generar los respectivos análisis. Sólo en el caso de que verifiquemos la calidad de la condición inicial esta comparación no sería válida, ya que tanto los datos que estamos utilizando para la comparación como los respectivos análisis no serían independientes. Por lo tanto, a continuación procederemos a verificar la calidad de los pronósticos a partir de las observaciones.

Con todo, esta verificación tiene un par de desventajas. La primera está relacionada con el hecho de que la distribución espacial y temporal de las observaciones es muy irregular y abarca sólo algunas regiones del dominio. La

otra cuestión que puede resultar problemática es que en nuestro caso esta verificación podría favorecer a los pronósticos LETKF. Esto podría ocurrir por el hecho de que si bien las observaciones ingresaron en los 3 análisis, en el caso del GDAS se agregaron los datos de radianzas de satélite. En consecuencia, los análisis LETKF podrán estar mejor ajustados a las observaciones asimiladas en nuestro experimento, y esto podría darles una ventaja inicial con respecto a los pronósticos GDAS.

Esta discusión nos lleva por tanto a concluir que las dos verificaciones son necesarias. Si bien ambas tienen puntos débiles y limitan la validez de las conclusiones que se pueden extraer de las mismas, al complementar ambas verificaciones se puede dar mayor validez a los resultados encontrados. Esto no sólo permite arribar a conclusiones más robustas en cuanto a la calidad de los pronósticos, sino que en cierto punto también ayuda a que la verificación de los análisis realizada en la sección anterior tenga una mayor validez.

En este caso se utilizan todas las observaciones asimiladas en este experimento, y se verifica la calidad del pronóstico desde el tiempo inicial hasta las 72 horas de plazo. Si bien mencionamos anteriormente que no sería válido verificar el análisis con respecto a las observaciones, esta verificación la realizamos a fines de comprender mejor los resultados obtenidos. Dado que las observaciones vienen dadas en intervalos de una hora y debido a que su número es altamente variable de una hora a la siguiente, agrupamos las observaciones en ventanas de 6 horas. De esta manera, para la verificación a 6 horas de plazo se utilizan todas las observaciones disponibles entre las 3 y 9 horas de plazo de pronóstico. La excepción a esto lo constituyen el tiempo inicial que considera solamente las observaciones asimiladas en el análisis, y el período comprendido entre las 69 y las 72 horas, que comprende un período de 3 horas.

El número medio de observaciones utilizadas para la verificación viene dado en la Tabla 5.4, la cual nos muestra el número medio de observaciones por ciclo de pronóstico discriminado por niveles verticales. Debemos mencionar aquí que el número tiene en cuenta los diferentes plazos de pronóstico, que en

nuestro caso son 13, incluyendo el tiempo del análisis. Esto significa entonces que la verificación será más robusta para las variables y niveles verticales en donde haya un mayor número de observaciones, como por ejemplo para el viento en niveles cercanos a superficie y en la troposfera alta, o la temperatura en la troposfera alta. El número total medio de observaciones de presión en superficie verificadas por ciclo de pronóstico es de 333.

Nivel	U	V	T	Q
1000	3442	3457	192	243
900	669	669	477	353
800	105	105	0	322
700	139	139	302	121
600	99	99	305	376
500	163	163	305	446
400	263	263	306	448
300	683	684	648	693
200	756	755	765	619
100	636	635	1920	1020
Total	6955	6969	5220	4641

Tabla 5.4: Número medio de observaciones por ciclo de pronóstico y nivel vertical de las variables viento zonal y meridional, temperatura y humedad.

Los resultados de la verificación utilizando las observaciones asimiladas se presentan en la Figura 5.12, la cual muestra el RMSE medio para el viento, la temperatura y la humedad específica pronosticados a 24 horas en diferentes niveles verticales. La magnitud de los errores es muy similar en los tres pronósticos, y en general se aprecia que el orden del mejor pronóstico al peor es el mismo en todas las variables. Esto es, el mejor de todos los pronósticos es el GDAS, seguido por el LETKF 20K y por el LETKF 60K. En particular se observa que el LETKF 20K supera al LETKF 60K en todas las variables, mientras que el GDAS es mejor que el LETKF 20K en el viento y la humedad específica (Figura 5.12 a, b y d). Para la temperatura en cambio observamos que el pronóstico LETKF 20K es mejor que el GDAS entre 600 y 100 hPa, mientras que en niveles más bajos los pronósticos GDAS son ligeramente

mejores (Figura 5.12 c). Este resultado se ve reflejado en la Tabla 5.5 que muestra el porcentaje de mejora relativa del pronóstico LETKF 20K y GDAS con respecto al LETKF 60K utilizando las observaciones. En dicha tabla se observa que las mejoras en temperatura son muy similares en ambos pronósticos, a diferencia de lo que indica la comparación con los análisis GDAS (ver Tabla 5.4).

	U		V		T		q		PSFC	
Plazo	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS	LETKF 20K	GDAS
24	3.80	9.11	2.90	8.54	1.41	0.67	4.41	7.85	4.51	13.05
48	2.46	5.75	1.92	5.97	1.08	1.57	2.61	4.64	3.31	10.55
72	1.71	4.28	1.04	3.47	0.54	1.19	0.39	1.57	0.38	6.27

Tabla 5.5: Ídem Tabla 5.4, verificando a partir de las observaciones asimiladas.

Para completar la verificación a diferentes plazos, la Figura 5.13 muestra el RMSE medio para todos los plazos de pronóstico para el viento zonal, presión en superficie, temperatura y humedad específica. Para el caso del viento meridional, los resultados son muy similares a los del viento zonal. En este caso se repite el mismo cuadro de la figura anterior, en el cual encontramos al pronóstico GDAS como el mejor de los 3, seguido en segundo lugar por el pronóstico LETKF 20K. Si comparamos los pronósticos en las diferentes variables, notamos que las diferencias entre los mismos son más evidentes para el viento (Figura 5.13a) y la humedad específica (Figura 5.13d), y en menor medida para la presión en superficie (Figura 5.13b). En cambio, para la temperatura prácticamente no se observan diferencias entre los pronósticos, tal como observamos en la Figura 5.12c. Esto se ve también reflejado en la Tabla 5.5, la cual muestra por ejemplo que para el viento, las mejoras en el pronósticos LETKF 20K son significativas a plazos de hasta 24 horas, mientras que para los pronósticos GDAS la significancia de la mejora alcanza a las 72 horas. En cambio, para la presión en superficie y la humedad específica las mejoras no son significativas para el LETKF 20K, aunque sí lo son para el

pronóstico GDAS en plazos de hasta 24 horas en el caso de la humedad específica y de 48 horas para la presión en superficie. Finalmente para la temperatura, las mejoras de los pronósticos LETKF 20K y GDAS con respecto a los pronósticos LETKF 60K no son significativas, amén de que son de una magnitud mucho menor.

Un detalle interesante que nos muestra la Figura 5.13 es el error del tiempo del análisis del LETKF 20K en las diferentes variables. En efecto, se aprecia aquí que el análisis de 20 km se ajusta mejor a las observaciones asimiladas que el de 60 km. Asimismo, se aprecia que su ajuste inicial es tan bueno como el análisis GDAS, y que en el caso particular de la temperatura el ajuste de los análisis LETKF es mejor que el GDAS. Sin embargo, a pesar del mejor ajuste inicial a las observaciones del análisis de 20 km, observamos 6 horas más tarde que los errores del pronóstico del LETKF 20K son más cercanos al LETKF 60K. Este comportamiento podría ser evidencia de la presencia de un desbalance en el análisis de 20 km, más aun si se tiene en cuenta que el pronóstico GDAS no muestra un acercamiento al pronóstico LETKF 60K y que en este plazo puede diferenciarse de los pronósticos LETKF, a pesar de utilizar el mismo modelo. Este comportamiento no sería extraño de observar teniendo en cuenta que al utilizar una menor escala de localización el análisis es más proclive a sufrir desbalances entre los campos de las diferentes variables. Para poder confirmar esta hipótesis habría que hacer uso de pruebas diagnósticas especialmente diseñadas para estudiar el balance del análisis. Dicho análisis se puede realizar utilizando variables como la segunda derivada de la presión en superficie (Houtekamer y Mitchell, 2005) o las componentes rotacionales del viento (Caron y Fillion, 2010). La cuestión de la localización en los sistemas de asimilación es una pregunta abierta dentro del ámbito científico, y que en nuestro caso deja abierta la posibilidad de aplicar otras técnicas de asimilación con localización multi-escala como la de Kondo y Miyoshi (2013), por ejemplo.

Los resultados encontrados en esta verificación corroboran que, salvo para la temperatura, los resultados encontrados en la verificación realizada previamente en base a los análisis GDAS asumiendo que los mismos eran más

cercanos a la realidad apuntan en la dirección correcta. Es decir que ratifican los resultados obtenidos en la verificación realizada utilizando el GDAS como referencia. Completamos la verificación comparando los pronósticos de precipitación acumulada en períodos de 12 horas. En este caso, la información utilizada para llevar a cabo la verificación proviene de las estimaciones satelitales “CPC Morphing Technique” (CMORPH, Joyce y otros, 2004). Estos datos constituyen un análisis global de precipitación y son el resultado de la combinación de técnicas de estimación de precipitación provenientes de diferentes satélites que miden en el canal de las microondas y el infrarrojo térmico. Esta base de datos está disponible desde diciembre de 2002 hasta el presente en diferentes resoluciones horizontales y temporales. La más alta es de aproximadamente 8 km con una resolución temporal de 30 minutos. En nuestro caso, utilizamos la base de datos con una resolución espacial de 0.25° y una resolución temporal de 3 horas por ser la más cercana a la resolución espacial de los pronósticos. Esta información es interpolada a la retícula del experimento LETKF 20K y agrupada en períodos de 12 horas para poder comparar con los respectivos pronósticos.

La verificación en este caso se basa en el cálculo de dos índices básicos y típicamente utilizados en la verificación de los pronósticos de precipitación. El primero de estos índices es el bias en frecuencia, el cual mide el grado de subestimación o sobrestimación de la frecuencia de ocurrencia de precipitación por encima de un determinado umbral (ver Apéndice). El segundo índice que utilizaremos es el Equitable Threat Score (ETS), el cual mide el grado de correspondencia espacial y temporal entre la precipitación pronosticada y observada (ver Apéndice). Estos índices se calculan para los umbrales de 1, 10, 50, 100 y 200 mm de precipitación acumulada en períodos de 12 horas.

Los resultados de la verificación de los pronósticos de precipitación aparecen en la Figura 5.14, que muestra el bias y el ETS para los umbrales de 1, 10 y 100 mm. En general notamos que los 3 pronósticos presentan una sobreestimación del área de precipitación, dados los valores de bias mayores a 1 en los 3 umbrales seleccionados. Vemos además que la magnitud de la

sobreestimación es mayor a medida que aumenta el plazo de pronóstico. Dado que los 3 pronósticos tienen valores similares de bias, podríamos atribuir este comportamiento más a errores propios del modelo WRF que a la calidad del análisis. No obstante, no debemos perder de vista que las estimaciones satelitales también pueden sufrir de errores sistemáticos en este caso. Con respecto al ETS, podemos deducir también que los errores del modelo condicionan los resultados, dado que los valores de ETS también son muy similares entre los pronósticos. Sin embargo, tanto en el bias como en el ETS, podemos distinguir que los pronósticos GDAS son levemente mejores que los pronósticos LETKF, dado que sus valores de bias son los más cercanos a 1 y los de ETS son los más altos. Esto se da en todos los plazos y umbrales, a excepción del plazo de las 12 horas en los umbrales más altos en donde el LETKF 20K supera al pronóstico GDAS. En general la mejora en el pronóstico de precipitación GDAS con respecto al LETKF 60K es significativa hasta las 72 horas de plazo, según un método bootstrap con 10000 réplicas y una significancia del 1%. Entre los dos pronósticos LETKF, encontramos que el LETKF 20K es levemente mejor que el LETKF 60K, aunque dicha mejora es significativa hasta las 48 horas de plazo de pronóstico. Si observamos umbrales de precipitación mayores, como por ejemplo 150 mm, encontramos que los pronósticos LETKF 20K son levemente mejores que los pronósticos GDAS. Estos casos se corresponden a precipitación asociada a ciclones tropicales. Sin embargo, las diferencias entre los pronósticos no son estadísticamente significativas. Por todo lo expuesto, podemos ver que la verificación de la precipitación arroja esencialmente los mismos resultados que la verificación de las demás variables.

5.5 Verificación de los pronósticos de ciclones tropicales

Una de las potenciales ventajas de disponer de un análisis en más alta resolución es que en principio provee un campo inicial más apropiado para inicializar un modelo en alta resolución y por ende, el pronóstico resultante del mismo debería ser más certero, especialmente cuando estamos interesados en

eventos en donde los procesos de pequeña escala (por ejemplo la convección) son importantes. En el dominio en el que estamos trabajando uno de los fenómenos de mayor impacto por sus consecuencias asociadas y que está relacionado con procesos de pequeña escala, son los ciclones tropicales o tifones. Estos sistemas constituyen un ejemplo de convección organizada, y por lo tanto proveen una oportunidad para evaluar en qué medida contar con un análisis en mayor resolución resulta en un mejor pronóstico de un evento de alto impacto en la sociedad. Por otro lado, dado que los resultados generales de la verificación de los pronósticos en base al análisis GDAS muestran que a grandes rasgos el LETKF 20K tiene un mejor desempeño que el LETKF 60K en la región de los tifones (ver Figura 5.11 a, c y e), podemos verificar hasta qué punto dicha mejora se ve reflejada en los pronósticos de los ciclones tropicales en particular.

Un punto muy importante a tener en cuenta es que esta verificación realizada para los ciclones tropicales nos dará apenas una primera noción acerca del grado de mejora en el pronóstico de eventos de pequeña escala. En efecto, si bien en un ciclón tropical la convección es un proceso dominante, gran parte de la evolución de un sistema de este tipo está determinado también por la gran escala (por ejemplo la posición relativa del ciclón con respecto a otros sistemas sinópticos determinará la trayectoria del mismo, mientras las condiciones de corte vertical que están determinadas por la escala sinóptica y las condiciones oceánicas tendrán impacto en la intensidad del ciclón). Estos aspectos propios de la escala mayor deberían ser más fácilmente representados por los respectivos análisis. No obstante, existen procesos de menor escala que también son muy importantes en la intensidad de un ciclón tropical (por ejemplo, la dinámica asociada al proceso de cambio y formación del ojo del ciclón), y que tienen un grado de predictibilidad mucho menor. Asimismo, existen también eventos de alto impacto que están asociados a convección no organizada, los cuales tienen una predictibilidad menor en comparación con un ciclón tropical. Es de esperar por lo tanto que en tales casos, el hipotético grado de mejora del análisis y su posterior pronóstico sea menor que el obtenido en nuestro caso particular.

