



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO  
POSGRADO EN CIENCIAS DE LA TIERRA  
CENTRO DE CIENCIAS DE LA ATMÓSFERA

Sensibilidad de WRF ante condiciones iniciales y de frontera:  
Un estudio de caso en el Valle de México

TESIS

QUE PARA OPTAR POR EL GRADO DE:  
MAESTRO EN CIENCIAS DE LA TIERRA

PRESENTA:

OSCAR ESLI JURADO DE LARIOS

TUTOR:  
DR. ANGEL RUIZ ANGULO  
CENTRO DE CIENCIAS DE LA ATMÓSFERA

Ciudad Universitaria, Cd. Mx., Julio 2017



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

## Agradecimientos

Agradezco a la UNAM por todo el apoyo y oportunidades que me han brindado a lo largo de toda mi carrera académica. Agradezco también a la Facultad de Ciencias y a todos mis profesores por toda la ayuda, preparación y orientación que me brindaron durante la licenciatura. Gracias al Centro de Ciencias de la Atmósfera por toda la preparación y experiencia que me ha brindado estos últimos años. Agradezco también al Laboratorio de Fluidos Geofísicos del CCA, por toda la práctica y experiencia que me brindó en mis proyectos de la maestría. Gracias al CONACyT por todo el apoyo que me brindaron para la realización de mis estudios de posgrado y por otorgarme una beca nacional de posgrado. Gracias al proyecto PAPIIT IA100915 y IA101614.

Gracias a mi asesor, el Dr. Angel Ruiz Angulo por su guía, consejos, regaños y amistad durante la elaboración de esta tesis. Agradezco también al Dr. Arturo Quintanar y al Dr. Benjamín Martínez por todo su apoyo desde la licenciatura. Agradezco también al Dr. Arón Jazcilevich por su ayuda en mi comité tutorial del posgrado. Muchas gracias a la Dra. Claudia Inés Rivera Cárdenas, al Dr. Harry Alvarez Ospina y al Taller de Meteorología de la Facultad de Ciencias por su invaluable apoyo para llevar a cabo el proyecto del club de meteorología de la Facultad de Ciencias, nimbus, el cual fue un gran contribuyente a muchas de las ideas desarrolladas en este trabajo. Gracias también a la Dra. Erika Danaé López y el Dr. Cuauhtémoc Turrent Thompson por su participación como mis sinodales, cuyas valiosas contribuciones e ideas hicieron posible el completar este trabajo de tesis. Agradezco especialmente al M. en C. Octavio Gómez Ramos por su asistencia técnica en el uso del cluster Ometeotl para realizar las simulaciones y al grupo Interacción Océano Atmósfera por su apoyo para hacer uso de este cluster.

Muchas gracias también a todas aquellas personas que me brindaron su amistad, consejos y ayuda en estos interesantes años de maestría. HM, tu sabes que este logro no hubiera sido posible sin ti. A mis compañeros de laboratorio, quienes hicieron que estar en el CCA siempre fuera toda una aventura: Andrea, Víctor, Abril y Josue. A mis amigos de CT, por toda su ayuda y consejos: Diego, Xanath, Lupita, Jardín, Citlali, Javier, Luis, Andrea, Edgar, Raiza, Bernardo y todos los demás. Gracias a Biotita y Adularia por no comerse mis papeles de titulación.

Agradezco sobre todo a mis padres, Alma y Beto, así como a mis abuelos, Rosita, Ricardo, María y Humberto, por todo su apoyo y dedicación, los cuales me permitieron llegar hasta donde estoy. ¡Este logro es suyo!

*Dedicado a Ricardo y Rosita, por impulsarme siempre a ser mejor.*



# Resumen

El propósito de este trabajo es cuantificar la respuesta que muestra el modelo de Pronóstico Numérico del Tiempo (PNT) de escala regional más utilizado en el Valle de México: Weather Research & Forecasting (WRF) ante condiciones iniciales y de frontera de diferente resolución espacial. La finalidad de esto es determinar como se ve afectada la calidad de la salida del pronóstico numérico al cambiar las condiciones iniciales. Dos resoluciones diferentes del modelo de PNT global Global Forecasting System (GFS) son utilizadas como condiciones iniciales y de frontera para inicializar el modelo WRF. Las salidas del modelo WRF son comparadas con las observaciones existentes dentro del dominio mediante un esquema de verificación de pronóstico para determinar la diferencia en calidad entre estas, permitiendo entonces estimar cuantitativamente la sensibilidad del modelo WRF para la región de estudio.

El esquema de verificación aplicado a los pares observación-pronóstico utilizó 5 medidas para datos discretos (probabilidad de precipitación y temperatura): proporción correcta, puntaje de amenaza, sesgo, probabilidad de detección, probabilidad de falsa detección, razón de falsa alarma y del puntaje de habilidad de Heidke. Para los datos continuos (temperatura y magnitud de la velocidad del viento) se evaluaron: el error cuadrático medio, el error medio absoluto y el error medio. También se estudiaron dos métodos gráficos: diagramas de Taylor y gráficos cuantil-cuantil. Los resultados fueron representados gráficamente en un mapa para observar la distribución espacial de los errores y comparar entre las salidas iniciadas con ambas resoluciones, observando un error generalizado del modelo en ambas resoluciones para pronosticar adecuadamente las tres variables utilizadas, sobre todo en la temporada de lluvias.

Posteriormente se realizó una prueba de diferencia de medias para determinar si existía una diferencia significativa entre los errores resultantes de las simulaciones con ambas resoluciones, usando un método no paramétrico de re-muestreo con bootstrap para determinar intervalos de confianza de la media de las diferencias. Los resultados mostraron que en la región mas plana de la ZMVM no hubo una diferencia significativa entre los errores; mientras que en las regiones con topografía más marcada, i.e. las montañas que rodean al Valle. La mayor parte de las estaciones mostraron una diferencia significativa entre los errores. Esta diferencia se adjudica a la mayor capacidad que muestra el modelo GFS para resolver zonas de topografía complicada cuando aumenta su resolución espacial, mientras que en zonas con topografía plana este aumento de resolución posiblemente no generaría cambios importantes en la salida para regiones pequeñas.

Se concluye que el modelo muestra una sensibilidad baja ante condiciones iniciales y de frontera para el dominio utilizado. Esto conlleva a que mejorar la resolución espacial de las condiciones iniciales y de frontera no mejora el pronóstico al ser comparados con las observaciones. El uso de condiciones iniciales de mayor resolución no mostró una mejoría en la comparación estudiada en esta tesis. En base a estudios previos, se asocia la mayor

f fuente de error a que la máxima resolución simulada pertenece a la denominada “zona gris” de modelación de procesos convectivos y de microfísica. Se propone como solución el cambio de la resolución de  $6,6/18km$  (actuales) a  $5/15km$  o  $3/9km$ . Otra posibilidad es el cambio en el uso de las parametrizaciones, cambiando de un esquema mixto de microfísica y cúmulos a únicamente el uso de uno de estos, dependiendo de la resolución. Finalmente, se sugiere que la implementación operacional de verificación para los pronósticos numéricos en el Valle de México sea llevada a cabo lo antes posible para tener una mejor idea de como mejorar los pronósticos basados en estos modelos.

# Índice general

<b>Índice de figuras</b>	<b>VIII</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Antecedentes . . . . .	1
1.1.1. La Cuenca de México . . . . .	2
1.1.2. Pronóstico numérico en la Cuenca de México . . . . .	3
1.1.3. Estudios de sensibilidad para el modelo WRF . . . . .	3
1.2. Marco Teórico . . . . .	4
1.2.1. Pronósticos Numéricos del Tiempo . . . . .	4
1.2.2. Predecibilidad de la atmósfera . . . . .	5
1.2.3. Inicialización de los modelos numéricos . . . . .	6
1.2.4. Verificación de pronóstico . . . . .	8
<b>2. Método</b>	<b>19</b>
2.1. Diseño del experimento numérico . . . . .	19
2.2. Base de datos observación-pronóstico . . . . .	20
2.2.1. Observaciones de superficie . . . . .	20
2.2.2. Pares de datos observación-pronóstico . . . . .	22
2.3. Verificación de pronóstico . . . . .	25
2.3.1. Datos continuos . . . . .	25
2.3.2. Datos discretos . . . . .	25
2.4. Análisis de sensibilidad . . . . .	26
2.4.1. Estimación de intervalos de confianza. . . . .	26
2.4.2. Diagramas de bosque . . . . .	27
<b>3. Resultados y Discusión</b>	<b>30</b>
3.1. Verificación de pronóstico . . . . .	30
3.1.1. Precipitación . . . . .	30
3.1.2. Temperatura . . . . .	34
3.1.3. Magnitud de la velocidad del viento . . . . .	36
3.2. Sensibilidad ante condiciones iniciales y de frontera . . . . .	46

---

3.2.1. Temperatura . . . . .	46
3.2.2. Viento . . . . .	56
<b>4. Conclusiones</b>	<b>64</b>
<b>Referencias</b>	<b>66</b>
<b>Anexos</b>	<b>70</b>
<b>A. namelist.input</b>	<b>71</b>

# Índice de figuras

1.1. Mapa representativo de la región de estudio. . . . .	2
1.2. Izquierda: Simulación temperatura GFS con 0.50 grados de resolución horizontal. Derecha: Simulación temperatura GFS con resolución horizontal de 0.25 grados. . . . .	9
1.3. Ejemplo de una tabla de contingencia de 2x2. . . . .	14
2.1. Dominio de la simulación mostrando el dominio principal de 20 km y el dominio anidado de 6.6 km. . . . .	21
2.2. Mapa de estaciones analizadas en el Valle de México y alrededores. . . . .	21
2.3. Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA iguala para el mes de Noviembre 2015. . . . .	23
2.4. Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA imteag para el mes de Noviembre 2015. . . . .	23
2.5. Mapa de estaciones y puntos de malla más cercanos. . . . .	24
2.6. Distribución de las estaciones en la Cuenca de México y en la Cuenca del río Balsas. . . . .	28
2.7. Histograma de la distribución empírica resultante al usar el método de remuestreo de <i>bootstrap</i> para la media $t^*$ de las diferencias del EMA para la estación CUA en la temporada húmeda. . . . .	29
3.1. Mapas de Proporción Correcta (PC) para la temporada húmeda. . . . .	32
3.2. Mapas de Puntaje de Amenaza (PA) para la temporada húmeda. . . . .	32
3.3. Mapas de Razón de Falsa Alarma (RFA) para la temporada húmeda. . . . .	33
3.4. Mapas de Sesgo para la temporada húmeda. . . . .	33
3.5. Diagrama de Taylor para la variable temperatura, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	36
3.6. Diagrama de Taylor para la variable temperatura, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	37

3.7. Diagrama de Taylor para la variable temperatura, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	37
3.8. Comparación del error cuadrático medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	38
3.9. Comparación del error medio absoluto para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	39
3.10. Comparación del error medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	40
3.11. Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Acolman. . . . .	41
3.12. Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Escuela Nacional de Ciencias Biológicas 2. . . . .	42
3.13. Diagrama cuantil-cuantil para la temperatura en la estación Acolman. . . . .	43
3.14. Diagrama cuantil-cuantil para la temperatura en la estación Encb02. . . . .	44
3.15. Diagrama de Taylor para la variable magnitud del viento, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	47
3.16. Diagrama de Taylor para la variable magnitud del viento, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	47
3.17. Diagrama de Taylor para la variable magnitud del viento, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	48
3.18. Comparación del error cuadrático medio para la variable magnitud del viento a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	49
3.19. Comparación del error medio absoluto para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación. . . . .	50
3.20. Comparación del error medio para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación. . . . .	51
3.21. Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación Ajusco. . . . .	52
3.22. Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación UAM Xochimilco. . . . .	53
3.23. Diagrama cuantil-cuantil para la magnitud del viento en la estación Ajusco. . . . .	54
3.24. Diagrama cuantil-cuantil para la magnitud del viento en la estación de la UAM Xochimilco (UAX). . . . .	55
3.25. Diagrama de bosque de temperatura para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	57

3.26. Diagrama de bosque de temperatura para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	58
3.27. Diagrama de bosque de temperatura para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	59
3.28. Diagrama de bosque de viento para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	61
3.29. Diagrama de bosque de viento para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	62
3.30. Diagrama de bosque de viento para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	63

# Capítulo 1

## Introducción

Los modelos de predicción numérica del tiempo (PNT) son una de las herramientas más utilizadas por meteorólogos para emitir pronósticos del tiempo (Warner, 2010). Esto es una consecuencia directa de los grandes avances en la computación y el almacenamiento digital: el avance en poder de cómputo puro hizo que el pronóstico operacional con base en modelos numéricos fuera viable. Los modelos de PNT son de gran importancia en regiones tropicales en donde el uso de otras fuentes de información puede no estar disponible, no ser confiable o ser muy pobre para dar una interpretación completa de la atmósfera (Laing, 2011). Un ejemplo se da en la región del Valle de México, en donde el pronóstico del tiempo diario es auxiliado por salidas de modelos de PNT de escala regional. Dichos modelos regionales son inicializados usando salidas de modelos de PNT de escala global. Cabe destacar que aunque se ha observado que los modelos regionales son muy sensibles ante las condiciones iniciales y de frontera usados para inicializarlos, no existen estudios para cuantificar dicha sensibilidad para el Valle de México.

El propósito de este trabajo es cuantificar la respuesta que muestra el modelo de predicción numérica del tiempo (PNT) de escala regional más utilizado en el Valle de México, *Weather Research & Forecasting* (WRF) (Skamarock et al., 2005), ante un cambio en la resolución espacial de condiciones iniciales y de frontera. Este estudio tiene como finalidad determinar como se ve afectada la calidad de la salida del pronóstico numérico al cambiar estos parámetros. Dos resoluciones diferentes del modelo de PNT global *Global Forecasting System* (GFS) son usadas como condiciones iniciales y de frontera para inicializar el modelo WRF. Las salidas del modelo WRF fueron comparadas contra observaciones en la región mediante un esquema de verificación de pronóstico para determinar la diferencia en calidad entre éstas al inicializar con una resolución o con otra. De esta manera se estimó cuantitativamente la sensibilidad del modelo WRF para la región de estudio.

### 1.1. Antecedentes

Para el presente estudio se eligió la región que comprende al Valle de México. El Valle de México es una subcuenca endorreica dentro de la Cuenca de México, siendo uno de los cuatro valles principales de la cuenca. Este valle es de interés ya que comprende casi en su totalidad a la Zona Metropolitana del Valle de México (ZMVM), que a su vez está conformada por la Ciudad de México y municipios aledaños. La mancha urbana de la ZMVM se puede apreciar en la Figura 1.1.



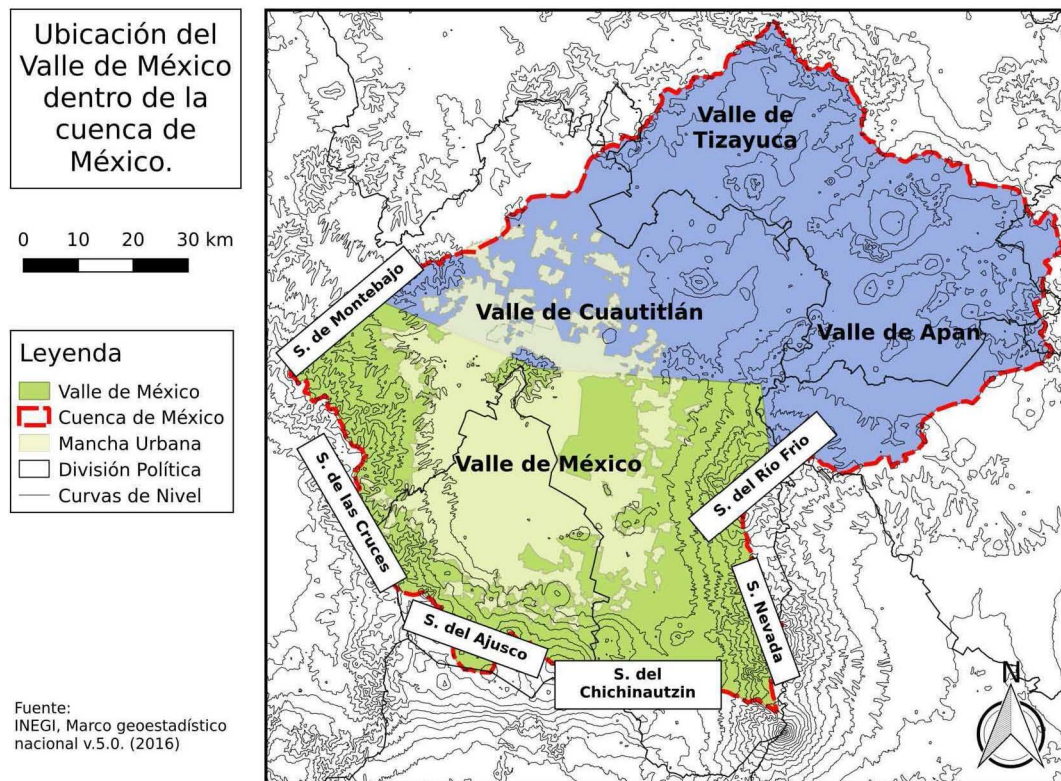


Figura 1.1: Mapa representativo de la región de estudio.