En nuestra muestra disponemos de 3 eventos de ciclones tropicales que ocurrieron durante el período del experimento. Los 3 ciclones tropicales son Sinlaku, Hagupit y Jangmi. Para cada uno de los 3 casos se utilizó una técnica de verificación orientada a objetos (Davis, 2005 a y b), en la cual se define al ciclón tropical como un objeto a seguir en los diferentes pronósticos y del cual se definen determinados parámetros o características. En nuestro caso, para los diferentes pronósticos en cada ciclón tropical, nos focalizaremos en 3 parámetros: posición, presión mínima del ciclón y viento máximo asociado. De esta manera, verificaremos los pronósticos de trayectoria, profundidad e intensidad de cada ciclón tropical. La información utilizada en este caso como la observación contra la cual comparar los pronósticos corresponde al Centro Regional de Meteorología encargada de la predicción de tifones en el área del Pacífico Norte, ubicada en la ciudad de Tokio (Regional Specialized Meteorological Center (RSMC) Tokyo-Typhoon Center).

En las figuras 5.15, 5.16 y 5.17 se muestran los resultados de la verificación realizada para los tifones Sinlaku, Hagupit y Jangmi, respectivamente. Estas figuras muestran por un lado la trayectoria, la presión mínima y el viento máximo de cada tifón cada 6 horas, estimado por el RSMC y por los respectivos análisis durante su ciclo de vida (gráficos a, c y e, respectivamente). Al mismo tiempo se muestran los errores medios en ubicación, y el RMSE en profundidad e intensidad para los respectivos pronósticos a diferentes plazos de pronóstico (gráficos b, d y f, respectivamente).

Comenzando por los errores en trayectoria y ubicación del ciclón, notamos que los errores varían con el ciclón verificado. Para el caso de Sinlaku tenemos el menor error en localización, en donde por lo general los errores son muy similares entre los 3 pronósticos, con una pequeña ventaja del LETKF 20K para plazos mayores a las 48 horas (Figura 5.15 a y b). Para los casos de Hagupit y de Jangmi en cambio, notamos que tanto el análisis como el pronóstico GDAS tienen el menor error en comparación con los análisis y pronósticos LETKF (Figura 5.16 y 5.17 a y b). En el caso de Hagupit existen ciertos problemas en

reconocer el sistema ciclónico para el análisis LETKF 60K en su etapa inicial, cuando el sistema consiste en una amplia zona de baja presión, con varios mínimos, lo cual provoca que el algoritmo de tracking del sistema tenga problemas en determinar la posición del mínimo (Figura 5.16 a). En el caso de Jangmi, notamos que la mayor discrepancia de la trayectoria en los análisis LETKF con el análisis GDAS y con las observaciones se da a su paso por la isla de Taiwán y en su posterior re-curvatura hacia el norte (Figura 5.17 a). Podemos ver que para estos casos los pronósticos GDAS superan a los pronósticos LETKF.

Cuando verificamos la intensidad y la profundidad de los ciclones tropicales encontramos en primer lugar que tanto el análisis como el pronóstico GDAS subestiman sistemáticamente la intensidad y profundidad del ciclón, y por lo tanto su error es mayor comparado con los errores de los LETKF (Figuras 5.15-5.17 c, d, e y f). Esto se debe a que la resolución horizontal del análisis GDAS utilizado en estos experimentos es de 1° , de manera que al interpolar los campos de la retícula original a la del LETKF 20K, el campo inicial del pronóstico GDAS presenta un ciclón de menor profundidad comparado con el de los análisis LETKF. Esto lo podemos corroborar en la Figura 5.18 que nos muestra el campo inicial del ciclón tropical Jangmi para los pronósticos GDAS y LETKF correspondientes al ciclo de las 12UTC del 26 de septiembre, y la estructura de dicho sistema pronosticada 24 horas más tarde. Este período corresponde con un período de rápida intensificación del tifón. Aquí se aprecia que la profundidad inicial del ciclón es diferente para los 3 pronósticos, y si bien los 3 pronósticos tienen la misma resolución horizontal y por ende son capaces de representar ciclones de intensidades similares, el de los pronósticos LETKF es más intenso y profundo que el del GDAS en los primeros plazos de pronóstico. Esta diferencia en intensidades continua observándose hasta plazos de 24 horas (Figura 5.18 d-f). Este comportamiento, que se da en otros ciclos de pronóstico y para los restantes casos analizados aquí, explica el mayor error en los primeros plazos de pronóstico de los pronósticos GDAS hasta que la intensidad del mismo se acerca a la de los LETKF a plazos mayores a las 36 horas. Este hecho no se contradice con lo encontrado anteriormente cuando

verificamos los pronósticos en relación al menor error de los pronósticos GDAS para la presión en superficie o viento. Esto es así por el hecho de que los errores cuadráticos medios son el resultado de errores en la posición, intensidad y forma de los diferentes fenómenos presentes en un campo escalar (Ebert y Mc Bride, 2000). En el caso particular de los ciclones tropicales, los pronósticos GDAS producen tormentas que son sistemáticamente más débiles que en los pronósticos LETKF. Sin embargo, la posición de dichos sistemas está mejor pronosticada, lo cual produce un valor de error cuadrático medio menor que en los pronósticos LETKF. Si comparamos los pronósticos de intensidad y profundidad entre el LETKF 20K y el LETKF 60K, notamos que el primero tiene en promedio menor error, tanto en intensidad como en profundidad para el tifón Sinlaku (Figura 5.15 d y f), y en intensidad para el caso de Jangmi (Figura 5.17f). En cambio para el caso de Hagupit se observa que el pronóstico LETKF 60K es mejor en predecir la profundidad del sistema (Figura 5.16 d), mientras no se aprecian grandes diferencias entre ambos pronósticos en lo que respecta a intensidad (Figura 5.16 f). Este resultado sugiere que si bien podría haber una mejora en el pronóstico de intensidad del ciclón a partir de un análisis mejor definido gracias a su mayor resolución, dicha mejora no se observó en estos experimentos. Un detalle interesante que surge de esta verificación es que la calidad del pronóstico de intensidad y profundidad es peor en la medida en que el ciclón tropical es más intenso. Esto es atribuible a dos factores: uno vinculado directamente con la resolución del modelo, y el otro al crecimiento no lineal de los errores dentro del sistema que afecta a la calidad del análisis. El primero de dichos factores lo podemos observar al comparar la profundidad del sistema representado en los 3 pronósticos a 24 horas de la Figura 5.18 con la presión indicada según la estimación del RSMC. Podemos observar aquí que la profundidad del tifón está claramente subestimada en los 3 pronósticos. Esto se debe a que la resolución horizontal del modelo de 20 km no alcanza a representar adecuadamente los procesos relacionados con la dinámica del ojo del ciclón, los cuales son de una escala espacial menor a la resuelta por el modelo y son muy importantes en ciclones intensos. Por lo tanto, no es de extrañar que los pronósticos tengan errores

importantes a la hora de representar la profundidad e intensidad, especialmente cuando se trata de ciclones tropicales intensos. Sin embargo, en este caso particular tampoco el análisis del LETKF 20K representa mejor la intensidad y profundidad del sistema en comparación con el LETKF 60K. Por el contrario, el campo inicial del LETKF 60K muestra un ciclón más intenso que el LETKF 20K (Figura 5.18 b y c). Esto indica que ni siquiera en el análisis se encuentra una ventaja de la mayor resolución, al menos en este caso correspondiente a un ciclón tropical intenso. La explicación a este hecho puede estar en que bajo tales condiciones, las hipótesis de linealidad del Filtro de Kalman no se cumplen y por lo tanto es esperable que el análisis en estos casos no sea capaz de representarlos adecuadamente. Esto suele ocurrir en situaciones de desarrollo de convección o bien cuando tenemos la rápida intensificación de un ciclón tropical. Como consecuencia de esto, para que el Filtro de Kalman pueda representar adecuadamente la aparición de una nueva perturbación de rápido crecimiento dentro del sistema, se requiere de un tiempo de spin-up dentro del filtro, el cual puede ser demasiado largo para que un pronóstico que se derive de dicho análisis sea de real utilidad. Por este motivo, se han desarrollado técnicas que buscan acelerar los tiempos de spin-up dentro del análisis. Una de estas técnicas es la desarrollada por Kalnay y Yang (2008, 2010), denominada RIP (del inglés “Running in Place”), la cual realiza sucesivas correcciones al análisis en forma iterativa mediante un suavizado de Kalman (denominado comúnmente Kalman smoother) y asimilando las mismas observaciones en cada iteración. Esta implementación fue probada para un caso particular de un tifón con resultados satisfactorios (Yang y otros, 2012). En nuestro caso, al no haberse aplicado técnica alguna para acelerar la convergencia del filtro a las observaciones, el crecimiento no lineal de los errores (que se da cuando los procesos están dominados por la inestabilidad convectiva) hace que la ventana de asimilación de 6 horas sea demasiado larga para mantener al análisis cerca del estado real. Como consecuencia de esto, los análisis utilizados aquí no son capaces de representar adecuadamente la intensidad del tifón cuando el mismo es de gran intensidad. Una vez que se inicializan los respectivos pronósticos y se supera el

plazo de spin-up, el error en intensidad decrece durante las primeras 12 a 24 horas de pronóstico tal como muestran las Figuras 5.15, 5.16 y 5.17 d, más no alcanza nunca a representar la intensidad del ciclón debido a la limitación del modelo. Estos resultados indican que si bien aumentar la resolución horizontal del análisis es necesario en vistas de mejorar la capacidad de predecir eventos de alto impacto como un ciclón tropical, el sólo hecho de incrementar la resolución en el rango entre 60 y 20 km no es suficiente para alcanzar tal fin.

En líneas generales observamos que un análisis operativo global parece proveer mejores condiciones iniciales para pronosticar eventos de alto impacto. Este resultado puede deberse a una serie de factores. Uno de ellos está vinculado con el hecho de que el análisis GDAS es un análisis operativo y por tal motivo, el volumen de información asimilada es mucho mayor que en estos experimentos, tal como mencionamos anteriormente. La principal diferencia en el volumen de información asimilada proviene, como ya hemos mencionado anteriormente, de los datos provenientes de radianzas medidas por satélite. Diversos estudios, como por ejemplo el de Liu y otros (2012) quienes trabajaron con un EnKF regional de 36 km de resolución, muestran que la inclusión de datos de radianzas medidas por satélite son de vital importancia para la mejora en el pronóstico tanto de trayectoria como de intensidad de los ciclones tropicales. En particular, los autores encontraron que utilizar datos de radianzas junto con estimaciones satelitales de viento ayuda a la mejora de la calidad del pronóstico a plazos mayores a 36 horas. El hecho de que en nuestro caso los pronósticos GDAS subestimen la intensidad de los ciclones tropicales debido a la resolución horizontal de los datos utilizados, y al mismo tiempo provean una mejor localización del sistema refuerza la idea acerca de la importancia de la inclusión de los datos de radianza en la asimilación. Al mismo tiempo, la mejora en la calidad del análisis y del pronóstico de ciclones tropicales a través del aumento de la resolución horizontal puede ser limitada, tal como indican los resultados encontrados por Holt y otros (2013). En dicho estudio los autores trabajan en un EnKF regional alimentado en los bordes por un EnKF global de 200 km de resolución horizontal. El objetivo de dicho trabajo es analizar en qué medida la

utilización de un análisis regional de mayor resolución que el análisis global mejora la calidad de la representación de los ciclones tropicales. Los autores encuentran que la mejora es significativa sólo cuando la resolución horizontal del modelo aumenta de 200 a 100 km. En cambio en resoluciones horizontales entre 100 y 36 km las mejoras no son muy importantes. En nuestro caso, el aumentar la resolución de 60 a 20 km tampoco obtiene grandes mejoras en la representación de los ciclones tropicales, sino que posiblemente sea necesario implementar otras técnicas adicionales para sacar provecho de la mayor resolución.

Capítulo 6: Conclusiones y perspectivas futuras

6.1 Resumen y aspectos sobresalientes de los resultados

La presente Tesis se ha desarrollado con el objetivo de evaluar un sistema de análisis-pronóstico basado en el LETKF y el modelo WRF a nivel regional. La implementación de un sistema de este tipo, tal como se planteó en la Introducción, es de vital importancia para el desarrollo y mejora de la capacidad de pronóstico en Argentina y en América del Sur, por todas las ventajas que del mismo se derivan, como por ejemplo la mejora en la capacidad de anticiparse a diferentes eventos meteorológicos que puedan tener mayor impacto sobre la sociedad. Teniendo en cuenta la escasa experiencia local en la asimilación de datos, esta Tesis representa un paso fundamental en busca de recorrer el camino hacia la implementación del sistema propuesto.

Dentro de este objetivo general, el estudio de esta Tesis se centró en dos aspectos principales de la asimilación de datos. El primero estuvo relacionado con las cuestiones prácticas y las posibles problemáticas relacionadas con la implementación del sistema regional de análisis-pronóstico propuesto. En particular se hizo especial hincapié en las fuentes de error presentes en un sistema de este tipo y su posible tratamiento en busca de mitigar sus efectos sobre la calidad del análisis. Las fuentes de error analizadas aquí fueron las relacionadas con las imperfecciones del modelo y con las de las condiciones de borde lateral. El segundo objetivo de esta Tesis por su parte, se enfocó en estudiar el impacto de la resolución horizontal del modelo en la calidad del análisis y de los pronósticos obtenidos a partir de dichos análisis.

Para llevar adelante el primer objetivo de esta Tesis trabajamos en un entorno idealizado en el cual se conoce la evolución real del sistema y en el cual se introducen las fuentes de error propuestas. Primeramente nos planteamos el escenario más idealizado posible en el cual tanto el modelo como las condiciones de borde no están afectados por errores. En dicho escenario, estudiamos el impacto producido por la asimilación de las observaciones sobre la calidad del análisis. Si bien en gran medida las condiciones de borde ejercen

un importante control sobre la calidad del análisis, la asimilación de observaciones provocó un impacto positivo apreciable sobre la calidad del análisis, incluso en este caso en el que el número de observaciones asimiladas es muy pequeño si lo comparamos con la cantidad de observaciones asimiladas en sistemas reales. Este hecho demostró la importancia y la necesidad de la asimilación. Otro aspecto notable de este experimento está relacionado con el comportamiento del algoritmo de IMA implementado. Si bien dicho algoritmo requirió de un tiempo de entrenamiento extenso (del orden de los 16 meses) para lograr su convergencia y ayudar al ensamble a representar adecuadamente las inestabilidades del flujo en la mayor parte del dominio, en ciertos sectores del dominio su convergencia no fue alcanzada. Esto se observó especialmente sobre la región de la cordillera de los Andes, en donde también se detectó un déficit sistemático de la dispersión del ensamble. Este comportamiento particular, con diferente intensidad, también se observó en los siguientes experimentos.