### 1.1.1. La Cuenca de México

La Cuenca de México es una cuenca endorreica con diferentes salidas hidrológicas artificiales (Imaz, 1989). A lo largo de su historia, diferentes modificaciones antropogénicas han modificado la distribución espacial de ríos a favor de un sistema de drenaje que transporta el agua afuera del valle.

Geográficamente, la Cuenca del Valle de México se puede pensar como una “unidad atmosférica”. Esto es debido a que es una región semiplana situada a una altura de 2240 m s.n.m. en promedio rodeada casi por completo por una cadena montañosa integrada por las formaciones de la Sierra de Monte Bajo, Sierra de las Cruces, Sierra del Ajusco, Sierra del Chichinautzin, Sierra Nevada y la Sierra de Río Frío, como se observa en la Figura 1.1.

La climatología de la Cuenca de México está comprendida por 4 subtipos de clima principales: seco, templado húmedo, subhúmedo y templado, lo cual es resultado de las diferencias de elevación y relieve del terreno (Fenn et al., 2002).

De acuerdo con Fenn et al. (2002) y Fast et al. (2007), el clima de la cuenca está determinado por dos flujos regionales de gran escala que se alternan durante el año. El primero está formado por los vientos del oeste (usualmente secos) que llegan a la región durante el invierno y primavera. El segundo está constituido por la corriente de vientos alisios que trae humedad a la región de mayo a octubre. Esta dinámica permite distinguir tres estaciones en la Cuenca de México:

- La estación seca cálida, de marzo a mayo;
- La estación seca fría, de noviembre a febrero; y

- La estación húmeda (o de lluvias), que se presenta desde mediados de mayo y se vuelve más evidente entre junio y octubre.

### 1.1.2. Pronóstico numérico en la Cuenca de México

Las condiciones histórico-geográficas de la ZMVM han resultado en una fuerte vulnerabilidad de la ciudad ante eventos hidrometeorológicos, en particular inundaciones (Domínguez Mora, 2000). Lo anterior es la razón por la cual el pronóstico del tiempo tiene un papel crucial en el desarrollo de muchas actividades sociales y económicas de la región. Debido a esto, la calidad que ofrecen los sistemas de pronóstico operativos en la región han sido cuestión de gran interés para la comunidad meteorológica.

Actualmente, diversos organismos gubernamentales y privados hacen uso del modelo WRF como herramienta principal de pronóstico. Un ejemplo de lo anterior es el pronóstico numérico diario emitido por el Servicio Meteorológico Nacional (SMN) mexicano, el Sistema de Monitoreo Atmosférico de la Ciudad de México (SEDEMA), el Centro de Ciencias de la Atmósfera de la UNAM, el Instituto Mexicano de Tecnología del Agua (IMTA), etc. Sin embargo, pocos estudios se han realizado en la región sobre la calidad que ofrecen dichos pronósticos numéricos. (Magaña et al., 2013) realizaron una evaluación de la calidad del pronóstico de precipitación obtenido con el modelo MM5 (antecesor del modelo WRF) llegando a la conclusión de que era poco adecuado para estimar tanto la intensidad como la región de la precipitación. Zhang et al. (2009) realizaron una verificación del modelo WRF-chem para las variables meteorológicas medidas durante la campaña MILAGRO, encontrando que era capaz de resolver relativamente bien la variabilidad temporal de temperatura, humedad relativa y magnitud del viento, presentando un fuerte sesgo en la temperatura durante el día y un error grande en la dirección del viento. El SMN recientemente comenzó un programa de verificación numérico para la precipitación, haciendo uso de varias de las técnicas utilizadas en este trabajo (Servicio Meteorológico Nacional, s.f.).

### 1.1.3. Estudios de sensibilidad para el modelo WRF

Diversos estudios han determinado la sensibilidad del modelo WRF ante varios factores en diferentes regiones. Aligo et al. (2007) estudiaron la sensibilidad del modelo al cambiar las condiciones iniciales de humedad del suelo, haciendo uso de diferentes medidas de verificación para cuantificar los cambios entre simulaciones. Aligo et al. (2007) encontraron una sensibilidad elevada ante cambios de humedad del suelo en regiones con sistemas convectivos, pero no encontraron que el cambio fuera tan amplio para modificar la precipitación significativamente en todo el dominio analizado. Etherton y Santos (2008) realizaron un estudio de sensibilidad del modelo ante un cambio de resolución espacial de condiciones iniciales para evaluar campos de precipitación en Florida del Sur, encontrando una mejoría importante en los pronósticos para las primeras horas al usar una resolución espacial mas pequeña. Para este estudio se realizó una comparación de diversas medidas de verificación de pronóstico como el puntaje de amenaza y el error cuadrático medio al cambiar las condiciones iniciales (C.I.) para cada simulación. Case et al. (2008) estudiaron la sensibilidad en la misma región, pero en este caso cambiando el tipo de modelo de humedad y de suelo entre simulaciones. Para evaluar la sensibilidad, los autores usaron diferencias entre error cuadrático medio y sesgo de las simulaciones, observando una sensibilidad fuerte del modelo ante el cambio de tipos de suelo. Jin et al. (2010) realizaron un estudio de sensibilidad del modelo ante diferentes parametrizaciones de superficie para la

región oeste de Estados Unidos. Estos autores hicieron uso de 4 esquemas de superficie diferentes, comparando los resultados con diagramas de Taylor para determinar qué tan sensible era el modelo ante estos cambios. Ruiz et al. (2010) estudiaron la sensibilidad del modelo ante diferentes parametrizaciones convectivas, de capa límite y de suelo usando cambios en error cuadrático medio y en sesgo comparando con las observaciones. Estos autores hacen hincapié en que las mejoras en la calidad de los pronósticos dependerán siempre de identificar adecuadamente qué errores en el diseño de la simulación conllevan a la propagación de los mismos. Globalmente todos estos estudios hicieron uso de alguna medida de verificación para estimar la sensibilidad del modelo, encontrando diferentes conclusiones de acuerdo al diseño y el objetivo de cada experimento. Otros estudios han hecho uso de ensambles y el método adjunto como lo hicieron Blázquez y Nuñez (2009) para el estudio de la sensibilidad del modelo ante el cambio de parametrizaciones de convección, encontrando una sensibilidad moderada en un dominio sur de Sudamérica.

La sensibilidad del modelo WRF para regiones tropicales es un tema menos estudiado que para las latitudes medias. (Flaounas et al., 2011) realizaron un estudio de sensibilidad ante diferentes esquemas de convección y capa límite para la región tropical de África afectada por el monzoon de África del este. En este estudio se usaron diferentes parametrizaciones de convección y capa límite para determinar qué salida se aproximaba más a las observaciones. Se observó una fuerte sensibilidad del modelo para simular escalas de alrededor de 50 km, especialmente en temporada de monzoon. Como conclusión del estudio, los autores recomiendan diseñar el experimento numérico de acuerdo a las propiedades de la región y los fenómenos a modelar, ya que cada uno requiere de una representación física diferente. De manera similar a este estudio, (Crétat et al., 2012) realizaron un estudio de sensibilidad ante parametrizaciones de cumulos, microfísica y capa límite en la región de África del Sur. En este caso el sesgo con respecto de las observaciones se usó para determinar la sensibilidad, empleando mapas para evaluar los cambios. Se observó una sensibilidad importante del modelo a la elección de esquemas de microfísica y convección, sin llegar a una conclusión definitiva de cuál es el mejor esquema para el pronóstico de precipitación.

En relación al Valle de México, López-Espinoza et al. (2012) realizaron un estudio de sensibilidad ante cambios de uso de suelo en las condiciones iniciales, observando una mejoría en la temperatura pronosticada al usar una base de datos de suelo más actualizada. Hasta el momento de elaboración de este trabajo, ningún estudio de sensibilidad ante diferentes resoluciones de las condiciones iniciales y de frontera para el Valle de México fue encontrado.

## 1.2. Marco Teórico

### 1.2.1. Pronósticos Numéricos del Tiempo

El pronóstico del tiempo es una de las piezas de información más utilizadas por la población en general, sirven para responder preguntas básicas como la vestimenta que conviene usar durante el día o para responder preguntas más complejas como el lugar más óptimo para colocar una planta de energía eólica. Es por esto que la *calidad* del pronóstico (que se puede pensar como la aproximación de lo pronosticado con lo observado) es un aspecto de gran interés para muchos científicos. Aunque se han logrado grandes avances desde el siglo XIX con Bjerkness y la fundación de la escuela de meteorología sinóptica, se podría argumentar que un gran avance se ha logrado gracias a la llegada de la llamada

*Predicción Numérica del Tiempo* (PNT o *NWP*, por sus siglas en inglés) (Warner, 2010; Lynch, 2006).

La PNT parte de que la atmósfera es un sistema físico bien conocido, en donde se conocen las ecuaciones que rigen tanto el movimiento como la conservación de masa y energía. Si resolvemos este sistema de ecuaciones utilizando como condiciones iniciales y de frontera observaciones provenientes de estaciones meteorológicas en superficie, radiosondeos, datos de satélite y radar, será posible conocer la evolución de la atmósfera. En teoría, esta idea podría funcionar idealmente si conociéramos el estado inicial de la atmósfera *en cada punto*, así como una solución a las ecuaciones primitivas que la describen. Ambas condiciones tienen limitaciones físicas importantes. En primera, conocer por completo las condiciones iniciales implicaría tener estaciones de medición en cada punto de la Tierra. En segunda las ecuaciones primitivas son ecuaciones diferenciales parciales no lineales de segundo orden, lo que hace que encontrar una solución analítica sea muy difícilmente alcanzable. Ante estas dificultades, una estrategia surgió para obtener soluciones por medio de métodos numéricos para integrar en el tiempo las ecuaciones primitivas (Lynch, 2006), (Warner, 2010). Dicha estrategia requiere realizar una discretización de las ecuaciones y del dominio que se desea simular, un problema que no es trivial.

El uso de esta estrategia para la PNT requiere de una cantidad gigantesca de operaciones en un periodo corto de tiempo. Aunque en la época de Richardson (pionero en el uso de estos modelos) esto era casi imposible, hoy en día el gran desarrollo que ha tenido el hardware de las computadoras permite la implementación de los modelos de PNT para ayudar a los meteorólogos a generar pronósticos del tiempo diarios y cada vez con mayor calidad. Es importante notar que esta mejoría proviene de dos aspectos: la gran rapidez con la que se pueden realizar las operaciones requeridas por los métodos numéricos para resolver las ecuaciones primitivas (poder crudo); así como la rápida integración de la información proveniente de todos los sensores meteorológicos que existen (estaciones, radiosondas, satélites, radares, etc) en un producto que pueda ser utilizado para alimentar los métodos numéricos (observaciones).

El uso de la PNT como auxiliar para realizar pronósticos del tiempo es especialmente marcado en regiones donde la red de observaciones meteorológicas es insuficiente, poco confiable o inexistente. Un ejemplo de esta región está en la región tropical, la cual presenta una escasez de estaciones de medición atmosférica (Laing, 2011). Debido a esto es común que los meteorólogos en la región dependan de salidas de modelos de PNT como su principal fuente de información. Como se mencionó anteriormente, la ZMVM es un ejemplo de una región tropical en donde el PNT es usado de manera habitual para emitir pronósticos.

### 1.2.2. Predecibilidad de la atmósfera

Los modelos de predicción numérica del tiempo tienen un tiempo finito de validez (Lynch, 2006). Esta característica fue ampliamente estudiada por Lorenz, quien realizó diversos estudios sobre la estabilidad de sistemas dinámicos resumiendo sus resultados en su libro *The Essence of Chaos* (Lorenz y Martin, 1995). Lorenz postuló el teorema fundamental de la predecibilidad: los sistemas inestables tienen un límite finito de predecibilidad, mientras que los sistemas estables son infinitamente predecibles, ya sea por soluciones estacionarias o periódicas. Adicionalmente, Lorenz argumenta que la atmósfera es un sistema inestable, dando origen a la idea de que "el aleteo de las alas de una mariposa en Brasil podría afectar la aparición de un tornado en Texas", el comportamiento de la

atmósfera es inestable ante pequeñas perturbaciones en la misma.

El descubrimiento de Lorenz fue de vital importancia para el desarrollo de la PNT, poniendo un límite temporal superior a la predecibilidad que pueden alcanzar dichos métodos (estimado como dos semanas por el mismo Lorenz). Dicha predecibilidad está directamente relacionada con las condiciones iniciales y de frontera usadas para inicializar el modelo, ya que pequeñas diferencias en las condiciones iniciales (C.I.) eventualmente resultan en diferencias significativas en los resultados del pronóstico. Esto da pie al concepto de *sensibilidad* de un modelo de PNT ante condiciones iniciales, definido como la cuantificación de qué tan grande es la diferencia entre salidas de un mismo modelo inicializado con condiciones iniciales *ligeramente* diferentes. Para el campo del PNT la sensibilidad de un modelo es una de las propiedades más importantes, dado que las condiciones iniciales usualmente provienen de instrumentos de medición sujetos a incertidumbre (e.g errores en los equipos, de medición, de comunicación). Lo ideal para un PNT es que muestre una especie de “resistencia” ante la incertidumbre en las condiciones iniciales, de tal manera que al avanzar en el tiempo el pronóstico no difiera mucho de las observaciones.

En un aspecto más operacional, Rabier et al. (1996) determinaron el efecto en el error del pronóstico debido a la sensibilidad mostrada por un modelo de PNT ante cambios ligeros de condiciones iniciales. Este estudio fue realizado teniendo en mente modelos de PNT de escala regional. Rabier demostró que cambios ligeros en las condiciones iniciales pueden tener una contribución importante en los errores de pronóstico dado por los modelos de PNT. Este estudio particular se enfocó en el modelo ECMWF (*European Center for Medium-Range Weather Forecasts*). Posteriormente Gustafsson et al. (1998) demostraron que no solamente las condiciones iniciales jugaron un papel en el error de dichos modelos, sino que las condiciones de frontera aportaron gran parte del error. Warner et al. (1997) realizaron un resumen destacando la gran importancia que tienen las condiciones de frontera como limitante de los modelos de PNT regionales, enumerando varias recomendaciones para minimizar el error causado por un mal uso de estas condiciones.

Tanto Rabier como Gustafsson utilizaron para el estudio de sensibilidad el método adjunto. Dicho método (desarrollado para la asimilación de datos) calcula primero el gradiente del error del pronóstico con respecto a las condiciones iniciales. Posteriormente se sustrae de las condiciones iniciales un vector proporcional a dicho gradiente para generar un nuevo “análisis”. Dicho análisis es entonces utilizado como condición inicial para una nueva simulación, la cual puede verse como una integración en sensibilidad. Los resultados de esta simulación, al compararlos con los de la primera simulación, sirven como un diagnóstico de la sensibilidad. Rabier propone el uso de dicho “análisis” para mejorar de manera iterativa y en tiempo real el pronóstico de los modelos de PNT operacionales de escala regional. Otra estrategia para el estudio de sensibilidad es aquella utilizada para la mayor parte de estudios de esta propiedad del modelo WRF, consistiendo en usar diferencias en medidas de verificación como un proxy para medir la sensibilidad del modelo (Aligo et al., 2007), (Etherton y Santos, 2008), (Case et al., 2008).