Cuando se introducen errores en el modelo, en particular en la forma en cómo se representan los efectos de los procesos de escala sub-reticular (i.e: en las parametrizaciones físicas utilizadas por el modelo), aparecen errores en el análisis que presentan ciertas particularidades. Los errores se ven especialmente amplificados en las regiones donde el flujo es más inestable, esto es, sobre las regiones de convección activa en latitudes bajas y en latitudes medias donde se da el desarrollo de ondas baroclínicas. Asimismo, dicho aumento del error está explicado principalmente por un incremento de su componente sistemática. Si bien el algoritmo de IMA está pensado para compensar en el ensamble la falta de dispersión provocada por los errores del modelo, en general su implementación no consiguió paliar los efectos producidos por las deficiencias del modelo.

Esto se debe a que la IMA modifica la magnitud pero no la estructura de la matriz de covarianza de los errores del campo preliminar. Por su parte los errores del modelo modifican la estructura de la matriz de covarianza de los errores del pronóstico y a su vez introducen errores sistemáticos que rompen

con las hipótesis sobre las que se basan los métodos de asimilación. Este hecho obligó a buscar otras formas de considerar la posible estructura de los errores de la matriz de covarianza y al mismo tiempo reducir el bias en vistas de aproximarse lo más posible a las hipótesis del KF. Es por esto que se implementó el tratamiento de ensamble físico. Es decir, se introdujeron diferentes parametrizaciones físicas en el ensamble con el fin de representar dentro del mismo dichas fuentes de error. Los resultados obtenidos con esta implementación fueron muy positivos y en gran medida coincidentes con lo encontrado por otros autores (como por ejemplo Meng y Zhang, 2008 a y b, Dillon y otros, 2016 y Otsuka y Miyoshi, 2015). Asimismo, dado que la utilización de diferentes configuraciones/parametrizaciones mejora la estructura de la matriz de covarianza estimada a partir de los miembros del ensamble, la IMA resulta ser menor puesto que la dispersión del ensamble se acerca más a la magnitud de las diferencias entre el campo preliminar y las observaciones. No obstante esto, los resultados encontrados sugieren que la implementación de una técnica de remoción del bias podría repercutir en un beneficio aún mayor en pos de reducir el error del análisis.

En el caso en que las condiciones de borde lateral representan la fuente de error del modelo, los errores tienden a amplificarse principalmente en latitudes medias y altas. La causa de dicho aumento obedece principalmente al hecho de que el flujo de latitudes extra-tropicales está dominado por el sucesivo pasaje de ondas baroclínicas, las cuales se propagan más rápidamente en el interior del dominio en dicha franja latitudinal debido a que el flujo básico es más intenso. Asimismo, la amplitud de estas perturbaciones en latitudes medias es mayor que en latitudes bajas. En consecuencia, la calidad del análisis se ve más afectada en los extra-trópicos, en donde el crecimiento del error está explicado principalmente por su componente no sistemática.

En vista de estos resultados, es evidente que para paliar el efecto producido por los errores en las condiciones de borde es necesario implementar alguna técnica de perturbación de las condiciones de borde. Dentro de los diferentes métodos de perturbación de bordes propuestos por Torn y otros (2006),

elegimos el de perturbaciones al azar a partir de una climatología. Los resultados obtenidos con esta implementación fueron muy positivos. Esto permite pensar que en el caso de utilizar un ensamble global para representar la incertidumbre en las condiciones de borde, el grado de mejora en la calidad del análisis puede ser aún mayor.

Finalmente, cuando se incluyen las dos fuentes de incertidumbre al mismo tiempo en el sistema, los errores en general reproducen un patrón que se parece esencialmente a una suma de los errores producidos por las imperfecciones del modelo y por los errores en los bordes por separado. En este caso se vuelve imperativo introducir el tratamiento de representación de las fuentes de error, como las propuestas en esta Tesis por ejemplo. En este sentido, la sola implementación de la técnica de IMA no es suficiente para representar en el ensamble las fuentes de incertidumbre del sistema.

Estos resultados son los que en general se observan en las diferentes variables meteorológicas analizadas, aunque con ciertas particularidades en cada una de ellas. En general, la mayoría de las variables meteorológicas como la temperatura o el viento reaccionan de forma similar a la descrita anteriormente ante las diferentes fuentes de error, y tienden a ser sub-dispersivas dentro del ensamble. Pero por otro lado, la humedad específica presenta un comportamiento particular, ya que por un lado es una variable que suele presentar sobre-dispersión dentro del ensamble, al mismo tiempo que su sensibilidad frente a las fuentes de error es diferente a las demás variables. Por su parte la precipitación mostró escasa respuesta ante las diferentes fuentes de error introducidas, lo cual respondió en gran medida al hecho de que fue una variable no asimilada en nuestros experimentos. Este hecho muestra la importancia de asimilar información de precipitación, más aun teniendo en cuenta la importancia que tiene dicha variable para modelos de suelo por ejemplo.

Dado el contexto de trabajo habitual del análisis – pronóstico operativo, en donde están presentes fuentes de error de orígenes diversos, el hecho de que el error del análisis pueda crecer más de 10 veces a causa de los mismos es un

resultado a destacar. En efecto, si se pretende en el futuro implementar un sistema de análisis-pronóstico operativo a escala regional, es de vital importancia adoptar estrategias en la construcción del ensamble que tengan en cuenta todas las fuentes de error analizadas en esta Tesis. En general, utilizar estrategias simples y de fácil implementación como las adoptadas en esta Tesis, obtiene resultados muy satisfactorios en pos de mejorar la calidad del análisis. En ese sentido podemos destacar la ventaja de utilizar un modelo como el WRF que es fruto de un desarrollo comunitario y que permite utilizar diferentes esquemas físicos. Con todo, los resultados obtenidos en este estudio de los efectos de las fuentes de incertidumbre disparan varios interrogantes y por lo tanto dejan un amplio espacio para continuar indagando sobre cuestiones diversas.

Una de las primeras cuestiones que quedan abiertas está relacionada con la IMA utilizada en los diferentes experimentos. Por un lado, hemos encontrado que la misma tiene ciertas limitaciones a la hora de corregir la falta de dispersión del ensamble en las situaciones en donde había presente al menos una fuente de error diferente al de las condiciones iniciales. Al mismo tiempo hemos visto que cuando la única fuente de error presente en el sistema proviene de las condiciones iniciales, aparece sobre los Andes subtropicales una región de falta de dispersión en el ensamble que es sistemática, y en donde la IMA requiere un tiempo muy largo para alcanzar la convergencia. En contrapartida, en los experimentos en donde se representan en el ensamble las incertidumbres asociadas a las fuentes de error de las condiciones de borde e imperfecciones del modelo, los valores de IMA en dicha región son más pequeños y la misma converge más fácilmente. Este resultado podría a uno llevarlo a trazar una hipótesis acerca de la causa que lleva a que la IMA aumente continuamente allí. A la luz de los resultados, la región de los Andes podría ser una región de inestabilidad en donde las perturbaciones crecen, o bien podría tratarse de una región frontera que separa una zona de errores relativamente pequeños corriente arriba de una zona con errores relativamente más grandes corriente abajo. En el caso de que nuestro ensamble no contenga perturbaciones de las condiciones de borde, la dispersión del mismo será

relativamente pequeña corriente arriba de la cadena montañosa, ya que la información proveniente de los bordes laterales condiciona fuertemente el estado del flujo en dicha región. En consecuencia, cuando el flujo alcanza la cadena montañosa, la poca dispersión del ensamble provoca que no se puedan representar adecuadamente las posibles direcciones de inestabilidad del flujo, lo cual conduce a que la IMA tenga un máximo allí. En cambio, cuando los bordes están debidamente perturbados, ya existe una incertidumbre dentro del ensamble corriente arriba de los Andes que ayuda a que, cuando el flujo atraviesa la cadena orográfica, el ensamble pueda capturar mejor las direcciones de inestabilidad del flujo. Este resultado puede hacernos preguntarnos si el crecimiento de la IMA en la región de los Andes se observaría en el caso de contar con un dominio global y que por lo tanto la aparición de este problema sea consecuencia de utilizar un dominio regional. Esto demuestra por tanto que este punto merece ser explorado más detalladamente en el futuro y que requerirá de experimentos específicamente diseñados para comprender mejor este comportamiento de la IMA. Sin embargo, no debemos perder de vista que la implementación de las técnicas de inflación no se agota en este aspecto particular, sino que es una pregunta abierta mucho más general y que es un área de investigación activa. En efecto, tal como mencionamos en el Capítulo 2 existen otras alternativas a la técnica IMA implementada en esta Tesis, y que pueden ser igualmente probadas.

La segunda pregunta principal de esta Tesis estuvo relacionada con la sensibilidad de la calidad del análisis frente a la resolución horizontal del modelo. Para abordar dicha pregunta se trabajó en un entorno realista sobre la región del Océano Pacífico Norte. Con todo, si bien estos experimentos se asemejaron más a las condiciones de un análisis operativo, el número de observaciones empleados en los mismos fue mucho menor comparado con la cantidad de observaciones empleadas en los sistemas globales operativos (de aproximadamente un 50% menos). La principal diferencia, como mencionamos en el Capítulo 5, estuvo dada en la falta de observaciones de radianza medidas por satélite. Un objetivo secundario dentro de este análisis fue el de analizar en qué medida el aumento en la resolución horizontal del análisis ayuda a

mejorar la calidad de los pronósticos en general, y de eventos de alto impacto dominados por procesos convectivos como los ciclones tropicales, en particular.

Esta pregunta que pretendimos plantear e intentar dar una respuesta en el Capítulo 5 de esta Tesis no es en rigor de fácil respuesta, por el hecho de que el problema en cuestión tiene una serie de aristas que son difíciles de contemplar en cualquier diseño experimental. El hecho de que hayamos construido dos análisis con diferentes resoluciones intentando que los dos sistemas funcionaran de la misma forma dejó fuera de la discusión ciertos aspectos relacionados con el grado de optimización del análisis.

El hecho de que la escala de localización en ambos sistemas no sea el mismo, hace que la información asimilada en cada punto del modelo no sea la misma, como así tampoco el peso dado a las observaciones en los dos sistemas. Sin embargo, experimentos previos utilizando la misma escala de localización para ambos sistemas llevaron a la conclusión de que es necesario reducir la escala de localización a medida que se incrementa la resolución del modelo. Estas pruebas previas están en coincidencia con lo encontrado por diversos autores (Zhang y otros, 2009, Miyoshi y Kondo, 2013). El cambio de la escala de localización impactó en los valores de IMA utilizados inicialmente en cada experimento. En efecto, al reducir la escala de localización del experimento de 20 km se volvió necesario reducir el valor de IMA introducido en el tiempo inicial del experimento, so pena de resultar en inestabilidades numéricas durante la integración del modelo. Estas cuestiones ponen en evidencia que la pregunta planteada no es sencilla de responder, dados los parámetros que se deben modificar para poder abordarla de forma tal que los mismos influyan lo menos posible en los resultados. Claramente, parámetros tales como la escala de localización y la inflación son difíciles de aislar en los experimentos. No obstante estos limitantes, los resultados obtenidos permiten arribar a algunas conclusiones valiosas que permiten incluso trazar un camino a seguir en el futuro.

En primer lugar, los resultados indican que aumentar la resolución del análisis de 60 a 20 km conlleva a una mejora de la calidad del mismo que en variables como el EETS, el viento y la humedad ronda en promedio el 10%, y que resulta estadísticamente significativa. Sin embargo, en variables de masa como la temperatura o la presión en superficie no se aprecia una mejora significativa en el análisis de 20 km. Esto último es consecuencia por un lado de la menor escala de localización del análisis de mayor resolución y por otro del comportamiento propio de dichas variables, ya sea por la escala horizontal de variabilidad de las mismas como de ajuste geostrófico en latitudes medias.

Un punto a no perder de vista acerca de estos resultados es que la verificación se realizó utilizando la base de datos GDAS como referencia, que también tiene errores. Sin embargo, la posterior verificación de los pronósticos en base a observaciones le dio mayor validez a estos resultados. La única excepción podemos encontrarla para la temperatura, la cual mostró diferencias según se realizara la verificación en base a los análisis GDAS o a las observaciones.

Por otro lado, al analizar el grado de ajuste de los análisis con respecto a las observaciones asimiladas encontramos que si bien el análisis de 20 km tiene un mejor grado de ajuste en comparación con el análisis de 60 km, es posible que haya un desbalance entre las diferentes variables dentro del análisis. Este punto deja abierta la pregunta acerca de la necesidad de implementar una técnica de localización de múltiple escala como la de Kondo y Miyoshi (2013), por ejemplo, en donde las observaciones correspondientes a diferentes variables se asimilan con escalas de localización diferente. Este desbalance provoca a su vez que la mejora ganada en la condición inicial a partir de la mayor resolución horizontal del modelo se pierda rápidamente en las primeras horas de pronóstico. Con todo, a plazos de entre 24 y 36 horas se aprecia una mejora significativa que oscila entre el 2 y el 5% en variables como el viento, la humedad y la precipitación, mientras que las variables de masa no reportan mejoras significativas. Dicha mejora, al igual que en el caso del análisis, depende de la región. La degradación se da más rápidamente en latitudes medias debido a la influencia de las condiciones de borde que es mayor en

dicha porción del dominio. En regiones tropicales la mejora en la calidad del pronóstico persiste por más tiempo. Este resultado constituye un punto a favor para continuar trabajando en el incremento de la resolución horizontal de modelos de pronóstico regionales como forma de dar valor agregado a los pronósticos operativos globales.

Otro resultado que se desprende de la verificación de los pronósticos es que la calidad de los pronósticos inicializados con los análisis LETKF son de menor calidad que los pronósticos inicializados con los análisis operativos GDAS. Existen diversos motivos por los que puede estar sucediendo esto. Como mencionamos previamente, los análisis GDAS incorporan un volumen mucho mayor de información proveniente de radianzas de satélites, los cuales permiten una mayor cobertura espacial, especialmente en regiones oceánicas donde el volumen de observaciones es mucho menor.

Cuando pretendemos llevar la verificación a eventos particulares donde la convección juega un rol fundamental, como en el caso de los ciclones tropicales, los resultados muestran que no hay una mejora apreciable en el pronóstico de la trayectoria e intensidad de los ciclones tropicales al aumentar la resolución del análisis de 60 a 20 km. Este resultado es consistente con lo encontrado por Holt y otros (2013), que muestra que las mejoras en la representación de los ciclones tropicales son muy pequeñas al incrementar la resolución horizontal de un análisis regional más allá de los 100 km. Existen diversos motivos para que ocurra esto. Uno de ellos es que la mayor cantidad de información asimilada en un sistema operativo como el GDAS es imprescindible para producir un mejor pronóstico tanto en la trayectoria de los ciclones tropicales como en su intensidad, tal como muestran Liu y otros (2012). Por otro lado, la resolución horizontal utilizada en estos experimentos representa un limitante para representar adecuadamente la dinámica asociada al ojo del sistema. Esto claramente afecta a la calidad del pronóstico de intensidad del tifón, especialmente cuando el mismo entra en una etapa de rápida intensificación. Al mismo tiempo, los EnKF requerirían, además, de técnicas adicionales como por ejemplo el RIP de Kalnay y Yang (2010) para

poder representar mejor los crecimientos rápidos de las inestabilidades del flujo en tales situaciones.