### 1.2.3. Inicialización de los modelos numéricos

Los estudios mencionados muestran que los modelos de PNT regionales muestran una sensibilidad ante las condiciones iniciales y de frontera utilizadas para alimentarlos. Conviene entonces ahondar un poco en como son inicializados los modelos de PNT de escala regional. Esto debido a que para el pronóstico a corto plazo, dicha escala es la más utilizada por meteorólogos para emitir un pronóstico.

La habilidad de un pronóstico *adecuado* requiere que el modelo sea una representación adecuada de la realidad y que las condiciones iniciales y de frontera sean conocidas con certeza. Las condiciones iniciales necesitan cumplir adicionalmente con una suposición muy importante: deben de estar *balanceadas*. El balance de las condiciones iniciales implica eliminar movimientos oscilantes con frecuencias que no se disipan rápidamente en la atmósfera. A grandes rasgos, dos tipos de movimientos prevalecen en la atmósfera. En primera están aquellas perturbaciones de alta frecuencia que viajan con velocidad de fase de cientos de metros por segundo (ondas de inercio-gravedad). En segunda tenemos aquellos movimientos de baja frecuencia del orden de diez metros por segundo. Estas últimas perturbaciones son de mayor interés meteorológico, ya que la mayor parte de la energía esta contenida en estos grandes movimientos rotacionales, aproximados usualmente mediante el balance geostrófico. Esta distinción es importante ya que en la atmósfera existe un balance sutil y delicado entre el viento y el campo de presión, tal que las perturbaciones de alta frecuencia son disipadas rápidamente cuando se crean con tal de favorecer que su amplitud sea siempre mucho menor que los movimientos de baja frecuencia (Lorenz y Martin, 1995). Las condiciones iniciales no siempre cumplen esta suposición, por lo que es necesario modificarlas de tal manera que no contengan movimientos de alta frecuencia que se puedan propagar sin disipación. Cuando las condiciones iniciales cumplen con esta condición, se dice que están balanceadas.

Si las condiciones iniciales no están balanceadas de tal manera que no contengan perturbaciones de alta frecuencia, las perturbaciones se propagaran en el modelo. Esto usualmente resultará en que la simulación muestre resultados muy diferentes a lo observado. Un ejemplo muy famoso de esto fue la primer predicción numérica de Richardson, en donde estos tipos de movimientos hicieron que pronosticara una presión superficial 146 veces más grande que la observada (Lynch, 2006).

La *inicialización* es la técnica mediante la cual se asegura que las condiciones iniciales cumplirán con la condición de balance necesaria para un modelo de PNT. El objetivo de dicha técnica es definir los campos iniciales de tal manera que las ondas de inercio-gravedad sean pequeñas durante toda la simulación. Nótese que esto no implica que las condiciones iniciales estarán mas aproximadas a la realidad, simplemente se busca que no contengan movimientos de alta frecuencia.

Dentro de los métodos de inicialización más utilizados se encuentra el desarrollado en Machenhauer (1977). Dicho método propone fijar la tasa de crecimiento de perturbaciones de frecuencia alta en cero, con el proposito de que éstas mantengan amplitudes pequeñas durante toda la simulación. Este método, conocido como el método de inicialización de modos normales no lineal (NNMI por sus siglas en inglés), es sumamente eficaz. Posteriormente Daley en 1991 formuló un método basado en procesamiento digital de señales conocido como el *filtro digital* (Daley, 1991). Este método fue formulado para inicializar modelos de área limitada, ya que el método NNMI es complicado de usar con estos modelos. Un ejemplo de un modelo de área limitada que utiliza esta técnica de inicialización es el modelo WRF (a partir de su versión 3.1) (Smirnova et al., 2009).

### Inicialización de modelos regionales

Los modelos de escala regional comúnmente hacen uso de salidas de los modelos globales como los datos para su inicialización. Dichos modelos globales a su vez son inicializados usando campos provenientes de observaciones, mediante un proceso conocido como *asimilación de datos*. La asimilación de datos es un problema no trivial, ya que posee problemas

matemáticos complejos de interpolación y validación de datos. En cierta manera podemos decir que las observaciones se van permeando dentro del modelo global para llegar al regional, llevando consigo los errores que podrían tener de la asimilación. Es por esto que se le ha dado especial atención en años recientes a el desarrollo de modelos globales, tanto en su integración como en su inicialización. Un ejemplo de esta dinámica lo encontramos nuevamente con el modelo regional WRF, el cual muy comúnmente es inicializado usando campos provenientes de la salida del modelo *Global Forecasting System* (GFS).

Al ir integrando en tiempo el modelo regional, es necesario actualizar las condiciones de frontera en las paredes del dominio. Lo anterior comúnmente se realiza utilizando valores provenientes del modelo global como condiciones de frontera. El diseño de estas condiciones de frontera puede repercutir fuertemente en errores en la simulación, por lo que se debe de diseñar de acuerdo al caso particular que se desea estudiar (Warner et al., 1997).

Para este trabajo, salidas provenientes del modelo GFS fueron seleccionadas para ser usadas como condiciones iniciales y de frontera de las simulaciones usando el modelo WRF. Lo anterior es debido a que en el 2015, el Centro Nacional de Predicción Ambiental de los EE.UU. (NCEP por sus siglas en inglés), anunció una mejora importante en la resolución horizontal del modelo GFS (for Environmental Prediction, 2015). El modelo GFS es un modelo del tipo *spectral*, el cual representa el estado de la atmósfera como una superposición de funciones de onda. La salida cruda de este tipo de modelos está en la forma de coeficientes espectrales, los cuales pueden ser convertidos mediante una síntesis espectral en valores puntuales de una malla. Una mayor resolución espacial se consigue al aumentar el número de funciones base usadas para truncar los coeficientes espectrales.

La mejora realizada por NCEP permitió aumentar la resolución de las salidas de GFS de 0.5 a 0.25 grados. Para esto se cambió de un integrador con dinámica de tipo Euleriano (resolución  $\sim 27$  km), a uno con dinámica Semi-Lagrangiana (resolución  $\sim 13$  km). Al pasar de coeficientes espectrales a una malla regular la resolución espacial de la salida disminuye un poco, quedando en 0.25 grados ( $\sim 27$  km). Sin embargo, esto es aún una disminución del 50% en la resolución disponible previamente, como se puede observar en la Figura 1.2. Ya que el integrador resolvió las ecuaciones con mayor resolución espacial, se espera también que las soluciones se aproximen mejor a la realidad.

#### 1.2.4. Verificación de pronóstico

Siguiendo el método utilizado por los otros estudios para el análisis de sensibilidad del modelo WRF, se hará uso de diferencias en medidas de verificación de pronóstico como estimador de sensibilidad. La verificación de pronóstico es la rama auxiliar de las ciencias atmosféricas encargada de la *validación* de los pronósticos (Jolliffe y Stephenson, 2012). Esta validación se realiza cuantificando qué tan hábil o valioso fue el pronóstico emitido *a posteriori*. Lo anterior sigue la idea de que tener información sobre eventos en el futuro siempre es mejor que ser completamente ignorantes de lo que va a suceder. Finley (1884) fue el primero en cuestionar la validez de esta idea, proponiendo las técnicas que se convirtieron en la base de esta rama auxiliar.

Brier y Allen (1951) identificaron tres ventajas asociadas con la verificación de pronóstico. La primera ventaja es la *administrativa*, ya que los resultados de verificación son una herramienta útil para tomar decisiones en cuanto el manejo de recursos humanos de los centros de pronóstico. La segunda ventaja es la *científica*, ya que los resultados ayudan a comprender la razón por la cual funcionan (o no) los pronósticos. La tercer ventaja se relaciona con lo *económico*, ya que siempre existe una relación (no siempre sencilla) entre



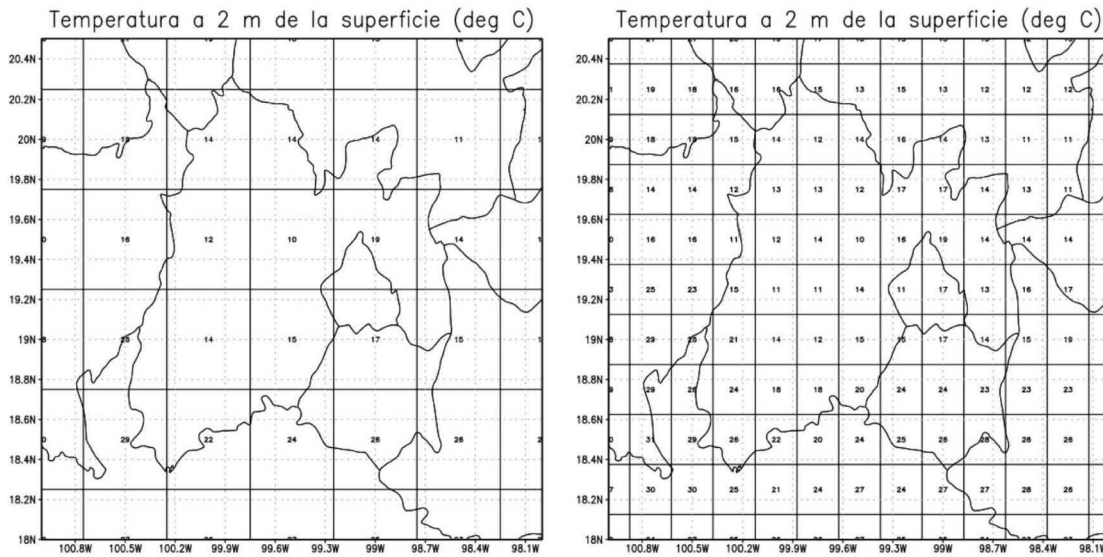


Figura 1.2: Izquierda: Simulación temperatura GFS con 0.50 grados de resolución horizontal. Derecha: Simulación temperatura GFS con resolución horizontal de 0.25 grados.

las necesidades de los usuarios y la habilidad de los pronósticos.

En este trabajo se hará un énfasis en la ventaja científica. Esto con el fin de tener una mejor comprensión de los efectos que las condiciones iniciales y de frontera (C.I. y de F.) junto con las parametrizaciones tienen sobre la calidad del pronóstico realizado con el modelo WRF en una región orográficamente compleja como lo es el Valle de México.

### Tipos de datos

Diferentes esquemas de verificación existen para diferentes tipos de datos. Las variables meteorológicas existen en un amplio espectro de tipos de datos, siendo importante distinguir entre estos. Para este trabajo nos interesan dos tipos de datos:

- Datos de tipo discreto (e.g. Precipitación o No precipitación).
- Datos de tipo continuo (e.g. Temperatura del aire).

Para cada uno de estos tipos de datos existen diferentes esquemas de verificación, como veremos más adelante.

Cabe mencionar que los datos siempre se pueden ordenar de tal manera que caigan dentro de uno u otro tipo de datos, de acuerdo al objetivo del usuario. Por ejemplo un agricultor puede estar interesado únicamente en saber cuando habrá una helada, sin importarle mucho el valor puntual de la temperatura mayor a 0 °C. En este caso una variable que inicialmente es continua (temperatura) puede convertirse a una variable binaria mediante



un umbral, quedando como:

$$\begin{aligned}T &\leq 0 = a \\T &> 0 = b.\end{aligned}$$

Cada tipo de dato puede también clasificarse en dos subcategorías: determinístico o probabilístico. Esta distinción es determinante para la elección de un esquema de verificación. En general la salida “cruda” de un modelo de PNT como el WRF da como resultado un pronóstico determinístico, en donde no se toma en cuenta la incertidumbre asociada al pronóstico. En contraste un pronóstico probabilístico se obtiene como resultado de un ensamble de salidas de un PNT. Debido al gran costo computacional que presentan los ensambles para ser usados de modo operativo, en este trabajo no se hará uso de éstos.

### Esquemas de verificación

Un esquema de verificación es el conjunto de métricas elegidas para evaluar la bondad de un pronóstico del tiempo. (Murphy, 1993) identificó tres diferentes tipos de bondad, cada una asociada al objetivo del usuario para la verificación:

1. La **consistencia** es una medida de qué tanto el pronóstico esta de acuerdo con el juicio del pronosticador;
2. el **valor** mide los beneficios económicos para él usuarios derivados del pronóstico y;
3. la **calidad** es una medida de qué tanto se acercó el pronóstico a las observaciones.

Cada uno de estos tipos de bondad se puede asociar a una de las tres ventajas de la verificación: La consistencia con lo administrativo, el valor con lo económico y la calidad con lo científico. Sin embargo cada tipo de bondad está también relacionada con las otras ventajas. Debido a esto la definición de lo que es un “buen” pronóstico no es estática, sino que obedece siempre al objetivo y la necesidad particular de los usuarios para cada estudio (Finley, 1884).

Las salidas crudas de un modelo de PNT permiten únicamente la evaluación de la calidad. Un estudio de consistencia requeriría que un experto evaluará la información del PNT y la integrara junto con otras fuentes para elaborar un pronóstico completo, ya que la salida de un PNT no es más que una aproximación a la realidad. Ya que las computadoras (aún) no son capaces de realizar este análisis, no es posible estudiar la consistencia de salidas crudas de un modelo de PNT. El presente estudio se limitará a evaluar las salidas del PNT, directamente relacionado con la calidad del pronóstico. En cuanto al valor, la parte económica queda fuera de los alcances de este trabajo, por lo que no será explorado.

### Atributos de la calidad del pronóstico

Tradicionalmente, la bondad de la calidad es cuantificada mediante una función que depende de la distancia que existe entre los pronósticos y las observaciones. Ejemplos de esto son el error cuadrático medio (RMSE), error medio absoluto (MAE), etc. Estas medidas son parte de una familia denominada como la aproximación basada en observaciones (Murphy y Winkler, 1987).

Mas recientemente, Wilks (2011) propone el uso de una aproximación basada en distribuciones. Esta aproximación, en vez de tomar distancias entre datos puntuales, hace

uso de la distribución conjunta de los pronósticos (denotado por  $y$ ) y de las observaciones (denotado por  $o$ ):

$$p(y, o). \quad (1.1)$$

Esta aproximación tiene una ventaja sobre la aproximación basada en observaciones al tener toda la información no dependiente del tiempo contenida en una distribución conjunta. Ya que la distribución conjunta es difícil de usar directamente, dos maneras diferentes de factorizar esta distribución, aprovechando las propiedades de la probabilidad, fueron concebidas por Murphy y Winkler (1987). La primera de estas es la *factorización de calibración-refinamiento*:

$$p(y_i, o_j) = p\{o_j|y_i\}p\{y_i\}; i = 1, \dots, I; j = 1, \dots, J. \quad (1.2)$$

Esta factorización es la más intuitiva de las dos, ya que el primer término es la probabilidad de que dado un pronóstico  $y_i$  ocurra cualquiera de las observaciones  $o_j$ . Esto se puede pensar como qué tan *calibrados* se encuentran los pronósticos  $y_i$ . El segundo término es la distribución marginal  $p(y_i)$ , que indica que tan probable es que se pronostique cualquiera de los  $I$  valores posibles. Mientras mayor sea la extensión de la probabilidad a lo largo de los  $I$  valores posibles, más *refinado* será el pronóstico.

Por otro lado, la *factorización de verosimilitud-tasa base* (Murphy y Winkler, 1987) toma la siguiente forma:

$$p(y_i, o_j) = p\{y_i|o_j\}p\{o_j\}; i = 1, \dots, I; j = 1, \dots, J. \quad (1.3)$$

En este caso el primer término indica la probabilidad para cada uno de los  $I$  pronósticos de haber sido indicados dada una única observación  $o_j$ . El segundo término es la distribución marginal de probabilidades para cada una de las  $J$  observaciones, conocida usualmente como la *climatología muestral*.

La información contenida en cada una de las dos factorizaciones permite reconstruir completamente la distribución (1.1). La elección de alguna de estas dos depende del objetivo de la verificación. Los diferentes atributos escalares asociados a la calidad del pronóstico están indicados en la tabla (1.1), junto con la factorización necesaria para calcularlos (Murphy, 1993).

Las métricas de calidad de pronóstico comunmente cuantifican uno de los 10 atributos descritos con anterioridad, aunque a veces una misma métrica puede evaluar dos o hasta más al mismo tiempo. Cada esquema de verificación de calidad debe definir tanto los atributos a medir como las métricas a utilizar. En este trabajo se evaluarán cada uno de los atributos descritos para los diferentes tipos de datos haciendo uso de las diferentes medidas de verificación descritas por (Wilks, 2011).

## Medidas de calidad para datos continuos

A continuación se describen las medidas de calidad más comunes para evaluar datos discretos, el error medio, el error medio absoluto y el error cuadrático medio. Adicionalmente se describen dos medidas gráficas para evaluar la calidad de datos continuos, los cuales son muy útiles para hacer una evaluación rápida, sobre todo al comparar modelos.

**Error medio** El error medio,  $EM$ , es una medida tradicional del sesgo, calculado como el promedio de las diferencias entre el pronóstico y la observación. Para un número  $n$  de pronósticos dados en un punto a lo largo del tiempo:

$$EM = \frac{1}{n} \sum_{k=1}^n (f_k - o_k) = \bar{f} - \bar{o}. \quad (1.4)$$

Esta medida es útil para identificar si un pronóstico sobrestima o subestima las observaciones. Los pronósticos que en promedio sobrestimen las observaciones exhibirán  $EM > 0$ . En cambio, aquellos que en promedio subestimen las observaciones exhibirán  $EM < 0$ . Si los pronósticos y las observaciones tienen el mismo valor en promedio,  $EM = 0$ .

Debemos tomar en cuenta que el EM es una medida muy limitada para describir la calidad del pronóstico. Esto es una consecuencia directa de utilizar promedios para calcular el EM, los cuales eliminan toda la variabilidad de los datos subyacentes. Por ejemplo, un pronóstico que en los extremos siempre subestime las observaciones pero en la parte media siempre las sobrestime, tendrá un valor de EM muy cercano al 0.

**Error medio absoluto** El error medio absoluto ( $EMA$ ) es una medida de la exactitud y la asociación de la calidad de un pronóstico. Matemáticamente se define como el promedio de la diferencia absoluta de las observaciones y los pronósticos,

$$EMA = \frac{1}{n} \sum_{k=1}^n |f_k - o_k|, \quad (1.5)$$

en donde  $k$  indica el  $k$ -ésimo par de observaciones y pronósticos para los cuales estamos evaluando la calidad. Si los pronósticos fueran perfectos ( $f_k = o_k$ ), el valor de EMA sería igual a cero. Este valor aumenta conforme las diferencias entre pronósticos y observaciones son mayores, teniendo las mismas unidades que la variable original.

El EMA es una medida útil y rápida de la exactitud, sobre todo para evaluar situaciones en donde no se espera que el pronóstico se aleje mucho del valor climatológico.

**Error cuadrático medio** De manera similar al EMA, el error cuadrático medio ( $ECM$ ) es una medida de la exactitud y asociación de la calidad del pronóstico, definido como

$$ECM = \frac{1}{n} \sum_{k=1}^n (f_k - o_k)^2. \quad (1.6)$$

El ECM es el promedio de la diferencia al cuadrado de los pronósticos y las observaciones, siendo casi igual al EMA, pero aplicando la función cuadrática a las diferencias. Dicha función cuadrática resulta en que el ECM sea más sensible a los errores grandes, en particular a los valores atípicos.

Para ver como el ECM se relaciona con la asociación de la calidad, debemos primero considerar la manipulación algebraica del ECM propuesta por Murphy (1988):

$$ECM = EM^2 + s_f^2 + s_o^2 - 2s_f s_o r_{fo}, \quad (1.7)$$

en donde  $r_{fo}$  es el coeficiente de correlación de Pearson entre las observaciones y los pronósticos (representando la asociación) y  $s$  es la desviación estándar de la distribución marginal.

El cuarto término de (1.7) indica que mientras mayor sea la correlación entre pronósticos y observaciones, menor será el ECM. Sin embargo, es posible que tengamos un pronóstico en donde  $r_{fo} = 1$  pero el EM sea muy elevado, dando como resultado un ECM grande. Es debido a este tipo de situaciones que el uso de un solo atributo para evaluar la calidad usualmente no aporta toda la información necesaria para hacer una buena evaluación.

**Diagrama Cuantil Condicional** Este diagrama muestra en una representación gráfica los dos componentes de la factorización de calibración-refinamiento de la distribución conjunta definida en (1.1). Un ejemplo de este tipo de diagrama se puede ver en la Figura (3.13). En el eje horizontal se muestran los valores pronosticados, mientras que en el eje vertical se encuentran los valores observados. Un pronóstico perfecto sería aquel en donde los puntos de pares  $(f, o)$  cayeran exactamente en la línea diagonal con pendiente 1 originada en  $(0,0)$ . Aquellos puntos que caigan por debajo de la línea son aquellos que *sobrestimaron* la observación, mientras que los que están por encima de la línea son aquellos que *subestimaron* la observación. Adicionalmente el eje horizontal muestra un histograma de los valores pronosticados, el cual representa la nitidez del pronóstico. Por último, líneas correspondientes a diferentes percentiles suavizados se agregan a la gráfica, los cuales ayudan a discernir la exactitud del pronóstico en valores medios o en valores extremos. La primer parte de la distribución (1.1) esta representada por los puntos y las líneas de los cuantiles, mientras que la segunda parte se ve reflejada en el histograma de los pronósticos.

**Diagrama de Taylor** La segunda herramienta gráfica utilizada fue el diagrama diseñado por Taylor en 2001 (Taylor, 2001). Este es un diagrama de gran utilidad para evaluar a simple vista la calidad del pronóstico de datos continuos, usando los principios de la descomposición del RMSE mencionados anteriormente. Una ejemplo de este tipo de diagrama puede verse en la Figura 3.5.

Para comprender este diagrama, es necesario observar primero que la factorización descrita en la ecuación (1.7), removiendo el error debido al sesgo EM, es muy similar a la ley de los cosenos:

$$C^2 = A^2 + B^2 - 2AB \cos \theta. \quad (1.8)$$

En este caso podemos ver que las desviaciones estándar  $s_f, s_o$  toman el lugar de los catetos de un triángulo, en donde el coeficiente de correlación  $r$  toma el lugar del ángulo  $\theta$ . De acuerdo a nuestro símil, el EMC será entonces el valor de la “hipotenusa”, o en este caso, de la línea que completa el triángulo entre los dos catetos. Esto se representa de manera gráfica al colocar los vértices de este triángulo en coordenadas polares, en donde el ángulo de la horizontal es el coseno de la correlación, y la distancia radial del origen está definida por las desviaciones estándar. Para comparar con un pronóstico perfecto, en donde  $f = o$ , este diagrama también incluye siempre el valor de  $s_o$  en la horizontal, ya que la correlación de las observaciones consigo mismas (el caso ideal) por definición es 1 y entonces  $\cos(1) = 0$ .

En general, un pronóstico es bueno cuando cumple con dos condiciones: se encuentra cercano a el círculo de radio definido por  $s_o$  y su correlación es cercana al 1.0. Mientras más lejano al círculo de  $s_o$ , mayor será el valor de EMC (esto da pie a graficar círculos de distintos valores de EMC, para facilitar la lectura del diagrama). Es útil recordar en este punto que un pronóstico puede presentar un valor de correlación muy elevado junto con un valor de sesgo elevado también, resultando en valores altos de EMC.

### Medidas de calidad para datos discretos

La evaluación de los datos discretos es comunmente realizada mediante el uso de tablas de contingencia, un método desarrollado por (Finley, 1884). Este método divide a los pares observación/pronóstico en una tabla con  $I \times J$  categorías de conteos de las  $I \times J$  combinaciones posibles de pares observación/pronóstico. Ya que los conteos son básicamente frecuencias absolutas de cada evento, basta con dividir cada uno de estos entre

		Observado	
		Sí	No
Pronosticado	Sí	a Aciertos	b Falsas Alarmas
	No	c Errores	d Correcto Negativo

Figura 1.3: Ejemplo de una tabla de contingencia de 2x2.

el tamaño de la muestra para obtener las frecuencias relativas, que da como resultado la distribución conjunta definida en (1.1). Un ejemplo sencillo se muestra en la Figura (1.3) usando una tabla de contingencia de 2x2, representando un pronóstico de ocurrencia *si* y no ocurrencia *no*. Como ejemplo la precipitación se puede dividir en dos eventos: Hubo precipitación o no hubo precipitación.

**Proporción Correcta (PC)** La proporción correcta (*proportion correct* en inglés) es una medida de la exactitud del pronóstico. Se define simplemente como el cociente de los conteos en donde el pronóstico coincidió con la observación y el número total de conteos. Para la tabla de 2x2 corresponde a:

$$PC = \frac{a + d}{n}. \quad (1.9)$$

El mejor valor posible es 1, mientras que el peor valor posible es 0. Esta medida le da el mismo peso a los pronósticos de ocurrencia “sí” y de no ocurrencia “no”, por lo que en situaciones donde el pronóstico “sí” sea muy raro (como pronosticar lluvia en temporada de secas) esta medida podrá estar muy inflada por los pronósticos de “no”, los cuales son mucho más sencillos de hacer.

**Puntaje de amenaza (PA)** El puntaje de amenaza (*threat score* en inglés) es otra medida de la exactitud de pronóstico. Esta medida fue creada para tomar en cuenta el problema de la PC al manejar pronósticos en donde una situación sea mucho más frecuente que otra. El PA se define como el cociente entre el evento de menor ocurrencia y la suma de el número total de ocasiones en donde dicho evento sea observado o pronosticado. Para nuestro ejemplo de 2X2, en donde el evento “a” es el más raro:

$$PA = \frac{a}{a + b + c}. \quad (1.10)$$

El mejor valor posible de PA es 1, mientras que el peor valor posible es de 0.

**Sesgo** El sesgo es una medida del atributo del mismo nombre. Este es simplemente la razón existente entre los pronósticos que anuncian un cierto evento entre las observaciones de dicho evento. Por ejemplo, para el ejemplo 2x2 usando como evento la ocurrencia  $si$ ,

$$S = \frac{a + b}{a + c}. \quad (1.11)$$

Cuando el evento de interés es pronosticado el mismo número de veces que es observado,  $S = 1$  es el valor óptimo, y si el evento es pronosticado más veces que es observado entonces  $S > 1$  (*sobrepronosticado*) y viceversa para cuando es pronosticado menos veces de lo que es observado (*subpronosticado*).

**Probabilidad de Detección (PD) y de Falsa Detección (PFD)** La discriminación es evaluada utilizando la probabilidad condicional  $p(f_i|o_j)$ . Diferentes métricas se han nombrado para cada una de las combinaciones posibles. Por ejemplo, cuando el evento de interés es la ocurrencia en una tabla 2x2, en donde  $f_1, o_1$  son la ocurrencia del evento, la probabilidad condicional se escribe como:

$$p(f_1|o_1) = PD = \frac{a}{a + c}. \quad (1.12)$$

Esta cantidad es comúnmente conocida como la probabilidad de detección (*Probability of Detection* en inglés), definida como la proporción de los pronósticos de ocurrencia correctos entre el número de veces que dicho evento ocurrió. El PD toma valores de 0 cuando ningún pronóstico de ocurrencia fue correcto, y de 1 cuando todos los pronósticos de ocurrencia fueron adecuados.

En cambio, si los pronósticos de interés fueran aquellos en donde se pronosticó la ocurrencia pero no se observó, tendríamos la probabilidad de falsa detección (*Probability of False Detection* en inglés):

$$p(f_1|o_2) = PFD = \frac{b}{b + d}. \quad (1.13)$$

El PFD es la proporción de los pronósticos que resultaron en falsa alarma entre el número total de no ocurrencias del evento. Esta medida toma un valor de 0 para pronósticos perfectos donde no hay falsas alarmas, y de 1 para pronósticos en donde siempre hubo falsas alarmas.

**Razón de Falsa Alarma (RFA)** La razón de falsa alarma (*False Alarm Ratio* en inglés) es una medida tanto de la confiabilidad como de la resolución. Esta está basada en la probabilidad condicional  $p(o|f)$  cuando se toma en cuenta el pronóstico de ocurrencia con la observación de no ocurrencia. En la tabla de 2x2 esto sería:

$$p(o_2|f_1) = RFA = \frac{b}{a + b}. \quad (1.14)$$

Podemos ver que la RFA es la proporción de los pronósticos de falsa alarma entre el número de veces que dicho evento fue pronosticado. Para un pronóstico con muy alta confiabilidad es preferible tener valores de RFA muy pequeños, mientras que un valor de RFA de 1 es el peor valor posible.

## Puntajes de habilidad

La habilidad de un pronóstico es una medida de la calidad relativa de un conjunto de pronósticos con respecto a otro conjunto de pronósticos de referencia. Un ejemplo de esto es el uso de la climatología muestral o de la persistencia como pronósticos de referencia, en donde veremos si nuestro conjunto de pronósticos fueron mejores o peores que haber pronosticado el valor climatológico o usar el valor anterior. En nuestro caso haremos uso de dos pronósticos de referencia; el primero será la climatología muestral, calculada usando todas las observaciones. El segundo será el pronóstico resultante de una de las dos resoluciones, de tal manera que la habilidad sea relativa a los pronósticos de la otra resolución. De esta manera podremos ver fácilmente si hubo o no una mejoría en la calidad del pronóstico al usar una resolución u otra.

Una manera común de representar la habilidad del pronóstico es mediante el uso del puntaje de habilidad (*skill score*). Aunque existen diferentes maneras de definir este puntaje, todos se basan en la forma general

$$PH_{ref} = \frac{A - A_{ref}}{A_{perf} - A_{ref}} \times 100\%; \quad (1.15)$$

en donde *ref* se refiere al pronóstico de referencia usado, *A* es la medida de habilidad usada (como PC por ejemplo, y *perf* es el valor de *A* que obtendría un pronóstico perfecto (i.e. 1 para PC).

El valor de PH estará determinado de acuerdo a la ganancia o pérdida de habilidad de un pronóstico con respecto a la referencia. Cuando el pronóstico es mejor que la referencia,  $PH > 0$ . Cuando el pronóstico es peor que la referencia,  $PH < 0$ . Cuando el pronóstico y la referencia tienen la misma habilidad,  $PH = 0$ .