Prueba de esto la da un experimento LETKF adicional realizado con una resolución horizontal de 5 km bajo las mismas condiciones que los experimentos LETKF 20K y LETKF 60K en busca de representar al tifón Sinlaku en su fase de rápida profundización. Si bien en dicho experimento la intensidad del tifón se acercó más a la realidad, el error en la ubicación del sistema fue de unos 600 km. Los resultados de dicho experimento ponen de manifiesto que a medida que se incrementa la resolución horizontal del modelo y el mismo se vuelve capaz de representar explícitamente los procesos convectivos, es necesario acortar las ventanas de asimilación (por ejemplo Vié y otros (2011) en una resolución de 2.5 km utilizan ventanas de 3 horas, y Kawabata y otros (2011) al asimilar datos de radar utilizan ventanas de media hora), y al mismo tiempo incrementar el número de miembros del ensamble para que el ensamble sea capaz de representar mejor el crecimiento de las perturbaciones.

Por lo tanto, incrementar solamente la resolución horizontal del modelo no alcanza para obtener un mejor pronóstico de eventos de alto impacto generados por convección. Por el contrario, el incrementar la resolución horizontal del modelo conlleva un notable incremento del costo computacional, sin obtenerse por ello mejoras importantes en lo que respecta a calidad de análisis/pronóstico de este tipo de eventos. A modo de comparación, la realización del experimento LETKF 20K implica un aumento de poco más de 27 veces del costo computacional en comparación con el experimento LETKF 60K. Esto sugiere entonces, que en vistas de obtener mejores análisis y pronósticos resultantes en un esquema regional de asimilación-pronóstico es preferible enfocar esfuerzos en asimilar un mayor número de observaciones y de implementar otras técnicas de localización en caso de utilizar un EnKF, amén de implementar otras técnicas de representación de errores en el modelo mediante la utilización ensambles físicos y de perturbación de condiciones de borde lateral como la empleada en el Capítulo 4. Esto es claramente menos costoso computacionalmente que incrementar la resolución del modelo con los

esfuerzos adicionales que eso conlleva (reducción de ventanas de asimilación y aumento del número de miembros del ensamble). No obstante, el camino de incrementar la resolución del modelo es ineludible y debe ser recorrido si se pretende en el futuro mejorar el pronóstico de eventos de alto impacto.

Los resultados obtenidos en el Capítulo 5 justifican la necesidad de realizar de los experimentos de sensibilidad en baja resolución de los Capítulos 3 y 4. En efecto, de haberse realizado los experimentos idealizados en mayor resolución posiblemente se habrían encontrado sensibilidades mayores por parte de las fuentes de error estudiadas, más las conclusiones de estos experimentos no habrían sido diferentes de las encontradas aquí. Por lo tanto, a la hora de trazar las conclusiones generales a la luz de los experimentos del Capítulo 5, habríamos igualmente determinado la necesidad de volcar el mayor esfuerzo en implementar diversas técnicas antes que en incrementar la resolución horizontal del modelo para lograr un mejor sistema de análisis-pronóstico regional.

Un último punto a tener en consideración es el hecho de que en el Capítulo 5 los pronósticos realizados fueron determinísticos con lo que en los mismos no se tuvo en cuenta la incertidumbre asociada a la condición inicial (a excepción de los análisis que se generaron a partir de un EnKF). En ese sentido, también es necesario trabajar en pronósticos por ensamble para representar mejor no sólo la incertidumbre asociada a la condición inicial, sino también la asociada a otras fuentes de error mediante las técnicas empleadas en esta Tesis por ejemplo.

6.2 Perspectivas futuras

El camino recorrido en esta Tesis permitió arribar a una serie de conclusiones importantes y establecer asimismo el futuro camino a recorrer para alcanzar el objetivo de la futura implementación de un sistema de análisis-pronóstico regional. Por todo lo expuesto, está claro que a la luz de los resultados

obtenidos se abre un gran abanico de preguntas a responder y por lo tanto un amplio campo para explorar en el futuro.

A modo de breve lista de los aspectos a testear en el futuro, podemos mencionar en primer lugar la implementación de las técnicas de inflación. Entre las alternativas posibles podemos citar la técnica híbrida de Whitaker y Hamill (2012), o la inflación aditiva, que pueden complementar o reemplazar la técnica IMA para compensar la falta de dispersión dada por el error del modelo.

Un punto de gran importancia a estudiar en el futuro está relacionado con la implementación de escalas de localización múltiple, que permitirá sacar mayor provecho de la información observacional que provee cada variable. Este aspecto, como hemos mencionado anteriormente, es clave a fines de lograr análisis de mayor resolución horizontal que permitan obtener pronósticos de mejor calidad.

Asimismo, los resultados de esta Tesis también indican que si se quiere seguir progresando en la mejora de la calidad del análisis es necesario identificar otras fuentes de error presentes en el sistema y buscar la forma de representarlas en la construcción del ensamble. Por ejemplo, una fuente de incertidumbre no cubierta en estos experimentos es la relacionada con las condiciones de la superficie. Es de particular interés analizar cómo impacta el error en la temperatura y la humedad de la superficie, realizando un experimento análogo al de perturbación de bordes laterales, siguiendo la idea de Kunii y Miyoshi (2012). Cubrir esta fuente de incertidumbre dentro del ensamble podría ser de vital importancia en la representación de situaciones particulares y que pueden ser de gran impacto en el pronóstico, como por ejemplo un evento de ciclogénesis o uno de convección severa.

Otro punto de particular interés es la asimilación de la precipitación, aspecto que en esta Tesis deja preguntas abiertas. Los resultados de los experimentos de esta Tesis dan a entender que la precipitación es poco sensible a los cambios asociados con la representación de la incertidumbre del sistema. Esto

significa que el error del análisis en esta variable no es fácilmente controlado asimilando otras variables del sistema como hicimos en esta Tesis, lo cual lleva a pensar que los análisis que no asimilen esta información son poco confiables en este aspecto, con las consecuencias que esto puede tener en bases de datos como los reanálisis que son la fuente de numerosos estudios científicos. Por lo tanto, a fines de comprender mejor el comportamiento de la precipitación dentro de un sistema de análisis, es evidente que es necesario emprender diferentes experimentos de sensibilidad relacionados con esta variable.

También es posible replicar los experimentos realizados en esta Tesis utilizando otras técnicas para representar las incertidumbres asociadas las fuentes de error estudiadas. Por ejemplo, implementar técnicas de estimación y reducción de bias, que como vimos en los diferentes capítulos de esta Tesis, son una componente del error que merece ser tratada especialmente, sobre todo porque la presencia de las mismas viola las hipótesis del KF. También puede implementarse la utilización de condiciones de borde provistas por un ensamble global, por ejemplo generando perturbaciones mediante la técnica de breeding (Toth y Kalnay, 1997).

Otra línea de trabajo a realizar en el futuro, a fines de completar los experimentos idealizados que se realizaron en esta Tesis, es rehacer dichos experimentos utilizando una distribución de observaciones más realista en donde se simulen observaciones obtenidas por satélite por ejemplo. Esto permitiría pesar mejor la influencia de las fuentes de error según la cantidad de observaciones asimiladas. Asimismo, la realización de los experimentos idealizados en resoluciones más altas, por ejemplo en 20 km, permitiría obtener una mejor noción acerca de la importancia de las fuentes de error estudiadas a medida que se incrementa la resolución del análisis. Dado que en la actualidad los sistemas globales de pronóstico trabajan con resoluciones horizontales del orden de los 15 km, es evidente que para que un sistema regional de asimilación-pronóstico provea información valiosa dentro de este contexto, se debe trabajar en resoluciones del orden de los 5 km. Como

mencionamos anteriormente, esto plantea una serie de dificultades técnicas adicionales que es necesario atacar para poder hacer realidad este proyecto en el futuro. En particular, la asimilación de observaciones de superficie es de vital importancia para lograr una mejor calidad del análisis, tal como prueban diversos trabajos (Ansell y otros, 2011, Ansell, 2012, Ha y Snyder, 2014). Sin embargo, la asimilación de esta información requiere de la aplicación de diversos tratamientos de las observaciones que no son triviales, y que son fundamentales para lograr un efecto benéfico de la asimilación de dicha información. Entre los aspectos que se deben tener en cuenta está la selección de las observaciones según su ubicación real en altura con respecto a la topografía del modelo y el tratamiento de su error de representatividad. Más allá de estas dificultades, es imprescindible avanzar en la asimilación en alta resolución, dado que la convección es posiblemente el fenómeno meteorológico que mayor impacto tiene en nuestra sociedad. En este sentido, el trabajo de Ha y Snyder (2014) demuestra la utilidad de asimilar información de superficie en un evento de convección severa en las Grandes Planicies de los Estados Unidos.

La meta última de la asimilación de datos en nuestro país debería ser, sin lugar a dudas, la asimilación de información de radar. En este caso lo que se busca es obtener la situación en tiempo real de la atmósfera para la ayuda en el pronóstico a no más de 2 a 3 horas, es decir para el pronóstico inmediato. Asimismo, la asimilación de datos de satélite será de una gran ayuda en pos de lograr este objetivo, más aun si se tiene en cuenta que para 2016 estaría disponible la información del GOES-R que proveerá datos de temperatura de topos nubosos con una resolución espacial y temporal muy alta (del orden de los 5 minutos). Algunos trabajos han mostrado resultados más que prometedores con la asimilación de estos datos, especialmente en regiones con escasa cobertura espacial de observaciones como la nuestra (Kerr y otros, 2015). Esta estrategia es la que se está adoptando actualmente en diferentes partes del mundo, y los resultados son muy alentadores, sobre todo en la previsión de eventos meteorológicos de alto impacto (Sun y otros, 2014).

Existen asimismo, otras áreas relacionadas con la meteorología que podrían beneficiarse con el desarrollo de la asimilación de datos en nuestro país. Por ejemplo, la asimilación de datos operativa puede ayudar a la predicción de la producción de energía (tanto eólica como solar), en la meteorología aeronáutica, o también en pronósticos de dispersión de contaminantes, entre los que podemos incluir la dispersión de cenizas volcánicas, los provenientes de la quema de biomasa y eventualmente de emisiones provenientes de accidentes de plantas nucleares.

Sin embargo, un beneficio no menor para la meteorología operativa y que en esta Tesis apenas hemos mencionado, es que la implementación de una técnica de asimilación basada en un Filtro de Kalman por ensambles posibilitaría la producción de pronósticos por ensambles. Esto representaría un gran avance para la meteorología en nuestro país, ya que posibilitaría la generación de pronósticos probabilísticos. Esto significa que ya no se dependería de un único pronóstico determinístico de un modelo operativo como ocurre en la actualidad, sino que se podrían generar pronósticos probabilísticos en alta resolución, los cuales permitirían cuantificar el grado de incertidumbre de diferentes eventos meteorológicos y serían de gran ayuda para la predicción de eventos potencialmente peligrosos. Más aún, la posibilidad de derivar la probabilidad de ocurrencia de distintos fenómenos, con diversos grados de intensidad (i.e. umbrales) ofrece un salto sustantivo respecto de la utilidad de la información que se obtiene de un pronóstico.

Podemos ver entonces que a partir del desarrollo de la asimilación de datos en nuestro país, se abre un gran abanico de posibilidades que puede ayudar a diferentes sectores de la sociedad. Sin embargo, hay un aspecto que es de vital importancia para poder hacer realidad estas perspectivas. El mismo está relacionado con la disponibilidad de la capacidad de cómputo adecuada para poder implementar los sistemas de asimilación de datos y de pronóstico en forma operativa. En ese sentido, la iniciativa del SNCAD (Sistema Nacional de Computación de Alto Desempeño) promovidos conjuntamente por el Ministerio de Ciencia, Tecnología e Innovación Productiva y el Consejo Interinstitucional

de Ciencia y Tecnología, provee un marco adecuado para lograr la concreción de proyectos de esta envergadura. Asimismo, el proyecto Alert.ar apunta en el mismo sentido, dado que permitirá incrementar significativamente la capacidad de cómputo operativa en el SMN.

En conclusión, tenemos un largo camino por recorrer en la técnica de la asimilación de datos, de la cual se pueden obtener desarrollos muy importantes. En ese sentido, las perspectivas futuras de la asimilación de datos como herramienta de desarrollo de la meteorología en nuestro país son sumamente alentadoras, dado el amplio campo de exploración que se abre a futuro. Esto se evidencia no solamente en el objetivo planteado en esta Tesis y en los posibles desarrollos, sino también dentro del contexto de proyectos como SINARAME, Alert.ar o RELAMPAGO, que planteamos en el capítulo inicial. El hecho de que organismos oficiales como el SMN y diferentes instituciones busquen trabajar mancomunadamente en pos del objetivo de lograr que la meteorología operativa en nuestro país se acerque a la de los países más desarrollados, nos permite ser optimistas. Todos estos hechos ponen de manifiesto que la meteorología operativa en nuestro país se está lanzando al futuro para saldar su deuda con la sociedad en su conjunto. Por lo tanto podemos afirmar, con absoluta confianza, que el futuro nos espera.

*“No preguntéis si estas ideas son nuevas o viejas,
preguntad más bien si coinciden con la verdad”*

Marcello Malpighi (1628-1694)

Apéndice de definiciones

El índice Bias en frecuencia utilizado en esta Tesis para la verificación de los pronósticos de precipitación acumulada se define de la siguiente manera:

$$Bias = \frac{F}{O} \quad (A.1)$$

En donde F representa la cantidad de puntos de retícula en los que se pronostica un evento, mientras que O es la cantidad de puntos en donde se observa dicho evento.

El Bias en frecuencia mide básicamente en qué medida el área de precipitación pronosticada está sobre o subestimada con respecto al área observada, dependiendo de si su valor es mayor o menor a 1, respectivamente.

El segundo índice utilizado en la verificación es el Equitable Threat Score (ETS) (Schaefer, 1990), que se define como:

$$ETS = \frac{H - E}{F + O - H - E} \quad (A.2)$$

Donde F y O tienen el mismo significado que en (A.1), mientras que H representa la tasa de aciertos (cuando el evento es pronosticado y observado al mismo tiempo), y E representa el número de aciertos dados por azar. La tasa de aciertos al azar representa en este caso el pronóstico de referencia, el cual sirve como piso para evaluar la calidad del pronóstico de precipitación. La misma está dada por la siguiente expresión:

$$E = \frac{F * O}{N} \quad (A.3)$$

Siendo N el número de puntos de retícula del modelo en este caso. El máximo valor posible de ETS es de 1 para un pronóstico perfecto, mientras que un ETS

de 0 implica que el pronóstico tiene el mismo valor que un pronóstico hecho al azar. Un valor negativo de ETS significa que el pronóstico es peor que el pronóstico al azar.

El ETS por tanto mide la habilidad de un modelo en pronosticar correctamente, tanto espacial como temporalmente, la precipitación acumulada para diferentes umbrales.