A continuación se hará una breve descripción de los 4 diferentes PH, los cuales son muy utilizados en el campo de verificación de pronóstico:

**Puntaje de habilidad de Heidke (PHH)** El puntaje de habilidad de Heidke (*Heidke Skill Score*), definido por Heidke (1926) es un PH en donde la PC es usada como medida de calidad. En este puntaje el pronóstico de referencia es la PC que obtendrían un conjunto de pronósticos aleatorios que sean estadísticamente independientes de las observaciones. Para la tabla 2x2:

$$PHH = \frac{2(ad - bc)}{(a + c)(c + d) + (a + b)(b + d)}. \quad (1.16)$$

**Puntaje de habilidad de Gilbert (PHG)** También conocido como la razón de éxito, el puntaje de habilidad de Gilbert (*Gilbert Skill Score*) es un puntaje construido con base en el PA. En la tabla de 2x2,

$$PHG = \frac{a - a_{ref}}{a - a_{ref} + b + c}. \quad (1.17)$$

En este caso  $a_{ref}$  hace referencia a el valor de *a* para un conjunto de pronósticos aleatorios,

$$a_{ref} = \frac{(a + b)(a + c)}{n}. \quad (1.18)$$

**Puntaje de Dependencia Extrema (PDE)** Para eventos en donde la ocurrencia sea extremadamente rara ( $p(o_1) \rightarrow 0$ ), puntajes como el PHH o el PHG se aproximan también al cero, aunque los pronósticos tengan buena habilidad. Para estos casos, Coles et al. (1999) creó el llamado puntaje de dependencia extrema (*Extreme dependency score*), definido para la tabla 2x2 como

$$PDE = \frac{2 \ln \left[ \frac{(a+c)}{n} \right]}{\ln[a/n]} - 1. \quad (1.19)$$

**Puntaje de habilidad de Gandin-Murphy (PHGM)** Hasta ahora los puntajes descritos han usado la tabla 2x2 como ejemplo, sin embargo, en el caso de tablas más grandes es importante tomar consideraciones adicionales. Un ejemplo de un puntaje de habilidad generado en especial para tablas de varias categorías es el puntaje de habilidad de Gandin-Murphy (*Gandin-Murphy Skill Score*). Este se define de la siguiente manera:

$$PHGM = \sum_{i=1}^I \sum_{j=1}^J p(f_i, o_j) s_{i,j}. \quad (1.20)$$

En donde  $p(f_i, o_j)$  son las diferentes probabilidades conjuntas de 1.1 y  $s_{i,j}$  es una función de pesos generados de tal manera que se recompensen los pronósticos acertados y se penalicen los pronósticos erróneos. Diferentes maneras de realizar estos pesos han sido propuestos, pero en este trabajo usaremos el método propuesto por Gerrity en 1992.



Tabla 1.1: Atributos escalares de la calidad.

<b>Atributo</b>	<b>Definición</b>	<b>Distribuciones Relevantes</b>
Sesgo	Correspondencia entre pronóstico medio y observación media.	$p(f), p(x)$
Asociación	Correspondencia lineal entre pares individuales de pronósticos y observaciones.	$p(f, x)$
Exactitud	Correspondencia promedio entre pares individuales de pronósticos y observaciones.	$p(f, x)$
Habilidad	Exactitud de pronósticos relativos a la exactitud de pronósticos producidos por un estándar de referencia.	$p(f, x)$
Confiabilidad	Correspondencia entre la observación condicional media y el pronóstico condicionante, promediado entre todos los pronósticos.	$p(x f), p(f)$
Resolución	Diferencia entre la observación condicional media y la observación incondicional media, promediado entre todos los pronósticos.	$p(x f), p(f)$
Nitidez	Variabilidad de los pronósticos descrita por su distribución marginal.	$p(f)$
Discriminación 1	Correspondencia entre el pronóstico condicional medio y la observación condicionante, promediado entre todas las observaciones.	$p(f x), p(x)$
Discriminación 2	Diferencia entre el pronóstico condicional medio y el pronóstico incondicional medio, promediado entre todas las observaciones.	$p(f x), p(x)$
Incertidumbre	Variabilidad de las observaciones descrita por su distribución marginal.	$p(x)$

# Capítulo 2

## Método

El objetivo de este trabajo es cuantificar la sensibilidad del modelo WRF (versión 3.8) al ser inicializado y alimentado con condiciones iniciales y de frontera (C.I. y de F.) de dos resoluciones diferentes. El primer paso fue cuantificar la calidad del pronóstico obtenido por el modelo considerando cada una de las dos resoluciones diferentes. Posteriormente se utilizó la diferencia entre la calidad como *proxy* de sensibilidad. Pruebas estadísticas derivadas de la verificación de pronóstico fueron usadas para determinar si la sensibilidad es lo suficientemente grande para cambiar significativamente la calidad del pronóstico.

### 2.1. Diseño del experimento numérico

En la presente investigación se implementó el modelo WRF en su versión 3.8 (Skamarock et al., 2005). Todos los experimentos numéricos fueron realizados en el cluster *Ometeótl* del Centro de Ciencias de la Atmósfera (CCA), UNAM. Para ello se utilizaron dos dominios anidados, un dominio principal que engloba gran parte de la República Mexicana con una resolución horizontal de 20 km (Figura 2.1), y un dominio anidado dentro del Valle de México con resolución horizontal de 6.6 km. La sensibilidad del modelo se estudió con base a los resultados del dominio de 6.6 km (mayor resolución), ya que es muy similar al dominio que actualmente se utiliza en el pronóstico del tiempo operativo del grupo Interacción Océano Atmósfera del CCA.

El dominio anidado fue elegido de tal manera que incluyera la mayor parte de la topografía representativa del Valle de México, cuidando que la frontera lateral no omitiera alguna montaña. Para todas las simulaciones se utilizaron 23 niveles verticales con un tope superior en 10 hPa.

Los datos estáticos geográficos utilizados para estas simulaciones están incluidos en el sistema de pre-procesamiento WPS (versión 3.8), con la base de datos de MODIS de uso de suelo de 2008. La topografía del WRF proviene del modelo digital de elevación global USGS GMTED 2010 (Danielson y Gesch, 2011), con una resolución horizontal de 30 segundos de arco para ambos dominios.

El modelo fue inicializado con las salidas del modelo global GFS versión 12.0.0. (National Centers for Environmental Prediction, 2015). Las condiciones iniciales corresponden al campo interpolado de la salida GFS para el primer paso de tiempo del modelo. Posteriormente, se actualizan las condiciones de frontera del modelo WRF cada tres horas haciendo uso del pronóstico correspondiente proveniente del modelo GFS. Ya que la agencia responsable de correr el modelo GFS libera cuatro salidas al día, cada una con 384 horas

de pronóstico se decidió usar siempre la salida correspondiente a las 00z, para mantener consistencia. De esta salida se tomaron los archivos correspondientes a las primeras 48 horas de pronóstico.

Todos los experimentos se llevaron a cabo usando las mismas parametrizaciones (ver apéndice A), con fin de evitar cambios en la salida del modelo debido a diferencias en la representación física de procesos de subescala.

Se seleccionaron 6 meses del año 2015 para la simulación. Este fue el año en donde el pronóstico GFS comenzó a generar salidas con una resolución de 0.25 grados. Los 6 meses fueron elegidos para ser representativos de las tres temporadas reportadas en el dominio por (Fenn et al., 2002): la temporada seca cálida, seca fría y de lluvias. El criterio para seleccionar los 6 meses se explicará a detalle en la siguiente sección.

La transferencia de radiación fue parametrizada usando el esquema RRTM para la onda larga (Mlawer et al., 1997) y el esquema Dudhia para la onda corta (Dudhia, 1989). Adicionalmente un esquema de microfísica de momento sencillo de tercera clase (Hong et al., 2004) junto con una parametrización de cúmulos usando el esquema Kain-Fritsch (Kain, 2004). La elección de usar un esquema de cúmulos junto a uno de microfísica se realizó debido a la incertidumbre asociada con la resolución horizontal de 6 km, que es la región conocida como "zona gris" de la simulación de convección (Gerard, 2007). Los procesos de superficie fueron parametrizados mediante el esquema YSU (Hong et al., 2006) para la capa límite planetaria, el esquema de difusión térmica de 5 capas para la superficie (Dudhia, 1996) y el esquema de similaridad de MM5 para los flujos de superficie.

El postprocesamiento de las salidas se realizó con el software ARWPost (versión 3) junto con el software GrADS para su visualización. Se realizó una inspección visual para determinar que no existieran problemas con las salidas del modelo, observando que el modelo se comportara de la manera esperada.

## 2.2. Base de datos observación-pronóstico

### 2.2.1. Observaciones de superficie

Los datos de observaciones en superficie fueron obtenidos de dos redes de observación existentes en el Valle de México: la red meteorológica del sistema de monitoreo atmosférico de la Ciudad de México (conocida como REDMET), y la red de estaciones meteorológicas automatizadas del Servicio Meteorológico Nacional Mexicano (conocidas como EMA's). Todos los datos fueron proporcionados por las dependencias gubernamentales correspondientes. Tres variables fueron seleccionadas para realizar la verificación: temperatura a 2 metros del suelo, magnitud de la velocidad del viento a 10 metros del suelo y la precipitación acumulada horaria. Esta última variable se encuentra disponible únicamente para estaciones EMA.

El primer paso para el uso de estos datos fue determinar cuáles de las estaciones se encontraban dentro del dominio descrito en la figura 2.1. Este criterio arrojó 37 estaciones, 15 de la red de EMAs y 22 de REDMET. La distribución espacial de estas estaciones se puede observar en el mapa de la Figura 2.2. Se incluyen las curvas de nivel de acuerdo a la topografía usada en el modelo.

Después de identificar las estaciones que podían ser usadas por ubicación, se procedió a homogeneizar la resolución temporal de los datos de ambas redes. Esto debido a que las estaciones EMA reportan datos cada 10 minutos, mientras que las REDMET reportan

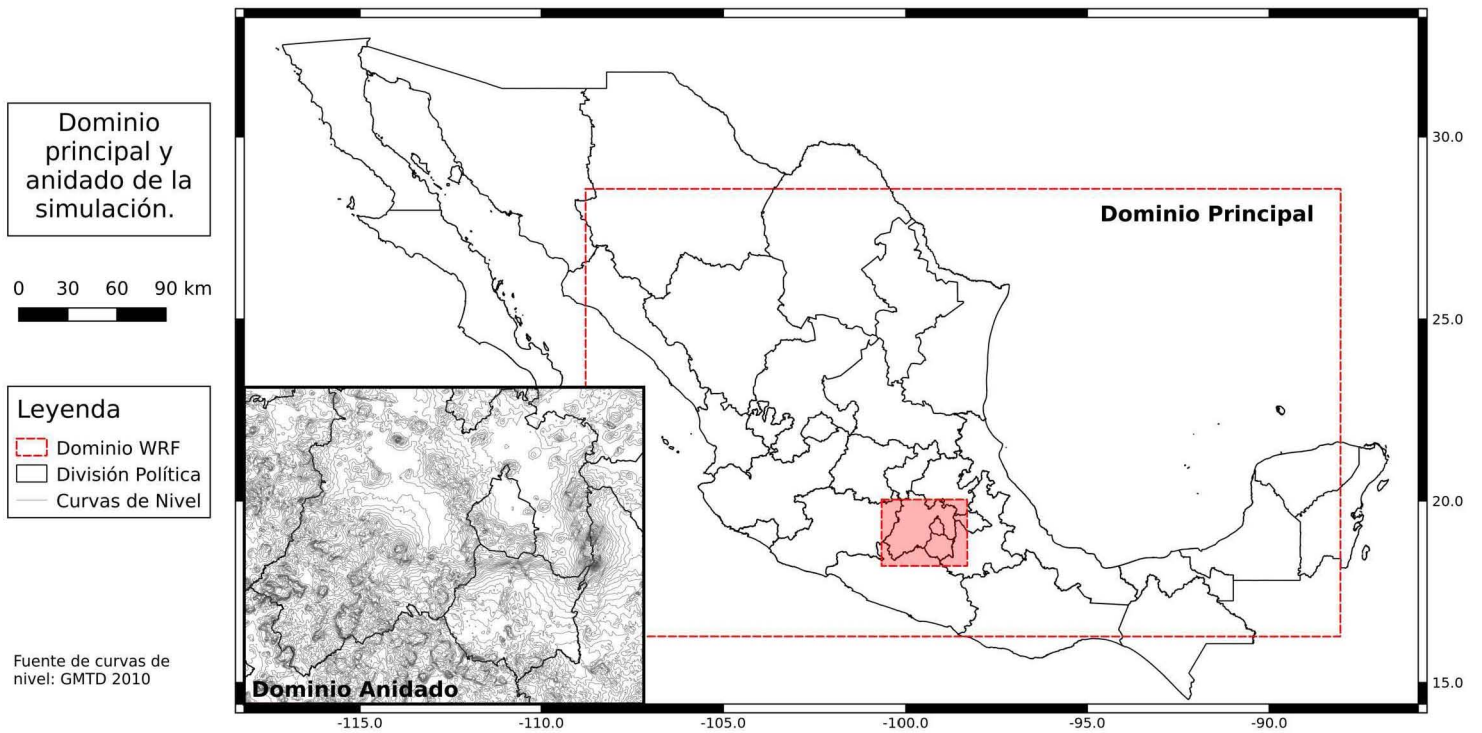


Figura 2.1: Dominio de la simulación mostrando el dominio principal de 20 km y el dominio anidado de 6.6 km.

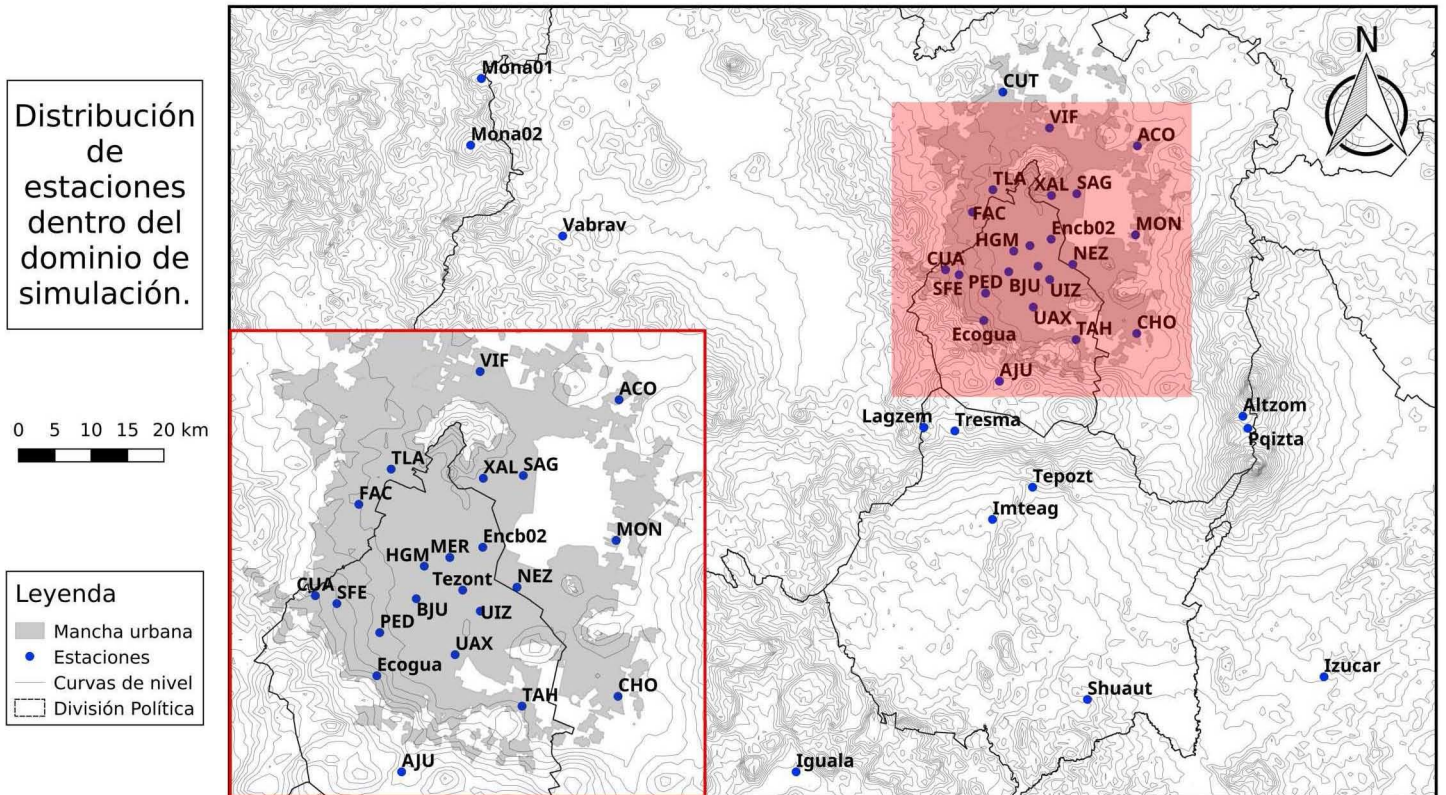


Figura 2.2: Mapa de estaciones analizadas en el Valle de México y alrededores.

cada hora. Con base a la frecuencia más baja (1 hora), se transformaron las series de las estaciones EMA para tener solo datos horarios. El criterio de esta transformación fue el de usar valores instantáneos para la velocidad del viento, valores horarios acumulados para la precipitación y medias horarias centradas en el valor de la hora para la temperatura. Ya que el modelo WRF trabaja con horario UTC, se realizó un cambio de horario de los datos REDMET de hora local de la Ciudad de México (GMT-5,6) a hora UTC. Los datos EMA no requirieron este cambio de horario.

Una vez que ambas series de datos presentaron la misma frecuencia temporal, se realizó un control de calidad. Este control considera como criterio únicamente el porcentaje de datos faltantes para cada estación en cada mes del año. Un porcentaje mínimo de 90% fue el umbral requerido para no descartar la estación en el mes evaluado. Lo anterior se puede ver ilustrado en la figura (2.3) que representa una estación con suficientes datos, en contraste de la estación ilustrada en la Figura (2.4) la cual muestra una ausencia de datos. Aunque se realizó un análisis visual para ver que no existieran picos o valores fuera de un rango esperado, no se aplicó ningún filtro más allá del descrito anteriormente.

Los 6 meses de simulación fueron elegidos al determinar qué meses contiguos presentarían la mayor probabilidad de tener series de datos completas en todas las estaciones meteorológicas. Esto se calculó utilizando el porcentaje total de datos para todas las estaciones en dos meses seguidos (p. ej. enero-febrero, marzo-abril, etc) como una probabilidad de que dicho par de meses tuviera datos completos. De este análisis los 3 pares de meses contiguos para cada temporada con la mayor probabilidad de estar completos fueron:

1. Abril-Mayo, representando la temporada seca cálida,
2. Agosto-Septiembre, representando la temporada de lluvias y,
3. Noviembre-Diciembre, representando la temporada seca fría.

### 2.2.2. Pares de datos observación-pronóstico

Los pares de observación-pronóstico fueron elaborados utilizando el punto de malla de la simulación más cercano a cada estación al igual que Ruiz et al. (2010). Esta aproximación requiere considerar que la representatividad de las estaciones meteorológicas de superficie es de máximo 5 kilómetros a la redonda (Jarraud, 2008). Esta condición es válida cuando el terreno es plano, cosa que ocurre en el interior del Valle de México pero no en los alrededores. Ya que los puntos de la malla del modelo no correspondían exactamente con las estaciones de superficie, se utilizó el punto del modelo más cercano a la estación, siempre que este estuviera adentro de la zona de representatividad. Se decidió utilizar esta aproximación en vez de interpolar valores con los vecinos más cercanos para no introducir errores de estimación al interpolar la precipitación. La Figura 2.5 muestra la posición de las estaciones con su radio de representatividad de 5 km, junto con los puntos de malla del modelo más cercanos.

La comparación de las observaciones y los pronósticos se realizó utilizando las últimas 24 horas resultantes de cada simulación. Las simulaciones numéricas se hicieron a 48 horas de pronóstico (empalmándose siempre 24 horas de días contiguos), por lo que era posible escoger diferentes intervalos para la comparación. Se permitió al modelo “calentarse” las primeras 24 horas para disminuir lo más posible errores por falta de *spin-up*.

Para facilitar la evaluación de medidas de precipitación los resultados numéricos las estaciones fueron agrupados de acuerdo a su localización espacial en las diferentes cuen-

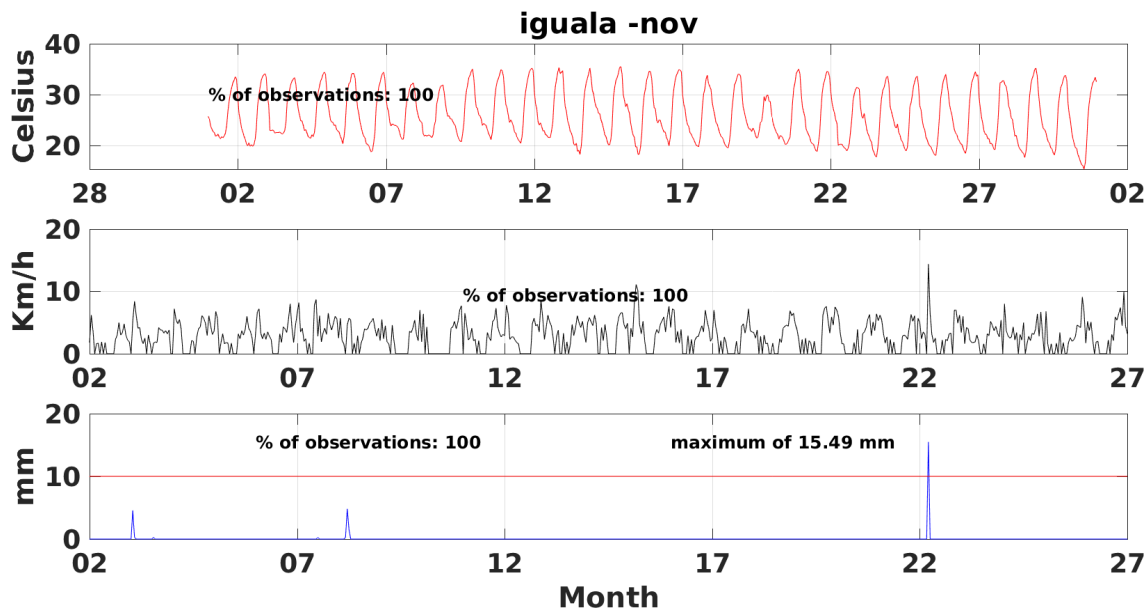


Figura 2.3: Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA iguala para el mes de Noviembre 2015.

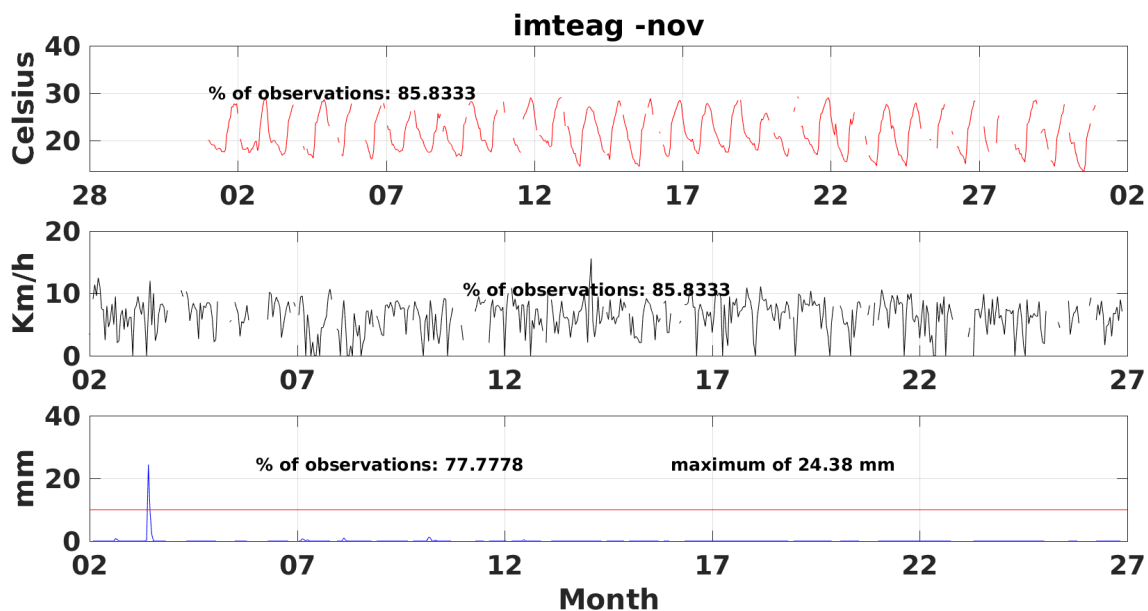


Figura 2.4: Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA imteag para el mes de Noviembre 2015.



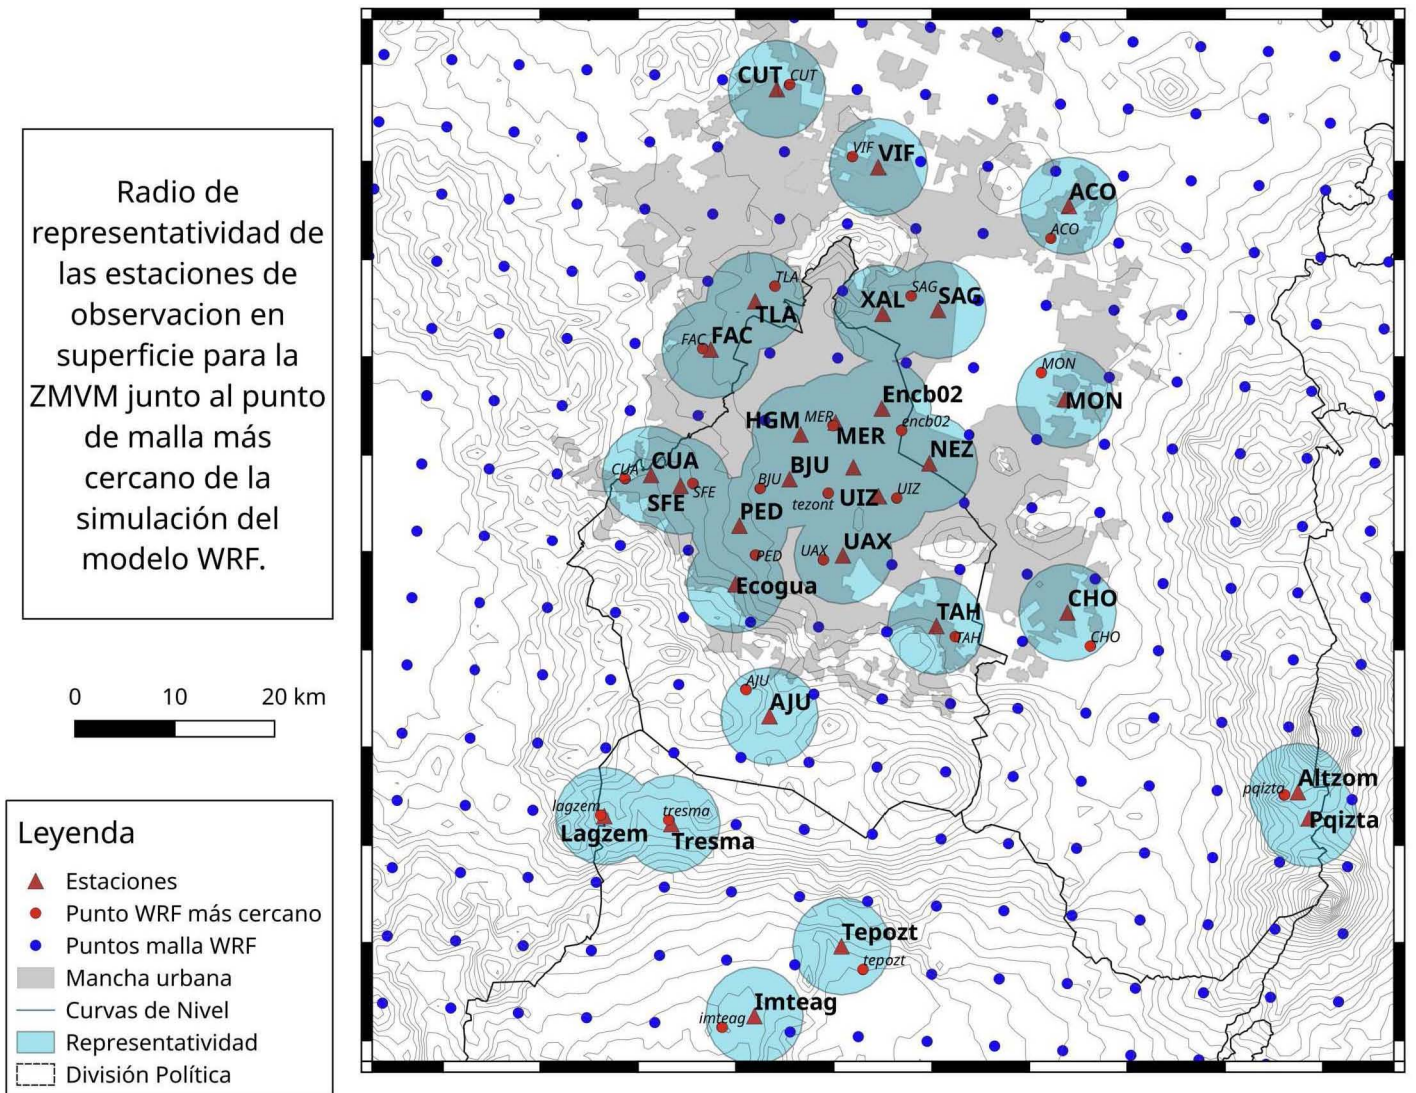


Figura 2.5: Mapa de estaciones y puntos de malla más cercanos.

cas hidrográficas del Valle de México. Dos cuencas fueron localizadas para el dominio: la Cuenca de México (22 estaciones), en donde se encuentra la mayor parte de la ZMVM, y la Cuenca del río Balsas (12 estaciones). La distribución de estaciones en cada cuenca se puede apreciar en la Figura 2.6. Para cada cuenca se tomaron todos los pares observación/pronóstico correspondientes y se calcularon las medidas de verificación como si fueran todas del mismo punto.

La distribución espacial de los errores resultantes de la verificación se analizó observando mapas con cada estación con una barra de color proporcional a la magnitud de la medida de calidad utilizada. Lo anterior se realizó con la ayuda de un sistema de información geográfica. Un ejemplo de este tipo de mapas se puede apreciar en la figura 3.8. Esto permite realizar una apreciación espacial de los errores del pronóstico a lo largo de las estaciones. Este método es similar a aquel usado en Case et al. (2008) para evaluar la diferencia entre errores de dos simulaciones distintas.

Teniendo ya los pares observación-pronóstico, fue posible realizar el procedimiento de verificación del pronóstico.

### 2.3. Verificación de pronóstico

Un esquema de verificación para dos variables continuas y una discreta fue elaborado para analizar los resultados de la simulación. Como se mencionó en el capítulo anterior, 10 diferentes criterios de verificación de pronóstico existen para evaluar la calidad de éste (tabla 1.1). De las 3 variables disponibles para la verificación podemos calcular dos tipos de datos: continuos para la temperatura y la magnitud del viento, y discretos para la precipitación.

El esquema de verificación elaborado se enfocó en evaluar la calidad de los pronósticos. Dentro de este esquema se hizo una distinción entre las medidas a utilizar de acuerdo al tipo de dato que están describiendo. A continuación se describen cada una de las métricas implementadas en el esquema.

#### 2.3.1. Datos continuos

Dos variables del tipo continuo fueron evaluadas: temperatura a dos metros y magnitud de la velocidad del viento a diez metros de superficie. Para estas variables se hizo uso de tres medidas:

- Error medio,
- Error medio absoluto y
- Error cuadrático medio.

Para facilitar la interpretación de los resultados se elaboraron también diagramas de Taylor y de cuantil condicional. Estos diagramas se hicieron para cada una de las 3 temporadas evaluadas.

#### 2.3.2. Datos discretos

La precipitación acumulada fue convertida en datos del tipo discreto al delimitar dos diferentes categorías: 1) Sin presencia de precipitación y 2) Presencia de precipitación. Pos-



teriormente se elaboraron tablas de contingencia para evaluar esta variable.

Las tablas de contingencia fueron evaluadas las siguientes medidas escalares:

- Proporción correcta,
- Puntaje de amenaza,
- Sesgo,
- Probabilidad de detección,
- Probabilidad de falsa detección y
- Razón de falsa alarma.

Para cada uno de los atributos descritos por 1.1 existe una o varias de estas medidas. Al igual que con las medidas de datos continuos, no es suficiente el uso de un solo atributo escalar para caracterizar completamente la calidad de un pronóstico. A continuación se mencionan las diferentes medidas utilizadas, junto con el atributo que describen. La nomenclatura y formulación de estas medidas se hizo siguiendo el método propuesto por Wilks (2011).