Listado de acrónimos

3DVar	→	Método de asimilación 3DVar
3DVar/EnKF	→	Método de asimilación 3DVar/EnKF
4DEnVar	→	Método de asimilación 4DEnVar
4DVar	→	Método de asimilación 4DVar
AIRS	→	Atmospheric Infrared Sounder
Alert.ar	→	Proyecto de investigación Alert.ar
ARPE	→	Australian Regional Primitive Equations
ASCAT	→	Advanced Scatterometer
BMJ	→	Parametrización de convección Betts-Miller-Janjic
BOM	→	Bureau of Meteorology de Australia
BRAMS	→	Brazilian Regional Atmospheric Modelling System
CMC	→	Canadian Meteorological Centre
CMORPH	→	CPC Morphing Technique
CFSR	→	Climate Forecast System Reanalysis
CPTEC	→	Centro de Previsión del Tiempo y Estudios Climáticos
DART	→	Data Assimilation Research Testbed
EAKF	→	Ensemble Adjustment Kalman Filter
ECMWF	→	European Centre for Medium Range Weather Forecast
EES	→	Error en Energía Seca
EETS	→	Error en Energía Total Seca
EHIV	→	Error en Humedad Integrada en la Vertical
EnKF	→	Filtro de Kalman por ensambles (Ensemble Kalman Filter)
EnsSRF	→	Ensemble Square Root Filter
ETKF	→	Ensemble Transform Kalman Filter
ETS	→	Equitable Threat Score
FNL	→	Base de análisis Final Analysis
GDAS	→	Base de análisis Global Data Assimilation System
GFS	→	Modelo Global Forecast System
GTS	→	Global Telecommunication System
IMA	→	Inflación multiplicativa adaptativa
JMA	→	Japan Meteorological Agency
KMA	→	Korean Meteorological Administration
KF	→	Filtros de Kalman (Kalman Filter)
LETKF	→	Local Ensemble Transform Kalman Filter
LETKF 20K	→	Sistema de análisis-pronóstico de 20 km
LETKF 60K	→	Sistema de análisis-pronóstico de 60 km
<i>MNBIAS</i>	→	Error sistemático de la media
<i>MIBI</i>	→	Experimento de Modelo Imperfecto y Bordes Imperfectos
<i>MIBI EF BP</i>	→	Experimento de Modelo Imperfecto y Bordes Imperfectos con Ensamble Físico y Bordes Perturbados
<i>MIBP</i>	→	Experimento de Modelo Imperfecto y Bordes Perfectos
<i>MIBP EF</i>	→	Experimento de Modelo Imperfecto y Bordes Perfectos con Ensamble Físico
<i>MOGREPS</i>	→	Met Office Global and Regional Ensemble Prediction System
<i>MPBI</i>	→	Experimento de Modelo Perfecto y Bordes Imperfectos
<i>MPBI BP</i>	→	Experimento de Modelo Perfecto y Bordes Imperfectos con

	Bordes Perturbados
<i>MPBP</i>	→ Experimento de Modelo Perfecto y Bordes Perfectos
<i>MRF</i>	→ Parametrización de capa límite Medium Range Forecast
<i>mse</i>	→ Error cuadrático medio (mean square error)
<i>MYJ</i>	→ Parametrización de capa límite Mellor-Yamada-Janjic
<i>NCEP</i>	National Center for Environmental Prediction
<i>No SIST</i>	→ Error no sistemático
<i>OI</i>	→ Método de interpolación óptima (Optimal Interpolation)
<i>OSSE</i>	→ Experimento de observaciones simuladas (Observing System Simulation Experiment)
<i>PH</i>	→ Variable Altura Geopotencial
<i>PP</i>	→ Variable Precipitación
<i>PSFC</i>	→ Variable Presión en superficie
<i>q</i>	→ Variable humedad específica
<i>RELAMPAGO</i>	→ Remote sensing of Electrification, Lightning, and Mesoscale/Microscale Processes with Adaptive Ground Observation
<i>RIP</i>	→ Técnica Running in Place
<i>RMSE</i>	→ Root-Mean Square Error
<i>RSMC</i>	→ Regional Specialized Meteorological Center Tokyo-Typhoon Center
<i>SDBIAS</i>	→ Error sistemático del desvío estándar
<i>SINARAME</i>	→ Sistema Nacional de Radares Meteorológicos
<i>SMN</i>	→ Servicio Meteorológico Nacional
<i>SST</i>	→ Temperatura Superficial del Mar (Sea Surface Temperature)
<i>SV</i>	→ Simulación Verdad
<i>T</i>	→ Variable Temperatura
<i>U</i>	→ Variable Viento Zonal
<i>UCAR</i>	→ University Corporation for Atmospheric Research
<i>V</i>	→ Variable Viento Meridional
<i>WRF</i>	→ Modelo Weather Research and Forecasting
<i>ZCIT</i>	→ Zona de Convergencia Intertropical

Referencias

- Ancell, B. C., 2012: Examination of Analysis and Forecast Errors of High-Resolution Assimilation, Bias Removal, and Digital Filter Initialization with an Ensemble Kalman Filter. *Mon. Wea. Rev.*, **140**, 3992-4004.
- Ancell, B. C., C. F. Mass, y G. J. Hakim, 2011: Evaluation of surface analyses and forecasts with a multiscale ensemble Kalman filter in regions of complex terrain. *Mon. Wea. Rev.*, **139**, 2008–2024.
- Anderson, J. L., 2001: An Ensemble Adjustment Kalman Filter for Data Assimilation. *Mon. Wea. Rev.*, **129**, 2884-2903.
- Anderson, J., L., Anderson, S., L., 1999: A Monte Carlo implementation of the nonlinear filtering problem to produce ensemble assimilations and forecasts, *Mon. Wea. Rev.* **127**, 2741–2758.
- Barnes, S., 1964: A techniques for maximizing details in numerical map analysis. *J. Appl. Meteor.* **124**, 1695-1713.
- Bei, N., Zhang, F., 2014: Mesoscale Predictability of Moist Baroclinic Waves: Variable and Scale-dependent Error Growth, *ADVANCES IN ATMOSPHERIC SCIENCES*, **31**, 995–1008.
- Bergthorsson, P., Döös, B., 1955: Numerical weather map analysis, *Tellus* **7**, 329-340.
- Bishop, C. H., B. J. Etherton, y S. J. Majumdar, 2001: Adaptive Sampling with Ensemble Transform Kalman Filter. Part I: Theoretical Aspects. *Mon. Wea. Rev.*, **129**, 420-436.
- Bjerknes, V., 1904: Das Problem der Wettervorhersage, betrachtet vom Standpunkt der Mechanik und der Physik. *Meteor. Zeits.* **21**, 1-7.

- Bonavita M, Torrisi L, Marcucci F. 2008. The ensemble Kalman filter in an operational regional NWP system: Preliminary results with real observations. *Q. J. R. Meteorol. Soc.* **134**, 1733-1744.
- Bonavita M, Torrisi L, Marcucci F. 2010. Ensemble data assimilation with the CNMCA regional forecasting system. *Q. J. R. Meteorol. Soc.* **136**, 132-145
- Bonavita, M., Isaksen, L., Hólm, E., 2012: On the use of EDA background error variances in the ECMWF 4D-Var. *Q. J. R. Meteorol. Soc.*, **138**: 1540-1559.
- Bowler, N., Arribas, A., Mylne, K., Robertson, K., Beare, S., 2008: The MOGREPS short-range ensemble prediction system. *Quart. J. Roy. Meteor. Soc.*, **134**, 703-722
- Buehner, M., Houtekamer, P., Charette, C., Mitchell, H., Be, B., 2010 a: Intercomparison of variational data assimilation and the ensemble Kalman filter for global deterministic NWP. Part I: Description and single-observation experiments. *Mon. Wea. Rev.*, **138**, 1550-1566.
- _____, _____, _____, _____, _____, 2010b: Intercomparison of variational data assimilation and the ensemble Kalman filter for global deterministic NWP. Part II: One-month experiments with real observations. *Mon. Wea. Rev.*, **138**, 1567-1586.
- Buizza, R., M. Miller, y T. N. Palmer, 1999: Stochastic representation of model uncertainties in the ECMWF Ensemble Prediction System. *Quart. J. Roy. Meteor. Soc.*, **125**, 2887-2908.
- Burgers, G., P. J. van Leeuwen, y G. Evensen, 1998: On the analysis scheme in the Ensemble Kalman Filter. *Mon. Wea. Rev.*, **126**, 1719-1724.

- Caron, J-F., Fillion, L., 2010: An Examination of the Incremental Balance in a Global Ensemble-Based 3D-Var Data Assimilation System. *Mon. Wea. Rev.*, **138**, 3946-3966. DOI: 10.1175/2010MWR3339.1
- Charney, J. G., R. Fjørtoft, J. von Neuman, 1950: Numerical integration of the barotropic vorticity equation. *Tellus* **2**, 237-254.
- Chen, S.-H., and W.-Y. Sun, 2002: A one-dimensional time dependent cloud model. *J. Meteor. Soc. Japan*, **80**, 99–118.
- Cressman, G. P., 1959: An operational objective analysis system. *Mon. Wea. Rev.* **87**, 367-374.
- Davis, C.; Brown, B.; Bullock, R., 2005a: Object-Based Verification of Precipitation Forecasts. Part I: Methodology and Application to Mesoscale Rain Areas. *Mon. Wea. Rev.*, **134**, 1772-1784.
- _____, _____, 2005b: Object-Based Verification of Precipitation Forecasts. Part II: Application to Convective Rain Systems. *Mon. Wea. Rev.*, **134**, 1785-1795.
- Desroziers, G., L. Berre, B. Chapnik, and P. Poli, 2005: Diagnosis of observation, background and analysis-error statistics in observation space. *Quart. J. Roy. Meteor. Soc.*, **131**, 3385–3396.
- Dillon M.E., Y. Garcia Skabar, J. Ruiz, E. Kalnay, E.A. Collini, P. Echevarría, M. Saucedo, T. Miyoshi, y M. Kunii, 2016: Application of the WRF-LETKF Data Assimilation System over Southern South America: Sensitivity to model physics. *Weather and Forecasting*, **31**, 217-236.

- Dirren, S., R. D. Torn, y G. J. Hakim, 2007: A data assimilation case-study using a limited-area ensemble Kalman filter. *Mon. Wea. Rev.*, **135**, 1455-1473.
- Dudhia, J., 1989: Numerical study of convection observed during the winter monsoon experiment using a mesoscale two-dimensional model, *J. Atmos. Sci.*, **46**, 3077–3107.
- Ebert, E.E. and J.L. McBride, 2000: Verification of precipitation in weather systems: Determination of systematic errors. *J. Hydrology*, **239**, 179-202.
- Eliassen, A., Sawyer, J. S., Smagorinsky, J., 1954: *Upper air network requirements for numerical weather prediction*. Technical Note No 29. World Meteorological Organization, Geneva.
- Errico, R. M., 1997: What is an adjoint model? *Bull. Amer. Meteor. Soc.* **78**, 2577-2591.
- Errico R. M., K. Reader y M. Ehrendorfer, 2004: Singular vectors for moisture-measuring norms. *Q. J. R. Meteorolol. Soc.*, **130**, 963-987
- G. Evensen, Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics, *J. Geophys. Res.* **99**, 10143–10162 (1994).
- Gandin, L. S., 1963: Objective analysis of meteorological fields. *Gidrometeorologicheskoe Izdatelstvo*, Leningrad.
- García Skabar, Y. (2008): Análisis enriquecidos, evaluación de su impacto en el pronóstico y su aplicación para describir circulaciones de mesoescala en el centro y norte de Argentina. Tesis doctoral, Depto. de Cs. de la Atmósfera y los Océanos, FCEyN, UBA

- García Skabar, Y., Nicolini, M., 2009: Enriched Analyses with Assimilation of SALLJEX Data. *J. Appl. Meteor. Climatol.*, **48**, 2425–2440. doi: <http://dx.doi.org/10.1175/2009JAMC2091.1>
- Gaspari, G. and S. E. Cohn, 1999: Construction of correlation functions in two and three dimensions. *Quart. J. Roy. Meteor. Soc.*, **125**, 723-757.
- Gilchrist, B., Cressman, G., 1954: An experiment in objective analysis. *Tellus* **6**, 309-318.
- Grell, G. A., and D. Devenyi, 2002: A generalized approach to parameterizing convection combining ensemble and data assimilation techniques. *Geophys. Res. Lett.*, 29(14), Article 1693
- Greybush, S., Kalnay, E., Miyoshi, T., Ide, K., Hunt, B., 2011: Balance and Ensemble Kalman Filter Localization Techniques. *Mon. Wea. Rev.* **139**, 511-522.
- Grimit, E., Mass, C., 2007: Measuring the Ensemble Spread – Error Relationship with a Probabilistic Approach: Stochastic Ensemble Results. *Mon. Wea. Rev.* **135**, 203 -221. DOI: 10.1175/MWR3262.1
- Ha, So-Young, Snyder, C., 2014: Influence of Surface Observations in Mesoscale Data Assimilation Using an Ensemble Kalman Filter. *Monthly Weather Review* **142**, 1489-1508.
- Hagedorn, R., Doblas-Reyes, F., Palmer, T. N., 2005: The rationale behind the success of multi-model ensembles in seasonal forecasting – I. Basic concept. *Tellus* 57A, 219-233.

- Hamill, T., Snyder, C., 2000: A hybrid ensemble Kalman filter–3D variational analysis scheme *Mon. Wea. Rev.* **128**, 2905–2919.
- Hamill, T., M., J. S. Whitaker, y C. Snyder, Distance-dependent filtering of background error covariance estimates in an ensemble Kalman filter, *Mon. Wea. Rev.* **129**, 2776–2790 (2001).
- Ho, S-P., Kuo, Y-H., Sokolovskiy, S., 2007: Improvement of the Temperature and Moisture Retrievals in the Lower Troposphere Using AIRS and GPS Radio Occultation Measurements. *Journal of Atmospheric and Oceanic Technology*, 24, 1726-1739, doi: 10.1175/JTECH2071.1
- Hoke, J., Anthes, R., 1976: The initialization of numerical models by a dynamic relaxation technique. *Mon. Wea. Rev.* **104**, 1551-1556.
- Holt, Christina R., Szunyogh, I., Gyarmati, G., 2013: Can a Moderate-Resolution Limited-Area Data Assimilation System Add Value to the Global Analysis of Tropical Cyclones? *Mon. Wea. Rev.*, **141**, 1866–1883.
- Hopson, T, 2014: Assesing the Ensemble Spread-Ensemble Error Relationship. *Mon. Wea. Rev.*, **142**, 1125-1142
- Hong, S.-Y., and H.-L. Pan, 1996: Nonlocal boundary layer vertical diffusion in a medium-range forecast model, *Mon. Wea. Rev.*, **124**, 2322–2339.
- Hong, S.-Y., J. Dudhia, and S.-H. Chen, 2004: A Revised Approach to Ice Microphysical Processes for the Bulk Parameterization of Clouds and Precipitation, *Mon. Wea. Rev.*, **132**, 103–120.
- Hong, S.-Y., and Y. Noh, and J. Dudhia, 2006: A new vertical diffusion package with an explicit treatment of entrainment processes. *Mon. Wea. Rev.*, **134**, 2318–2341.