Se hizo uso también del puntaje de habilidad de Heidke y del puntaje de dependencia extrema para determinar el cambio en habilidad al pasar de una resolución a otra.

## 2.4. Análisis de sensibilidad

Los resultados de la verificación de pronóstico arrojaron resultados de la calidad para la resolución de 0.5 y 0.25 grados. Con la finalidad de responder nuestra pregunta de investigación (¿Qué tan sensible es el modelo al cambio de condiciones iniciales y de frontera?) se aplicó una prueba estadística que permitió inferir esta sensibilidad. En este caso la sensibilidad se entiende como el cambio en calidad al pasar de una resolución de C.I y de F. a otra, sin importar si el cambio fue negativo o positivo.

### 2.4.1. Estimación de intervalos de confianza.

La sensibilidad se evaluó al ver si existió un cambio entre una de las medidas de calidad obtenidas en la sección anterior al cambiar las C.I. y de F. Un ejemplo de esto es calcular el cambio del EMA entre las dos resoluciones de entrada para la simulación. Construimos nuestra hipótesis nula de tal modo que:

$$H_o : EMA_{0,5} = EMA_{0,25}, \quad (2.1)$$

$$H_a : EMA_{0,5} \neq EMA_{0,25}. \quad (2.2)$$

Para disminuir los grados de libertad del problema, se realizó la diferencia diaria del estadístico a probar para cada temporada. Esto resultó en tres series de diferencias, una para cada temporada. Ya que cada serie contenía un número de diferencias de aproximadamente 60 valores, se consideró a la muestra lo suficientemente grande para realizar inferencias estadísticas sobre esta. Nuestra hipótesis nula anterior se modificó para tomar en cuenta las diferencias, quedando de la siguiente manera:

$$H_o : \overline{(EMA_{0,5} - EMA_{0,25})} = 0, \quad (2.3)$$

$$H_a : \overline{(EMA_{0,5} - EMA_{0,25})} \neq 0. \quad (2.4)$$

Para estimar el valor que tendrá la media de las diferencias de los errores, se utilizó la aproximación tomada en Willmott et al. (1985). Esta consiste en hacer uso de una prueba no paramétrica de remuestreo con *bootstrap* para estimar los intervalos de confianza del estadístico de interés, en este caso la media. Esto fue necesario ya que la distribución que presentan los errores es desconocida. Para poder aplicar este método es necesario que las dos muestras sean independientes entre sí. Ya que cada muestra viene de simulaciones diferentes, se asumió que existe independencia entre ellas. Para evitar que los datos presentaran correlación espacial entre ellos mismos (ya que estamos tratando con puntos sobre un campo geográfico) se aplicó el método de manera individual a cada punto. Se asumió también que los datos no presentan correlación temporal entre ellos al tomar las diferencias de los errores en vez de los errores crudos.

Los intervalos de confianza utilizando el método de *bootstrap* se realizaron tomando 10,000 remuestreos con reemplazo para cada serie. Lo anterior se realizó de manera automatizada con la función *boot* del software de procesamiento estadístico R. Este método dió como resultado un histograma de la distribución empírica de la media para cada serie, como puede ser observado en la Figura (2.7). Se realizó una supervisión manual de cada histograma para descartar aquellos que no cumplieran con una distribución aproximadamente normal. Los intervalos de confianza del 95 % fueron calculados a partir de los percentiles del 95 % de estos histogramas.

Para realizar un primer análisis de sensibilidad se observó si los intervalos de confianza de la media de cada serie incluyen el 0. Si la respuesta es positiva entonces (asumiendo que  $H_o$  es verdadero), existe una gran probabilidad de que los datos se acoplen a los resultado observado.

#### 2.4.2. Diagramas de bosque

Se realizó un análisis más completo de la sensibilidad mostrada por el modelo utilizando un diagrama de bosque construido con los intervalos de confianza obtenidos en la sección anterior. Lo anterior sigue el método propuesto en Cumming (2013), donde se hace énfasis en evitar el uso de pruebas de significancia a favor de ver el tamaño y comportamiento de los intervalos de confianza.

Los diagramas de bosque se realizaron para cada una de las tres temporadas con dos errores diferentes: el EMA y el ECM tanto de la temperatura como de la magnitud de la velocidad del viento. Un ejemplo de estos diagramas de bosque se puede apreciar en la Figura 3.25.

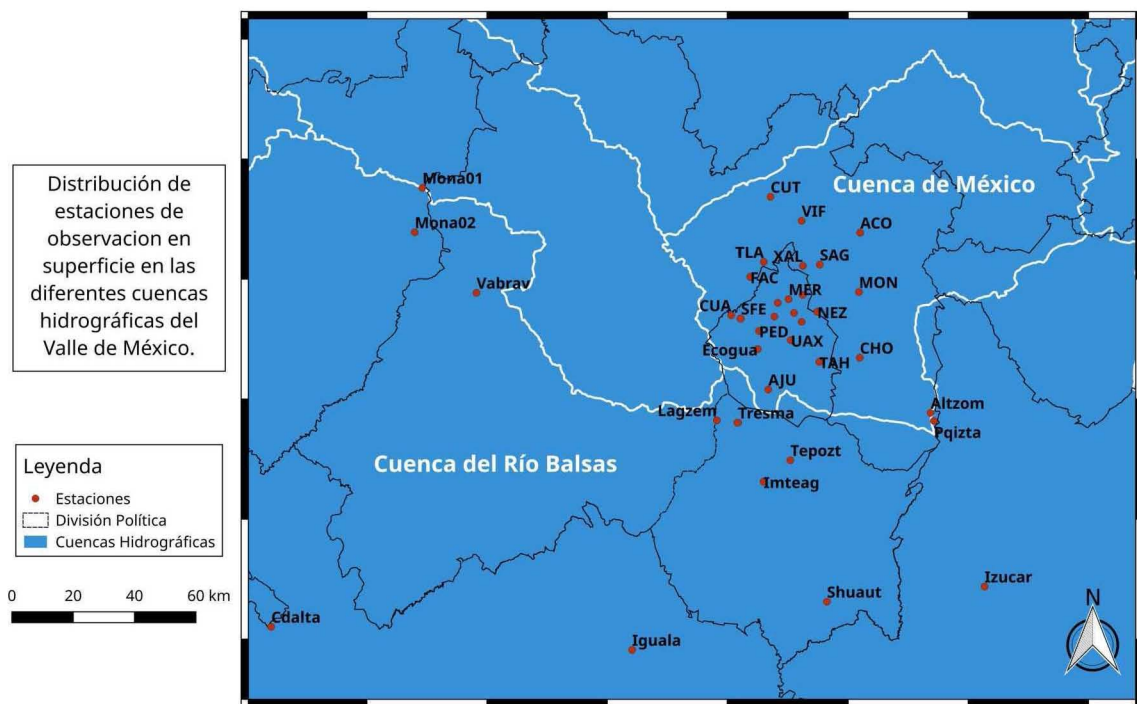


Figura 2.6: Distribución de las estaciones en la Cuenca de México y en la Cuenca del río Balsas.




Figura 2.7: Histograma de la distribución empírica resultante al usar el método de remuestreo de *bootstrap* para la media  $t^*$  de las diferencias del EMA para la estación CUA en la temporada húmeda.

## Capítulo 3

# Resultados y Discusión

Se muestran los resultados de aplicar el esquema de verificación y el análisis de sensibilidad a los 6 meses de simulación. Primero se procede a describir los resultados de calidad de acuerdo a las medidas de verificación, para posteriormente describir los resultados del análisis de sensibilidad.

### 3.1. Verificación de pronóstico

#### 3.1.1. Precipitación

Las tablas 3.1 y 3.2 muestran las tablas de contingencia para la precipitación de acuerdo a las agrupaciones de estaciones descritas en el capítulo anterior. Para esta variable se muestran únicamente los datos para la temporada de lluvias. No hay la misma cantidad de pronósticos para las dos resoluciones debido a que existían faltas en la base de datos de GFS para la resolución de 0.5, pero ya que estas faltas fueron menores al diez por ciento del total de días simulados, se considero que el efecto de estos días adicionales no agregaría un error significativo a los resultados de verificación.

Podemos apreciar que en ambas cuencas, el caso dominante es aquel en donde el pronóstico de no lluvia corresponde con la observación de no lluvia. En contraste, el valor más pequeño corresponde al pronóstico de lluvia con observación de lluvia.

La tabla (3.3) muestra los resultados de aplicar los métodos descritos en el capítulo anterior a las tablas de contingencia, igualmente para el periodo de lluvias.

Para analizar la distribución espacial a lo largo del dominio para la temporada húmeda, se realizaron 4 mapas para las métricas que se consideraron más importantes: la Figura 3.1 muestra la PC, la Figura 3.2 el PA, la Figura 3.3 el RFA y la Figura 3.4 el sesgo. Ya que únicamente las estaciones EMA del SMN cuentan con pluviometro, se omiten los puntos correspondientes a estaciones REDMET en estos mapas.

Tabla 3.1: Tabla de contingencia para la cuenca de México, temporada de lluvias.

Resolución	0.5		0.25	
obs	si	no	si	no
pron				
si	144	458	165	448
no	613	4047	663	4178

Tabla 3.2: Tabla de contingencia para la cuenca del río Balsas, temporada de lluvias.

Resolución	0.5		0.25	
pron \ obs	si	no	si	no
si	754	1331	687	1325
no	2137	12375	2198	11814

Tabla 3.3: Resultados de la verificación para las tablas de contingencia, temporada de lluvias.

	Cuenca México		Cuenca Balsas	
Res	0.5	0.25	0.5	0.25
PC	0.80	0.80	0.78	0.79
PA	0.12	0.13	0.16	0.18
S	0.80	0.74	0.70	0.72
PD	0.19	0.20	0.24	0.26
PFD	0.05	0.06	0.08	0.10
RFA	0.76	0.73	0.66	0.64
PHH	0.10	0.12	0.16	0.18
PDE	0.08	0.08	0.09	0.13

El mapa de PC muestra valores bastante elevados de éste para todo el dominio. Esto es consistente con la tabla de contingencia, en donde la mayor parte de los eventos fue de “no precipitación”, algo que el modelo fue muy bueno para pronosticar. El complemento de esta medida se puede ver en el mapa de PA, que muestra un error muy grande para todo el dominio. Esto indica que para observaciones de “precipitación” el modelo no fue capaz de indicar lo mismo. Esto es congruente también con las tablas de contingencia, donde los pares de observación ‘sí’/pronóstico ‘no’ y observación ‘no’/pronóstico ‘sí’ fueron mucho más numerosos que los pares observación ‘sí’ / pronóstico ‘sí’.

El mapa de sesgo indica que las regiones con mayor sesgo son aquellas en donde la topografía es más complicada, como es el caso de las estaciones ubicadas cerca del volcán Popocatepetl, al sureste del dominio. Los puntos ubicados en la parte central del dominio, donde la topografía es más plana, muestran el menor sesgo de todo el dominio.

El mapa de RFA muestra también un error fuerte en todo el dominio, lo que indica que el modelo es muy propenso a indicar que habrá precipitación cuando no hay. Esto también es consistente con las tablas de contingencia observadas.

Así mismo la tabla 3.3 muestra que la PD es muy baja para ambas cuencas. Similarmente el PHH y el PDE muestran valores muy bajos, lo que nos permite concluir que el modelo tiene una calidad de pronóstico muy baja para la precipitación.

Entre las dos resoluciones se observa que hay cambios muy pequeños al pasar de 0.5 a 0.25. Lo anterior sugiere que el error es debido a la elección de parametrizaciones y resolución de modelación, mostrando posiblemente una sensibilidad muy baja ante cambio en las C.I. y de F., aunque cabe destacar que también es posible que estas condiciones no estén cambiando notablemente al pasar de una resolución a otra.

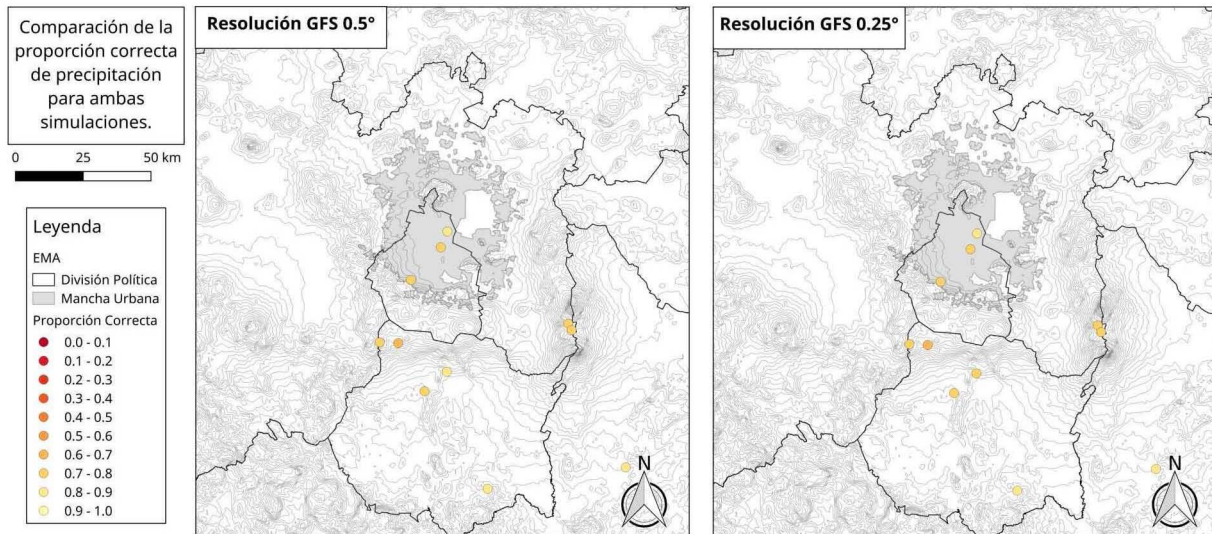


Figura 3.1: Mapas de Proporción Correcta (PC) para la temporada húmeda.

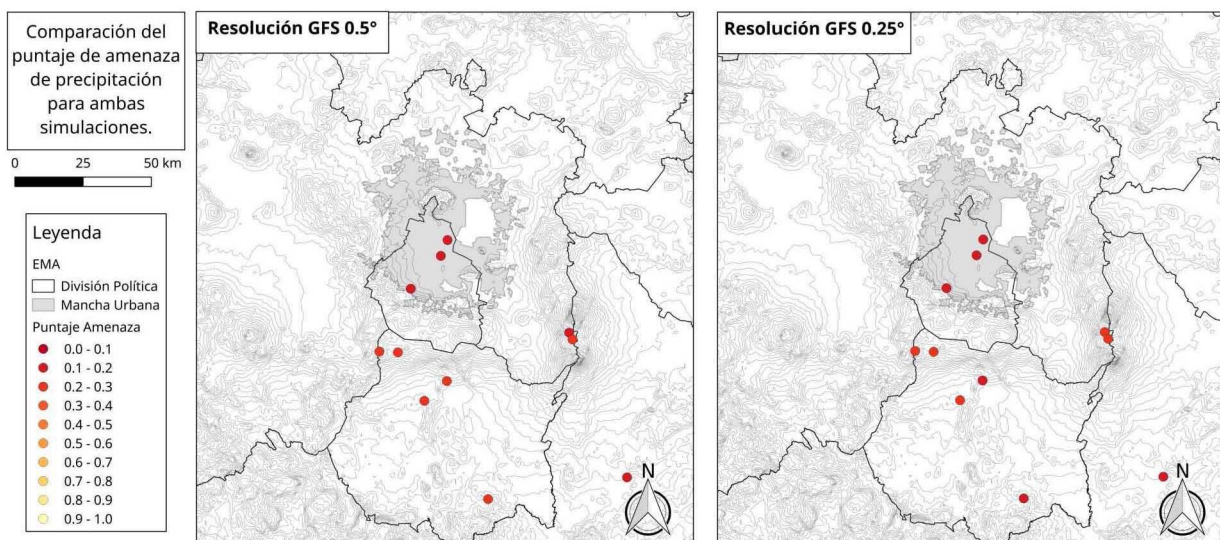


Figura 3.2: Mapas de Puntaje de Amenaza (PA) para la temporada húmeda.