- Hou, D., Kalnay, E., Droegmeier, K., 2001: Objective verification of the SAMEX '98 Ensemble Forecasts. *Mon. Wea. Rev.*, **129**, 73-91.
- Hou, D., Z. Toth, Y. Zhu and W. Yang, 2008: Evaluation of the Impact of the Stochastic Perturbation Schemes on Global Ensemble Forecast. Preprints of 19th Conference on Probability and Statistics, New Orleans, LA, Amer. Meteor. Soc.
- Houtekamer, P. L., L. Lefaivre, J. Derome, H. Ritchie, and H. L. Mitchell, 1996: A system simulation approach to ensemble prediction. *Mon. Wea. Rev.*, **124**, 1225–1242.
- Houtekamer, P. L. and H. L. Mitchell, 1998: Data Assimilation Using an Ensemble Kalman Filter Technique. *Mon. Wea. Rev.*, **126**, 796-811.
- Houtekamer P. L., Mitchell, H., L., A sequential ensemble Kalman filter for atmospheric data assimilation, *Mon. Wea. Rev.* **129**, 123–137 (2001).
- Houtekamer, P., Mitchell, H. L., 2005: Ensemble Kalman filtering. *Q. J. R. Meteorol. Soc.*, **131**, 3269-3289. doi: 10.1256/qj.05.135
- Houtekamer, P. L., H. L. Mitchell, and X. Deng, 2009: Model error representation in an operational ensemble Kalman filter. *Mon. Wea. Rev.*, **137**, 2126–2143.
- Hunt, B. R., E. Kalnay, E. J. Kostelich, E. Ott, D. J. Patil, T. Sauer, I. Szunyogh, J.A. Yorke y A. V. Zimin, 2004: Four-dimensional ensemble Kalman filtering. *Tellus*, **56A**, 273-277

- Hunt, B. R., Kostelich E. J., Szunyogh I., 2007: Efficient data assimilation for spatio temporal chaos: a local ensemble transform Kalman filter. *Physica D: Nonlinear Phenomena*, **77**, 437-471.
- Janjic, Z. I., 1990: The step-mountain coordinate: Physical package. *Mon. Wea. Rev.*, **118**, 1429-1443.
- Janjic, Z.I., 1994: The step-mountain Eta coordinate model: Further developments of the convection, viscous sublayer and turbulence closure schemes. *Mon. Wea. Rev.*, **122**, 927-945.
- Janjic, Z. I., 2002: Nonsingular Implementation of the Mellor–Yamada Level 2.5 Scheme in the NCEP Meso model, *NCEP Office Note*, No. 437, 61 pp.
- Jazwinski, A., H., *Stochastic Processes and Filtering Theory*, Academic Press (1970).
- Joyce, R. J.; Janowiak J. E.; Arkin, P. A.; Xie, P., 2004: CMORPH: A method that produces global precipitation estimates from passive microwaves and infrared data at high spatial and temporal resolution. *J. Hydrometeor.*, Vol 5, p. 487-503.
- Kain, J., and J. Fritsch, 1993: Convective parameterization for mesoscale models: The Kain-Fritsch scheme. *The Representation of Cumulus Convection in Numerical Models, Meteor. Monogr.*, No. 46, Amer. Meteor. Soc., 165-170.
- Kalman, R.: A New Approach to Linear Filtering and Prediction Problems, *Trans. ASME, Ser. D: J. Basic Eng.* **82**, 35-45 (1960).
- Kalman, R., Bucy R.: New Results in Linear Filtering and Prediction Theory, *J. Basic Eng.* **83**, 95-108 (1961).

- Kalnay, E., 2003: *Atmospheric modeling, data assimilation and predictability*. Cambridge University Press, Cambridge, 341 pp.
- Kalnay, E., y S.-C. Yang, 2008: Accelerating the spin-up of ensemble Kalman filtering. Cornell University, arXiv:0806.0180v1, 11 pp. [Disponible en <http://arxiv.org/abs/0806.0180v1>.]
- Kalnay, E., and S.-C. Yang, 2010: Accelerating the spin up of ensemble Kalman filtering. *Quart. J. Roy. Meteor. Soc.*, **136**, 1644–1651.
- Kawabata, T., Kuroda, T., Seko, H., Saito, K., 2011: A Cloud-Resolving 4DVAR Assimilation Experiment for a Local Heavy Rainfall Event in the Tokyo Metropolitan Area. *Mon. Wea. Rev.*, **139**, 1911-1931.
- Keppenne, C. L., 2000: Data assimilation into a primitive-equation model with a parallel ensemble Kalman filter, *Mon. Wea. Rev.* **128**, 1971–1981.
- Kerr C. A., Stensrud D. J., y Wang X., 2015: Assimilation of Cloud-Top Temperature and Radar Observations of an Idealized Splitting Supercell Using an Observing System Simulation Experiment. *Mon. Wea. Rev.*, **143**, 1018–1034. doi: <http://dx.doi.org/10.1175/MWR-D-14-00146.1>
- Keyser, D., 2010: PREPBUFR PROCESSING AT NCEP, disponible en http://www.emc.ncep.noaa.gov/mmb/data_processing/prepbufr.doc/document.htm.
- Kirtman, y co-autores, 2014: The North-American Multimodel Ensemble. *Bull. Amer. Meteor. Soc.*, **95**, 585-601.

- Kistler, R. E., 1974: A study of data assimilation techniques in an autobarotropic primitive equation channel model. MS Thesis, Dept of Meteorology, Penn State University.
- Kleist, D. T., 2012: An evaluation of hybrid variational-ensemble data assimilation for the NCEP GFS. Tesis doctoral, Universidad de Maryland.
- Kondo, K., T. Miyoshi, y H. L. Tanaka, 2013: Parameter sensitivities of the dual-localization approach in the local ensemble transform Kalman filter. *SOLA*, **9**, 174–178, doi: 10.2151/sola.2013-039
- Krishnamurti, T. N., C. M. Kishtawal, Z. Zhang, T. LaRow, D. Bachiochi, E. Williford, S. Gadgil, y S. Surendran, 2000: Multimodel ensemble forecasts for weather and seasonal climate. *J. Climate*, **13**, 4196–4216.
- Kunii, M., Miyoshi T., 2012: Including Uncertainties of Sea Surface Temperature in an Ensemble Kalman Filter: A Case Study of Typhoon Sinlaku (2008). *Weather and Forecasting*, **27**, 1586-1597.
- Lahoz, W., Kattatov, B., y Menard, R., 2010: *Data Assimilation: Making sense of observations*. Springer Editions, 732 pp.
- Leslie, L. M., Mills, G. A., Logan, L.W., Gauntlett, D. J., Kelly, G.A., Mc Gregor, J. L., Manton, M. J., Sardie, J. M., 1985: A high resolution primitive equations model for operations and research. *Aust. Met. Mag.*, 33, 11-36.
- Li, H., E. Kalnay, y T. Miyoshi, 2009: Simultaneous estimation of covariance inflation and observation errors within an ensemble Kalman filter. *Quart. J. Roy. Meteor. Soc.*, **135**, 523–533.

- LIEN, Guo-Yuan; KALNAY, Eugenia; MIYOSHI, Takemasa. Effective assimilation of global precipitation: simulation experiments. **Tellus A**, [S.l.], v. 65, jul. 2013. ISSN 1600-0870.
- Liu, C., Xiao, Q., Wang, B., 2008: An ensemble-based four-dimensional variational data assimilation scheme. Part I: Technical formulation and preliminary test. *Mon. Wea. Rev.*, **136**, 3363-3373. DOI: 10.1175/2008MWR2312.1
- Liu, C., Xiao, Q., Wang, B., 2009: An ensemble-based four-dimensional variational data assimilation scheme. Part II: Observing System Simulation Experiments with Advanced Research WRF (ARW). *Mon. Wea. Rev.*, **137**, 1687-1704. DOI: 10.1175/2008MWR2699.1
- Liu, Z, Schwartz, C, Snyder, C, and Ha, S-Y, 2012: Impact of assimilating AMSU-A Radiances on Forecasts of 2008 Atlantic Tropical Cyclones Initialized with a Limited- area Ensemble Kalman Filter. *Mon. Wea. Rev.*, **140**, 4017-4034.
- Lorenc, A., 1986: Analysis methods for numerical weather prediction. *Quart. J. Roy. Meteor. Soc.* **112**, 1177-1194
- Lorenc, A. C., 2003: The potential of the ensemble Kalman filter for NWP – A comparison with 4D-Var. *Quart. J. Roy. Meteor. Soc.*, **129**, 3183–3203.
- Lorenz, E. N., 1963: Deterministic non-periodic flow. *J. Atmos. Sci.* **20**, 130-141.
- Matsudo, C., y coautores: High resolution model intercomparison for Convective Events during CHUVA Santa María. Chuva International Workshop, Sao Pablo, Brasil, Mayo 2013.

- Mass, C. F., Ovens, D., Westrick, K., Colle, B. A., 2002: Does increasing horizontal resolution produce more skillfull forecasts? *Bull. Amer. Met. Soc.*, **83**, 407-430.
- Mc Gregor, J. L., Leslie, L.M., Gauntlett, D. J., 1978: The ANMRC limited-area model: consolidated formulation and operational results. *Mon. Wea. Rev.*, **106**, 427-438.
- Meng, Z., Zhang, F., 2008a: Test of an Ensemble Kalman Filter for Mesoscale and Regional-Scale Data Assimilation. Part III: Comparison with 3DVAR in a Real-Data Case Study. *Mon. Wea. Rev.*, **136**, 522-540.
- _____, _____, 2008b: Test of an Ensemble Kalman Filter for Mesoscale and Regional-Scale Data Assimilation. Part IV: Comparison with 3DVAR in a Month-Long Experiment. *Mon. Wea. Rev.*, **136**, 3671-3682.
- Mesinger, F., y coautores, 2012: An upgraded version of the Eta model. *Meteorol Atmos Phys*, **116**, 63-79. DOI 10.1007/s00703-012-0182z
- Mitchell, H. L., y P. L. Houtekamer, 2000: An adaptive ensemble Kalman filter. *Mon. Wea. Rev.*, **128**, 416–433.
- Mitchell, H. L., P. L. Houtekamer, y G. Pellerin, 2002: Ensemble Size, Balance, and Model-Error Representation in an Ensemble Kalman Filter *Mon. Wea. Rev.*, **130**, 2791–2808.
- Miyoshi, T., 2005: Ensemble Kalman filter experiments with a Primitive-Equation global model. Tesis doctoral, Universidad de Maryland, College Park, 197 pp.

- Miyoshi, T., 2011: The Gaussian approach to adaptive covariance inflation and its implementation with the local ensemble transform Kalman filter. *Mon. Wea. Rev.*, **139**, 1519–1535.
- Miyoshi, T., Aranami, K., 2006: Applying a Four-dimensional Local Ensemble Transform Kalman Filter (4D-LETKF) to the JMA Nonhydrostatic Model (NHM). *SOLA*, 2, 128–131.
- Miyoshi, T., Sato, Y., 2007: Assimilating Satellite Radiances with a Local Ensemble Transform Kalman Filter (LETKF) Applied to the JMA Global Model (GSM). *SOLA*, 3, 37–40.
- Miyoshi, T., Yamane, S., 2007: Local ensemble transform Kalman filtering with an AGCM at a T159/L48 resolution. *Mon. Wea. Rev.*, **135**, 3841–3861.
- Miyoshi, T., Yamane, S., Enomoto, T., 2007: Localizing the Error Covariance by Physical Distances within a Local Ensemble Transform Kalman Filter (LETKF). *SOLA*, 3, 89–92. doi:[10.2151/sola.2007-023](https://doi.org/10.2151/sola.2007-023).
- Miyoshi, T., Sato, Y., Kadowaki, T., 2010: Ensemble Kalman filter and 4D-Var inter-comparison with the Japanese operational global analysis and prediction system. *Mon. Wea. Rev.*, **138**, 2846–2866.
- Miyoshi, T., Kunii, M., 2012: The local ensemble transform Kalman filter with the Weather Research and Forecasting model: experiments with real observations. *Pure Appl. Geophys.*, 169 (321), DOI: 10.1007/s00 024–011–0373–4.
- _____, _____, 2012b: Using AIRS retrievals in the WRF-LETKF system to improve regional numerical weather prediction. *Tellus*, **64A**, 18408. doi:[10.3402/tellusa.v64i0.18408](https://doi.org/10.3402/tellusa.v64i0.18408)

- Miyoshi, T., y K. Kondo, 2013: A multi-scale localization approach to an ensemble Kalman filter. *SOLA*, **9**, 170–173.
- Mlawer, E. J., S. J. Taubman, P. D. Brown, M. J. Iacono, y S. A. Clough, 1997: Radiative transfer for inhomogeneous atmosphere: RRTM, a validated correlated-k model for the longwave. *J. Geophys. Res.*, 102 (D14), 16663–16682.
- Monin, A.S. y A.M. Obukhov, 1954: Basic laws of turbulent mixing in the surface layer of the atmosphere. *Contrib. Geophys. Inst. Acad. Sci.*, USSR, (151), 163–187
- Murphy, J., D. Sexton, D. Barnett, G. Jones, M. Webb, M. Collins, and D. Stainforth, 2004: Quantification of modelling uncertainties in a large ensemble of climate change simulations. *Nature*, 430, 768–772.
- Nicolini, M. y Y. García Skabar, 2011: Diurnal cycle in convergence patterns in the boundary layer east of the Andes and convection. *Atmospheric Research*, Vol.100, N°4, 377-390.
- Nutter, P., D. Stensrud, y M. Xue, 2004a: Effects of coarsely resolved and temporally interpolated lateral boundary conditions on the dispersion of limited-area ensemble forecasts. *Mon. Wea. Rev.*, **132**, 2358–2377.
- Nutter, P., M. Xue, y D. Stensrud, 2004b: Application of lateral boundary condition perturbations to help restore dispersion in limited-area ensemble forecasts. *Mon. Wea. Rev.*, **132**, 2378–2390.
- Otsuka, S., y T. Miyoshi, 2015: A Bayesian Optimization Approach to Multi-Model Ensemble Kalman Filter with a Low-Order Model. *Mon. Wea. Rev.*, 143, 2001-2012. DOI: 10.1175/MWR-D-14-00148.1

Ott, E., B. R. Hunt, I. Szunyogh, A. V. Zimin, E. J. Kostelich, M. Corazza, E. Kalnay, D. J. Patil, and J. A. Yorke, 2004: A local ensemble Kalman filter for atmospheric data assimilation. *Tellus*, **56A**, 415-428.

Palmer, T. N., 2001: A nonlinear dynamical perspective on model error: A proposal for non-local stochastic-dynamic parameterization in weather and climate prediction. *Quart. J. Roy. Meteor. Soc.*, **127**, 279–304.

Palmer, T., Hagedorn, R., 2006: Predictability of Weather and Climate, Cambridge University Press.

Panofsky, H., 1949: Objective weather-map analysis. *J. Appl. Meteor.* **6**, 386-392

Parrish, D. F., Derber, J. C., 1992. The National Meteorological Center's Spectral Statistical-Interpolation Analysis System. *Mon. Wea. Rev.* **120**, 1747–1763.

Patil, D. J. S., B. R. Hunt, E. Kalnay, J. A. Yorke, y E. Ott, 2001: Local low dimensionality of atmospheric dynamics. *Phys. Rev. Lett.* **86**, 5878-5881.

Peña, M., van den Dool, H., 2008: Consolidation of Multimodel Forecasts by Ridge Regression: Application to Pacific Sea Surface Temperature. *Journal of Climate*, **21**, 6521-6538.

Richardson, L.F., 1922: *Weather prediction by numerical process*. Cambridge University Press, Cambridge.

Rogers, E., Black, T., Ferrier, B., Lin, Y., Parrish, D., DiMego, G., 2001: Changes to the NCEP Meso Eta Analysis and Forecast System: Increase in resolution, new cloud microphysics, modified precipitation assimilation,

modified 3DVAR analysis. Disponible en <http://www.emc.ncep.noaa.gov/mmb/mmbpll/eta12tpb/>.

Ruiz, J., 2009. Aplicación de los pronósticos por ensambles a la predicción del tiempo a corto plazo sobre Sudamérica. Tesis doctoral, Depto. de Cs. de la Atmósfera y los Océanos, FCEyN, UBA.

Ruiz, J., C. Saulo, y E. Kalnay, 2009: Comparison of Methods Used to Generate Probabilistic Quantitative Precipitation Forecasts over South America. *Wea. Forecasting*, **24**, 319–336.

Saha, S., y co-autores, 2010: The NCEP Climate Forecast System Reanalysis. *Bull Amer Met. Soc.*, **91**, 1015-1057.

SAITO, K., M. KUNII, M. HARA, H. SEKO, T. HARA, M. YAMAGUCHI, T. MIYOSHI y W. WONG, 2010: WWRP Beijing 2008 Olympics Forecast Demonstration/Research and Development Project (B08FDP/RDP). Tech. Rep. MRI, 62, 210 pp. (http://www.mri-jma.go.jp/Publish/Technical/DATA/VOL_62/62_en.html).

Saulo, C., J. Ruiz, y Y.G. Skabar, 2007: Synergism between the Low-Level Jet and Organized Convection at Its Exit Region. *Mon. Wea. Rev.*, **135**, 1310–1326.

Saulo, C., S. Cardazzo, J. Ruiz, C. Campetella, A. Rolla, 2009. El sistema de pronóstico experimental del Centro de Investigaciones del Mar y la Atmósfera, *Meteorologica*, **33**, 83-97.

Schaefer, J. T., 1990: The Critical Success Index as an Indicator of Warning Skill. *Weather and Forecasting*, **5**, 570-575.

- Shutts, G. J., 2005: A kinetic energy backscatter algorithm for use in ensemble prediction systems. *Quart. J. Roy. Meteor. Soc.*, **131**, 3079–3102.
- Skamarock, W. C., y co-autores, 2008: A description of the Advanced Research WRF Version 3. NCAR Tech. Note NCAR/ TN-4751STR, 113 pp.
- Stainforth, D., y co-autores, 2005: Uncertainty in predictions of the climate response to rising levels of greenhouse gases. *Nature*, **433**, 403–406.
- Stensrud, D., Yussouf, N., Dowell, D C., Coniglio, M C., 2009: Assimilating surface data into a mesoscale model ensemble: Cold pool analyses from spring 2007. *Atmospheric Research*, [Volume 93, 1-3](#), 207-220.
- Sun, J., y co-autores, 2014: Use of NWP for Nowcasting convective precipitation Recent Progress and Challenges. *BAMS*, 409-426.
- Talagrand .O. 1997: Assimilation of observations, an introduction. *J. Met. Soc. Japan Special Issue*, 75, No 1b,191-209.
- Talagrand, O., Courtier, P. 1987: "Variational assimilation of meteorological observations with the adjoint vorticity equation. Part 1: Theory". *Quart. J. Roy. Met. Soc.*, **113**, 1311-1328
- Tan, Z., Zhang, F., Snyder, C., Rotunno, R., 2004: Mesoscale Predictability of Moist Baroclinic Waves: Experiments with Parameterized Convection. *Journal of the Atmospheric Sciencies*, **61**, 1794-1804.
- Tippett M. K., J. L. Anderson, C. H. Bishop, T. M. Hamill, J. S. Whitaker, Ensemble square-root filters, *Mon. Wea. Rev.* **131**, 1485–1490 (2003).
- Torn, R. D., Hakim, G. J. y Snyder, C. 2006. Boundary conditions for limited-area ensemble Kalman filters. *Mon. Wea. Rev.* **134**, 2490_2502.

Torn, R. D., y G. J. Hakim, 2008a: Ensemble-based sensitivity analysis. *Mon. Wea. Rev.*, **136**, 663--677.

_____, y _____, 2008b: Performance characteristics of a pseudo-operational Ensemble Kalman Filter. *Mon. Wea. Rev.*, **136**, 3947-3963.

Torn, R. D., y G. J. Hakim, 2009a: Ensemble Data Assimilation applied to RAINEX observations of Hurricane Katrina (2005). *Mon. Wea. Rev.*, **137**, 2817-2829.

_____, y _____, 2009b: Initial condition sensitivity of Western-Pacific extratropical transitions determined using ensemble-based sensitivity analysis. *Mon. Wea. Rev.*, **137**, 3388-3406.

Toth, Z., Kalnay, E., 1997: Ensemble forecasting at NCEP: the breeding method. *Mon. Wea. Rev.*, **125**, 3297-3318.

Vera, C.; Possía, M. N.; Nuñez, 1990: "Evaluación Preliminar de un sistema de asimilación de datos intermitente para la región sur de Sudamérica". *Meteorologica*, **17**, 27-32

Vera, C., 1994a: "Analysis Verification Experiments with a Statistical Interpolation System" *Mon. Wea. Rev.*, **122**, 1247-1262.

_____, 1994b: "Horizontal Structure of Height Forecast Errors over the Southern Part of South America" *Quart. Jou. Roy. Met. Soc.*, **120**, 1345-1365.

Vié, B., Nuissier, O. y Ducrocq, V. 2011. Cloud-resolving ensemble simulations of Mediterranean heavy precipitating events: uncertainty on initial conditions and lateral boundary conditions. *Mon. Wea. Rev.* **139**, 403_423.

- Vukicevic, T., y J. Paegle, 1989: The influence of one-way interacting boundary conditions upon predictability of flow in bounded numerical models. *Mon. Wea. Rev.*, **117**, 340–350.
- Vukicevic, T., y R. M. Errico, 1990: The influence of artificial factors upon predictability estimates using a complex limited-area model. *Mon. Wea. Rev.*, **118**, 1460–1482.
- Walko R., Band L., Baron J., Kittel F., Lammers R., Lee T., Ojima D., Pielke R., Taylor C., Tague C., Tremback C., Vidale P. Coupled Atmosphere-Biophysics-Hydrology Models for Environmental Modeling. *J Appl Meteorol* **39**: (6) 931-944, 2000.
- Warner, T. T., L. E. Key, y A. M. Lario, 1989: Sensitivity of mesoscale model forecast skill to some initial data characteristics: Data density, data position analysis procedure, and measurement error. *Mon. Wea. Rev.*, **117**, 1281–1310.
- Whitaker, J. S. y T. M. Hamill, 2002: Ensemble data assimilation without perturbed observations, *Mon. Wea. Rev.* **130**, 1913–1924.
- Whitaker, J. S., Hamill T. S., X. Wei, Y. Song, y Z. Toth, 2008: Ensemble data assimilation with the NCEP global forecast system. *Mon. Wea. Rev.*, **136**, 463–482.
- Whitaker, J. S. y T. M. Hamill, 2012: Evaluating methods to account for system errors in ensemble data assimilation, *Mon. Wea. Rev.* **140**, 3078–3089.
- Wilks, D. S., 2006: *Statistical Methods in the Atmospheric Sciences*. 2d ed. International Geophysics Series, Vol. 91, Academic Press, 627 pp.

- Xu, J-Y., Zhong, Q.: The Effect of Error Growth and Propagation on the Predictability of Quantitative Precipitation in a Cloud-Resolving Model, *ATMOSPHERIC AND OCEANIC SCIENCE LETTERS*, 2009, VOL. 2, NO. 2, 79–84.
- Yang, S.-C., K.-J. Lin, T. Miyoshi, y E. Kalnay, 2013: Improving the spin-up of regional EnKF for typhoon assimilation and forecasting with Typhoon Sinlaku (2008). *Tellus*, **65A**, 20804. doi:10.3402/tellusa.v65i0.20804
- Žagar, N., Gustafsson, N. y Källén,, E. (2004), Dynamical response of equatorial waves in four-dimensional variational data assimilation. *Tellus A*, **56**: 29–46. doi: 10.1111/j.1600-0870.2004.00036.x
- Zhang, F., Snyder, C., Rotunno, R., 2002: Mesoscale Predictability of the “Surprise” Snowstorm of 24-25 January 2000. *Mon. Wea. Rev.*, **130**, 1617-1632.
- Zhang, F., Snyder, C., Rotunno, R., 2003: Effects of Moist Convection on Mesoscale Predictability. *Journal of the Atmospheric Sciencies*, **60**, 1173-1185.
- Zhang, F., C. Snyder, y J. Sun, 2004: Impacts of initial estimate and observation availability on convective-scale data assimilation with an ensemble Kalman filter. *Mon. Wea. Rev.*, **132**, 1238–1253.
- Zhang, F., Bei, N., Rotunno, R., Snyder, C., Epifanio, C., 2007: Mesoscale Predictability of Moist Baroclinic Waves: Convection-Permitting Experiments and Multistage Error Growth Dynamics, *Journal of the Atmospheric Sciencies*, **64**, 3579-3594.

Zhang, F., Y. Weng, J. A. Sippel, Z. Meng, y C. H. Bishop, 2009: Cloud-Resolving hurricane Initialization and prediction through assimilation of doppler radar observations with an ensemble Kalman filter. *Mon. Wea. Rev.*, **137**, 2105–2125.



UNIVERSIDAD DE BUENOS AIRES

Facultad de Ciencias Exactas y Naturales
Departamento de Ciencias de la Atmósfera y los Océanos

**Estudio de los efectos de diferentes fuentes de error
sobre la calidad de los análisis generados por un
sistema de asimilación por filtros de Kalman**

Marcos Adolfo Saucedo

Apéndice de Figuras

Buenos Aires, 2016

CAPÍTULO 1

La asimilación de datos




Figura 1.1: Esquema de un ciclo de análisis-pronóstico de un centro mundial de pronóstico.




Figura 1.2: Esquema de un ciclo de análisis-pronóstico regional.

CAPÍTULO 2

Técnicas de asimilación de datos por ensambles y su verificación




Figura 2.1: Diagrama de diferentes KF, con sus principales debilidades (en recuadros rosa) y las técnicas de mitigación de los mismos (en recuadros azules).




Figura 2.2: Diagrama de los diferentes algoritmos de inflación desarrollados en el Capítulo 2, con sus ecuaciones principales.




Figura 2.3: Esquema de las diferentes métricas utilizadas para la verificación de los experimentos de la Tesis

CAPÍTULO 3:

Experimentos idealizados – impacto de las fuentes de error en el sistema de asimilación-pronóstico




Figura 3.1: Esquema de procesos y datos utilizados para la implementación del sistema LETKF-WRF en los experimentos idealizados. Para mayor información consultar en el texto.




Figura 3.2: Dominio utilizado para los experimentos idealizados junto con el perfil de la topografía.




Figura 3.3: Número total de observaciones de viento zonal por encima de los 300 hPa (a), entre 300 y 800 hPa (b) y por debajo de 800 hPa (c), y de presión en superficie (d) en regiones de 5° por 5° en los experimentos idealizados.




Figura 3.4: Puntos de observaciones de presión en superficie correspondientes al ciclo del día 21 de junio a las 00 UTC.




Figura 3.5: EETS de los experimentos MPBP. Marcha temporal de promedio espacial de experimento MPBP (magenta) y MPBP-NoObs (verde) (a); promedio temporal de EETS promediado en la vertical de experimento MPBP-NoObs (b) y MPBP (c); y media temporal de EETS promediado horizontalmente de experimento MPBP (magenta) y MPBP-NOOBS (verde) (d).




Figura 3.6: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) según la ecuación (2.49) para los experimentos MPBP-NoObs (a-d) y MPBP (e-h): MSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).

Error Temperatura nivel sigma 1




Figura 3.7: Promedio temporal de las componentes de los errores en temperatura en superficie ($^{\circ}\text{C}$) para los experimentos MPBP-NoObs (a-d) y MPBP (e-h): RMSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 3.8: Relación entre el Error y la dispersión del ensamble para los experimentos MPBP-NoObs (a-c) y MPBP (d-f): promedio temporal de EETS (a y d) y de dispersión de Energía Total Seca (b y e), y correlación temporal entre ambas (c y f).




Figura 3.9: Diferencia relativa promediada temporalmente entre el Error cuadrático medio y la varianza del ensamble para los experimentos MPBP-NoObs (a-c) y MPBP (d-f) según la ecuación (3.1): EETS (a y d), viento zonal en el nivel sigma 22 (aprox. 300 hPa) (b y e), y temperatura en superficie (c y f).




Figura 3.10: Promedio temporal de las componentes de EHIV (mm) para los experimentos MPBP-NoObs (a-d) y MPBP (e-h): RMSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 3.11: Relación entre el EHIV y su dispersión para los experimentos MPBP-NoObs (a-c) y MPBP (d-f): promedios temporales de RMSE (a y d) y de Spread (b y e), y correlación temporal entre ambas (c y f).




Figura 3.12: Promedio temporal de las componentes del error en precipitación acumulada cada 6 horas (mm) para los experimentos MPBP-NoObs (a-d) y MPBP (e-h): RMSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 3.13: EETS de los experimentos MPBP y MIBP. Marcha temporal de promedio espacial de experimento MPBP (verde) y MIBP (magenta) (a); promedio temporal de EETS promediado en la vertical de experimento MPBP (b) y MIBP (c); y media temporal de EETS promediado horizontalmente de experimento MPBP (verde) y MIBP (magenta) (d).




Figura 3.14: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) según la ecuación (2.49) para los experimentos MPBP (a-d) y MIBP (e-h): MSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 3.15 Promedio temporal de las componentes del error promediadas horizontalmente en geopotencial (a-d), temperatura (e-h) y viento zonal (i-l) para los experimentos MPBP (verde) y MIBP (magenta): RMSE (a, e, i), MNBIAS (b, f, j), SDBIAS (c, g, k) y No Sistemática (d, h, l).




Figura 3.16: Relación entre el Error y la dispersión del ensamble para los experimentos MPBP (a-c) y MIBP (d-f): promedio temporal de EETS (a y d) y de dispersión de Energía Total Seca (b y e), y correlación temporal entre ambas (c y f).




Figura 3.17: Promedio temporal de las componentes del error en precipitación acumulada cada 6 horas (mm) para los experimentos MPBP (a-d) y MIBP (e-h): RMSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 3.18: Marcha temporal de promedio espacial de IMA de experimento MPBP (verde) y MIBP (magenta) (a); promedio vertical y temporal de experimento MPBP (b) y MIBP (c); y promedio horizontal y temporal de experimento MPBP (verde) y MIBP (magenta) (d).




Figura 3.19: Diferencia relativa de la ecuación (3.8) para los experimentos MPBP (a-c) y MIBP (d-f) en las variables viento zonal entre 300 y 800 hPa (en %) (a,d), temperatura (en %), (b, e) entre superficie y 800 hPa, y humedad específica entre superficie y 800 hPa (en g/kg) (c, f).




Figura 3.20: EETS de los experimentos MPBP y MPBI. Marcha temporal de promedio espacial de experimento MPBP (verde) y MPBI (magenta) (a); promedio temporal de EETS promediado en la vertical de experimento MPBP (b) y MIBP (c); y media temporal de EETS promediado horizontalmente de experimento MPBP (verde) y MIBP (magenta) (d).




Figura 3.21: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) según la ecuación (2.49) para los experimentos MPBP (a-d) y MIBP (e-h): MSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemático (d y h).




Figura 3.22: Relación entre el Error y la dispersión del ensamble para los experimentos MPBP (a-c) y MPBI (d-f): promedio temporal de EETS (a y d) y de dispersión de Energía Total Seca (b y e), y correlación temporal (c y f).




Figura 3.23: Marcha temporal de promedio espacial de IMA de experimento MPBP (verde) y MPBI (magenta) (a); promedio vertical y temporal de experimento MPBP (b) y MPBI (c); y promedio horizontal y temporal de experimento MPBP (verde) y MPBI (magenta) (d).




Figura 3.24: Diferencia relativa de la ecuación (3.8) para los experimentos MPBP (a-c) y MPBI (d-f) en las variables viento zonal entre 300 y 800 hPa (en %) (a,d), y temperatura (en %) (b, e) entre superficie y 800 hPa; y diferencia absoluta en humedad específica entre superficie y 800 hPa (en g/kg) (c, f).




Figura 3.25: EETS de los experimentos MPBP y MIBI. Marcha temporal de promedio espacial de experimento MPBP (verde) y MIBI (magenta) (a); promedio temporal de EETS promediado en la vertical de experimento MPBP (b) y MIBP (c); y media temporal de EETS promediado horizontalmente de experimento MPBP (verde) y MIBI (magenta) (d).




Figura 3.26: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) según la ecuación (2.49) para los experimentos MPBP (a-d) y MIBI (e-h): MSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 3.27: Relación entre el Error y la dispersión del ensamble para los experimentos MPBP (a-c) y MPBI (d-f): promedio temporal de EETS (a y d) y de dispersión de Energía Total Seca (b y e), y correlación temporal entre ambas (c y f).




Figura 3.28: Promedio temporal de las componentes del error promediadas horizontalmente en geopotencial (a-d), temperatura (e-h) y viento zonal (i-l) para los experimentos MIBP (verde) y MIBI (magenta): RMSE (a, e, i), MNBIAS (b, f, j), SDBIAS (c, g, k) y No Sistemática (d, h, l).




Figura 3.29: Marcha temporal de promedio espacial de IMA de experimento MPBP (verde) y MIBI (magenta) (a); promedio vertical y temporal de experimento MPBP (b) y MIBI (c); y promedio horizontal y temporal de experimento MPBP (verde) y MIBI (magenta) (d).




Figura 3.30: Diferencia relativa de la ecuación (3.8) para los experimentos MPBP (a-c) y MIBI (d-f) en las variables viento zonal entre 300 y 800 hPa (en %) (a,d), y temperatura (en %) (b, e) entre superficie y 800 hPa, y diferencia absoluta en humedad específica entre superficie y 800 hPa (en g kg⁻¹) (c, f).

CAPÍTULO 4:

Experimentos idealizados – implementación de técnicas para la representación de las fuentes de error en el sistema




Figura 4.1: EETS de los experimentos MIBP y MIBP EF. Marcha temporal de promedio espacial de experimento MIBP (verde) y MIBP-EF (magenta) (a); promedio temporal de EETS promediado en la vertical de experimento MPBP-NoOBS (b) y MPBP (c); y media temporal de EETS promediado horizontalmente de experimento MIBP (verde) y MIBP-EF (magenta) (d).




Figura 4.2: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) según la ecuación (2.49) para los experimentos MIBP (a-d) y MIBP-EF (e-h): MSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 4.3: Relación entre el Error y la dispersión del ensamble para los experimentos MIBP (a-c) y MIBP EF (d-f): promedio temporal de EETS (a y d) y de dispersión de Energía Total Seca (b y e), y correlación temporal (c y f).




Figura 4.4: Promedio temporal de las componentes del error promediadas horizontalmente en geopotencial (a-d), temperatura (e-h) y viento zonal (i-l) para los experimentos MIBP (verde) y MIBP EF (magenta): RMSE (a, e, i), MNBIAS (b, f, j), SDBIAS (c, g, k) y No Sistemática (d, h, l).




Figura 4.5: Promedio temporal de las componentes del error en precipitación acumulada cada 6 horas (mm) para los experimentos MIBP (a-d) y MIBP EF (e-h): RMSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemático (d y h).




Figura 4.6: Relación entre el Error y la dispersión en precipitación acumulada cada 6 horas para los experimentos MIBP (a-c) y MIBP EF (d-f): promedios temporales de RMSE (a y d) y de dispersión (b y e), y correlación temporal entre ambas (c y f).




Figura 4.7: Marcha temporal de promedio espacial de IMA de experimento MIBP (verde) y MIBP EF (magenta) (a); promedio vertical y temporal de experimento MIBP (b) y MIBP EF (c); y promedio horizontal y temporal de experimento MIBP (verde) y MIBP EF (magenta) (d).




Figura 4.8: Diferencia relativa de la ecuación (3.8) para los experimentos MIBP (a-c) y MIBP-EF (d-f) en las variables viento zonal entre 300 y 800 hPa (en %) (a,d), y temperatura (en %) (b, e) entre superficie y 800 hPa, y diferencia absoluta en humedad específica entre superficie y 800 hPa (en g/kg) (c, f).




Figura 4.9: EETS de los experimentos MPBI y MPBI-BP. Marcha temporal de promedio espacial de experimento MPBP (verde) y MIBP (magenta) (a); promedio temporal de EETS promediado en la vertical de experimento MPBP (b) y MIBP (c); y media temporal de EETS promediado horizontalmente de experimento MPBP (verde) y MIBP (magenta) (d).




Figura 4.10: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) según la ecuación (2.49) para los experimentos MPBI (a-d) y MIBP BP (e-h): MSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 4.11: Relación entre el Error y la dispersión del ensamble para los experimentos MPBI (a-c) y MPBI BP (d-f): promedio temporal de EETS (a y d) y de dispersión de Energía Total Seca (b y e), y correlación temporal (c y f).




Figura 4.12: Marcha temporal de promedio espacial de IMA de experimento MPBI (verde) y MPBI BP (magenta) (a); promedio vertical y temporal de experimento MPBI (b) y MPBI BP (c); y promedio horizontal y temporal de experimento MPBI (verde) y MPBI BP (magenta) (d).




Figura 4.13: Diferencia relativa de la ecuación (3.8) para los experimentos MPBI (a-c) y MPBI-BP (d-f) en las variables viento zonal entre 300 y 800 hPa (en %) (a,d), y temperatura (en %) (b, e) entre superficie y 800 hPa, y diferencia absoluta en humedad específica entre superficie y 800 hPa (en g/kg) (c, f).




Figura 4.14: EETS de los experimentos MIBI y MIBI-EF-BP. Marcha temporal de promedio espacial de experimento MPBP (verde) y MPBI (magenta) (a); promedio temporal de EETS promediado en la vertical de experimento MPBP (b) y MIBP (c); y media temporal de EETS promediado horizontalmente de experimento MPBP (verde) y MIBP (magenta) (d).




Figura 4.15: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) según la ecuación (2.49) para los experimentos MIBI (a-d) y MIBI-EF-BP (e-h): MSE (a y e), MNBIAS (b y f), SDBIAS (c y g) y No Sistemática (d y h).




Figura 4.16: Relación entre el Error y la dispersión del ensamble para los experimentos MPBP (a-c) y MPBI (d-f): promedio temporal de EETS (a y d) y de dispersión de Energía Total Seca (b y e), y correlación temporal entre ambas (c y f).




Figura 4.17: Marcha temporal de promedio espacial de IMA de experimento MIBI (verde) y MIBI EF BP (magenta) (a); promedio vertical y temporal de experimento MIBI (b) y MIBI EF BP (c); y promedio horizontal y temporal de experimento MIBI (verde) y MIBI EF BP (magenta) (d).




Figura 4.18: Diferencia relativa de la ecuación (3.8) para los experimentos MIBI (a-c) y MIBI-EF-BP (d-f) en las variables viento zonal entre 300 y 800 hPa (en %) (a,d), y temperatura (en %) (b, e) entre superficie y 800 hPa, y diferencia absoluta en humedad específica entre superficie y 800 hPa (en g/kg) (c, f).

CAPÍTULO 5:

**Sensibilidad del análisis y del pronóstico a la
resolución horizontal del modelo: Experimentos
con observaciones reales**




Figura 5.1: Dominio de los experimentos de asimilación y pronóstico LETKF 60K y LETKF 20K.




Figura 5.2: Número medio de observaciones asimiladas por ciclo de análisis para el viento zonal (a-c), temperatura (d-f) y humedad específica (g-i) por encima de los 300 hPa (a, d y g), entre 300 y 800 hPa (b, e y h) y por debajo de 800 hPa (c, f e i) en regiones de 5° por 5° .




Figura 5.3: EETS con respecto al análisis GDAS de los experimentos LETKF. Marcha temporal de promedio espacial de experimento LETKF 60K (verde) y LETKF 20K (magenta) (a); promedio temporal de EETS promediado en la vertical de experimento LETKF 60K (b) y LETKF 20K (c); y media temporal de EETS promediado horizontalmente de experimento LETKF 60K (verde) y LETKF 20K (magenta) (d).




Figura 5.4: Promedio temporal de las contribuciones de las diferentes componentes del EETS integrado en la vertical (J/Kg) con respecto al análisis GDAS según la ecuación (2.49) para los experimentos LETKF 60K (a, c, e y g) y LETKF 20K (b, d, f y h): MSE (a y b), MNBIAS (c y d), SDBIAS (e y f) y No Sistemática (g y h).




Figura 5.5: Promedio temporal de las diferentes componentes del error para el viento en sus dos componentes (a-c), temperatura (d-f), presión en superficie (g-i) y EHIV (j-l) para el experimento LETKF 60K: MNBIAS (a, d, g, j), SDBIAS (b, e, h, k) y No Sistemático (c, f, i, l).




Figura 5.6: Promedio temporal de las componentes del error promediadas horizontalmente en geopotencial (a-d), temperatura (e-h), viento zonal (i-l) y humedad específica (m-p) para los experimentos LETKF 60K (verde) y LETKF 20K (magenta) con respecto al análisis GDAS: RMSE (a, e, i), MNBIAS (b, f, j), SDBIAS (c, g, k) y No Sistemático (d, h, l).




Figura 5.7: Relación entre el Error y la dispersión del ensamble para los experimentos LETKF 60K (a, c, e) y LETKF 20K (b, d, f): promedio temporal de EETS (a y b) y de dispersión de Energía Total Seca (c y d), y correlación temporal entre ambas (e y f).




Figura 5.8: Dispersión en el ensamble de análisis de los experimentos LETKF 60K (a, c, e, g) y LETKF 20K (b, d, f, h) promediada temporal y verticalmente para las componentes zonal (a, b) y meridional del viento (c, d) (m/s), temperatura (e, f) (°C) y presión en superficie (g, h) (hPa).




Figura 5.9: Marcha temporal de promedio espacial de IMA de experimento LETKF 60K (verde) y LETKF 20K (magenta) (a); promedio vertical y temporal de experimento LETKF 60K (b) y LETKF 20K (c); y promedio horizontal y temporal de experimento LETKF 60K (verde) y LETKF 20K (magenta) (d).




Figura 5.10: Promedio temporal del EETS con respecto al análisis GDAS integrado en la vertical (J/Kg) para los pronósticos LETKF 60K (a, d, y g), LETKF 20K (b, e, y h) y GDAS (c, f e i). Plazos a 24 (a, b y c), 48 (d, e y f) y 72 (g, h e i) horas.




Figura 5.11: Porcentaje de reducción/aumento del EETS integrado en la vertical (J/Kg) con respecto al pronóstico LETKF 60K para los pronósticos LETKF 20K (a, c y e) y GDAS (b, d y f). Plazos a 24 (a y b), 48 (c y d) y 72 (e y f) horas.




Figura 5.12: RMSE medio para los pronósticos LETKF 60K (rojo), LETKF 20K (verde) y GDAS (azul) a 24 horas de viento zonal (a) y meridional (b), temperatura (c) y humedad específica (d).




Figura 5.13: RMSE medio para los pronósticos LETKF 60K (rojo), LETKF 20K (verde) y GDAS (azul) para viento zonal (a), presión en superficie (b), temperatura (c) y humedad específica (d) desde el tiempo inicial hasta 72 horas de pronóstico.




Figura 5.14: Bias (a, c y e) y ETS (b, d y f) medio para los pronósticos LETKF 60K (rojo), LETKF 20K (verde) y GDAS (azul) para los umbrales de 1 (a y b), 10 (c y d) y 100 (e y f) mm desde el tiempo inicial hasta 72 horas de pronóstico.




Figura 5.15: Trayectoria del tifón SINLAKU dado por los análisis y el RSMC (a), error medio en localización del ciclón a diferentes plazos de pronóstico (b), marcha temporal de presión mínima del tifón estimada por el RMSC y por los análisis (c), RMSE de presión mínima del tifón en los pronósticos (d), marcha temporal del viento máximo del tifón estimada por el RSMC y por los análisis (e) y RMSE de viento máximo del tifón dado por los pronósticos (f).




Figura 5.16: Ídem Figura 5.15 para el tifón HAGUPIT.




Figura 5.17: Ídem Figura 5.15 para el tifón JANGMI.




Figura 5.18: Campo inicial (a-c) y pronosticado a 24 horas (d-f) de presión a nivel del mar (contornos) e intensidad del viento a 10 metros (sombreado, m/s) correspondientes al tifón JANGMI a las 12 UTC del 26 de septiembre de 2008. En asteriscos verdes se indica la posición real del sistema, junto con la intensidad y profundidad.