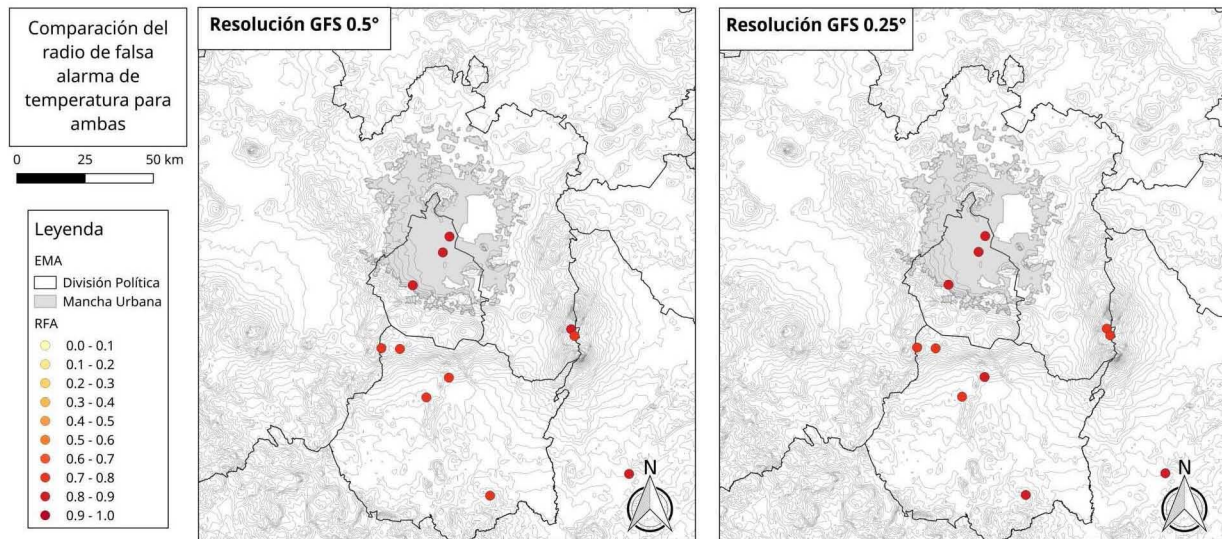


Figura 3.3: Mapas de Razón de Falsa Alarma (RFA) para la temporada húmeda.

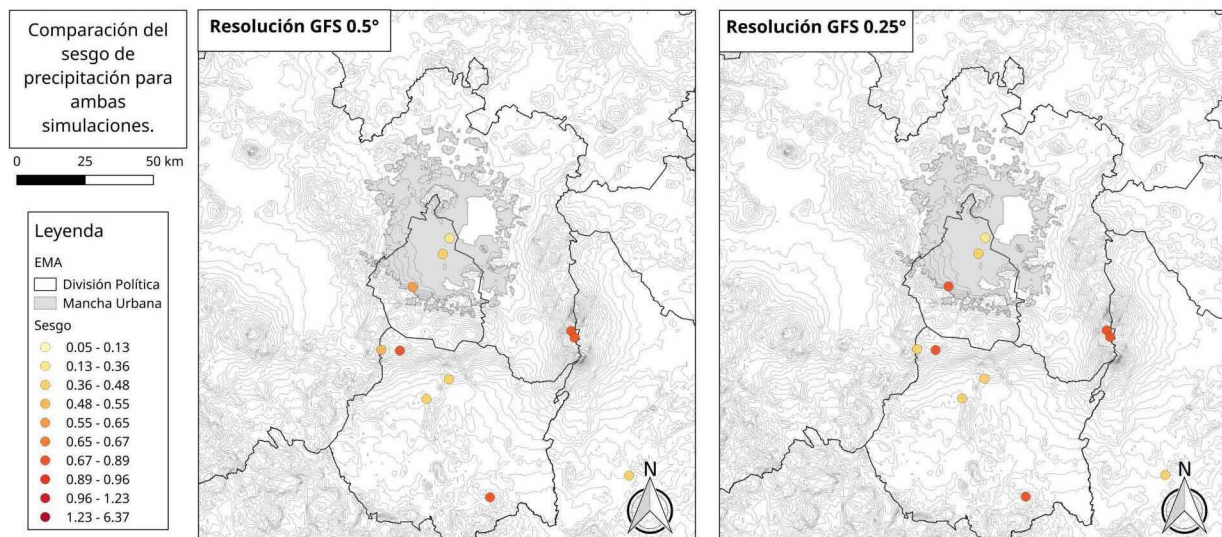


Figura 3.4: Mapas de Sesgo para la temporada húmeda.



### 3.1.2. Temperatura

Los diagramas de Taylor calculados para la temperatura se muestran en las Figuras 3.5 a 3.7. En estos se muestran los resultados de verificación para las estaciones contenidas en la Cuenca de México y en la Cuenca del Río Balsas. Mientras más cercano estén los puntos a el punto verde con correlación de 1 y desviación estándar de 1, mejor será el pronóstico.

Los resultados para las tres temporadas son muy similares, con los puntos mostrando un coeficiente de correlación que va del 0.8 al 0.9, el cual es un valor bastante elevado. En particular para la temporada de secas frías este coeficiente llega a valores cercanos a 0.95, sobre todo para las estaciones de la Cuenca de México. Esto nos dice que cuando las temperaturas observadas son relativamente altas, las temperaturas del modelo son altas también, y viceversa para las temperaturas bajas.

Por otro lado, si analizamos la posición radial de los puntos para ver la distribución de la desviación estándar a lo largo de las estaciones podemos ver algunas diferencias entre estas. En la temporada de lluvias los puntos caen principalmente en valores más grandes de desviación estándar, indicando que el pronóstico constantemente sobreestima la amplitud de las observaciones. Esta situación se invierte en las temporadas secas, donde los puntos principalmente caen en valores más pequeños de desviación estándar, indicando que los pronósticos comúnmente subestiman las observaciones.

Cabe destacar que al comparar entre simulaciones con diferentes condiciones iniciales, no se observan cambios importantes. Casi siempre los puntos rojos se encuentran muy cercanos a los azules, con pocas instancias en donde se pueda apreciar un cambio entre los dos colores. La poca diferencia entre estos puntos podría indicar que la sensibilidad del modelo ante diferentes resoluciones de C.I. y de F. no es muy fuerte para el Valle de México, algo que será explorado más a fondo en la siguiente sección.

Estos dos resultados (correlación alta con fuerte sesgo) nos dicen que la simulación muestra una buena calidad para representar el aumento o disminución de las temperaturas a lo largo del día, pero no es bueno para estimar adecuadamente la magnitud de estos valores. Este fenómeno ocurre tanto para las estaciones del Valle de México como para aquellas localizadas en zonas con topografía más compleja. Tomando esto en cuenta podemos inferir que el problema es generalizado para el modelo con la configuración usada.

Un resultado que apoya esta observación está dado por los círculos de error cuadrático medio centrado constante (dibujados en verde en los diagramas). En la temporada de lluvias vemos que este error tiene valores relativamente altos, que van del 0.4 al 0.6, mientras que para las temporadas secas va del 0.3 al 0.6. Esto nos dice que en general el modelo muestra un poco más de calidad para pronósticos de las temporadas secas que de la temporada de lluvia, aunque para ambas temporadas el error mostrado es relativamente alto para todas las estaciones.

Los mapas de las Figuras 3.8 a 3.10 muestran la distribución espacial de los errores a lo largo del dominio, con colores menos rojizos mostrando el menor error, y colores más rojos mostrando mayor error. Se observa que los menores errores medios cuadráticos se concentran en la parte noreste de la Ciudad de México, incluyendo algunas estaciones del Estado de México. En contraste, las estaciones en el noroeste/centro de la ciudad muestran fuertes valores de EMC, junto con las estaciones fuera del Valle de México.

El mapa de errores medios absolutos de la Figura 3.9 muestra una historia similar al de los EMC, aunque en este caso los puntos con menos errores son todos aquellos localizados en la zona norte/centro de la Ciudad de México, estando los errores más grandes en las

afueras de la ZMVM. La magnitud de los errores para esta región es del rango de 1 a 2 grados centígrados para todas las temporadas.

El análisis del EMA nos dice que la simulación es buena para aproximar las magnitudes de las temperaturas en el Valle de México, pero el EMC nos dice que no es adecuada para simular los valores extremos, sobre todo en la región noroeste del Valle.

El análisis del mapa del error medio, Figura 3.10, muestra que en la región norte/central del valle las temperaturas son constantemente subestimadas por el modelo. Esto va de acuerdo a los diagramas de Taylor, que indicaban que para las temporadas secas la mayor parte de los puntos subestimaba la variabilidad de las observaciones.

Para analizar más a fondo los errores de los puntos del norte y centrales, se escogieron dos estaciones para observar los diagramas cuantil-cuantil y las series de tiempo: la estación de la Escuela Nacional de Ciencias Biológicas 02 (Código encb02) y la estación Acolman (Código ACO). Las series de tiempo se pueden ver en la Figura 3.11 para ACO y en la Figura 3.12 para Encb02; y los diagramas cuantil en la Figura 3.13 para ACO y en la Figura 3.14 para Encb02. Los códigos de tres letras *SEC*, *HUM*, *SEF* hacen referencia a la temporada seca cálida, seca fría y húmeda, respectivamente. La estación ACO se encuentra al norte del Valle de México, en la región donde el EMC presentaba menores valores. En cambio, la estación Encb02 se encuentra en el norte/centro, la región con elevados valores de EMC.

La serie de tiempo del punto ACO muestra que los pronósticos están muy bien correlacionados con las observaciones, manteniendo el mismo ciclo diurno. Sin embargo, para las temporadas secas se puede ver que los pronósticos tienen magnitudes más pequeñas que las observaciones, y en la temporada húmeda los pronósticos son constantemente de mayor magnitud que las observaciones. Esto va de acuerdo con lo visto en el digrama de Taylor analizado al inicio de esta sección. La situación es la misma para ambas resoluciones, sugiriendo que en esta región la sensibilidad de la simulación ante C.I. y de F. es muy baja.

Los diagramas cuantil-cuantil del punto ACO muestran también este comportamiento. En los meses de secas el pronóstico subestima constantemente las temperaturas, mientras que en la temporada húmeda se subestiman las bajas temperaturas y se sobreestiman los extremos cálidos. La temporada húmeda muestra el mejor desempeño del pronóstico en temperaturas cercanas a los 20 grados centígrados. Entre resoluciones hay cambios pequeños, sin notar una mejoría aparente entre los pronósticos. Los valores de nitidez, representados por qué tan *desparramado* está el histograma en los diagramas, parecen ser constantes también, con una pequeña tendencia del pronóstico de 0.25 de ser un poco más concentrado hacia valores centrales.

La situación cambia al analizar la serie de tiempo del punto Encb02 al mostrar pronósticos que subestiman siempre la observación. Esto es consistente con lo observado en la distribución del EM, que mostraba fuertes valores negativos en esta región. Al comparar las dos resoluciones no se aprecia un cambio fuerte, lo que sugiere que para esta región la sensibilidad del modelo ante CI también es baja.

Al observar los diagramas cuantil-cuantil para este punto se observa también una subestimación de los valores de temperatura. Esta es constante a lo largo del año, siendo un poco menos marcada en los extremos derechos de la temporada de lluvias. Entre resoluciones la situación es la misma, sin que se aprecie un cambio fuerte entre estos. La nitidez del modelo tiende a centrarse en valores de temperaturas relativamente bajas, de 10 a 15 grados centígrados para ambas resoluciones.

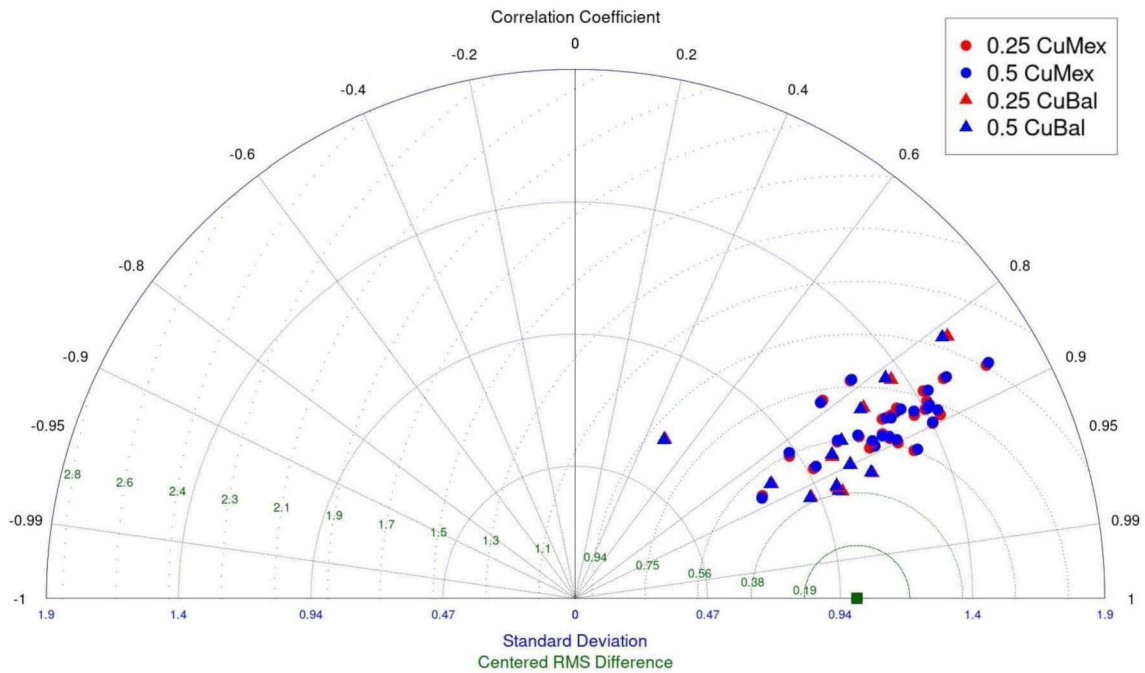


Figura 3.5: Diagrama de Taylor para la variable temperatura, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).

Para este punto (Encb02) la correlación entre las dos series es muy buena, pero el modelo no parece ser capaz de representar los procesos de superficie que ocasionan una subida en la temperatura. Ya que esta región es de las más urbanizadas en el Valle de México podemos pensar que la isla de calor urbana sea causante de las altas temperaturas en esta zona. Este es un fenómeno estudiado en anterioridad por Jauregui (1997).

El que no hubiera un cambio fuerte entre las resoluciones para modelar este fenómeno sugiere que el problema está en la representación de uso de suelo y de parametrizaciones de superficie usadas para la simulación. Este es un problema común al usar bases de datos de uso de suelo no actualizadas, como ha sido estudiado por López-Espinoza et al. (2012).

### 3.1.3. Magnitud de la velocidad del viento

Al igual que con la temperatura, los diagramas de Taylor calculados para la magnitud de la velocidad del viento se muestran en las Figuras 3.15 a 3.17. En este caso basta con hacer una observación rápida de los tres diagramas para observar que el modelo muestra un error muy grande para simular tanto la correlación como la variabilidad de las observaciones.

En la temporada de lluvias los resultados muestran una correlación con rango de 0 a 0.4, valor considerado como bajo. Esto indica que la simulación no representa adecuadamente los aumentos y disminuciones de la magnitud del viento a lo largo del día. Los puntos caen tanto en valores mayores y menores a la desviación estándar de la muestra, en donde las estaciones CuBal parecen subestimar la variabilidad de los datos y las estaciones CuMeX la sobre estiman. Lo anterior sugiere que el error podría estar asociado a la distribución espacial de los accidentes orográficos del dominio.




Figura 3.6: Diagrama de Taylor para la variable temperatura, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).




Figura 3.7: Diagrama de Taylor para la variable temperatura, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).

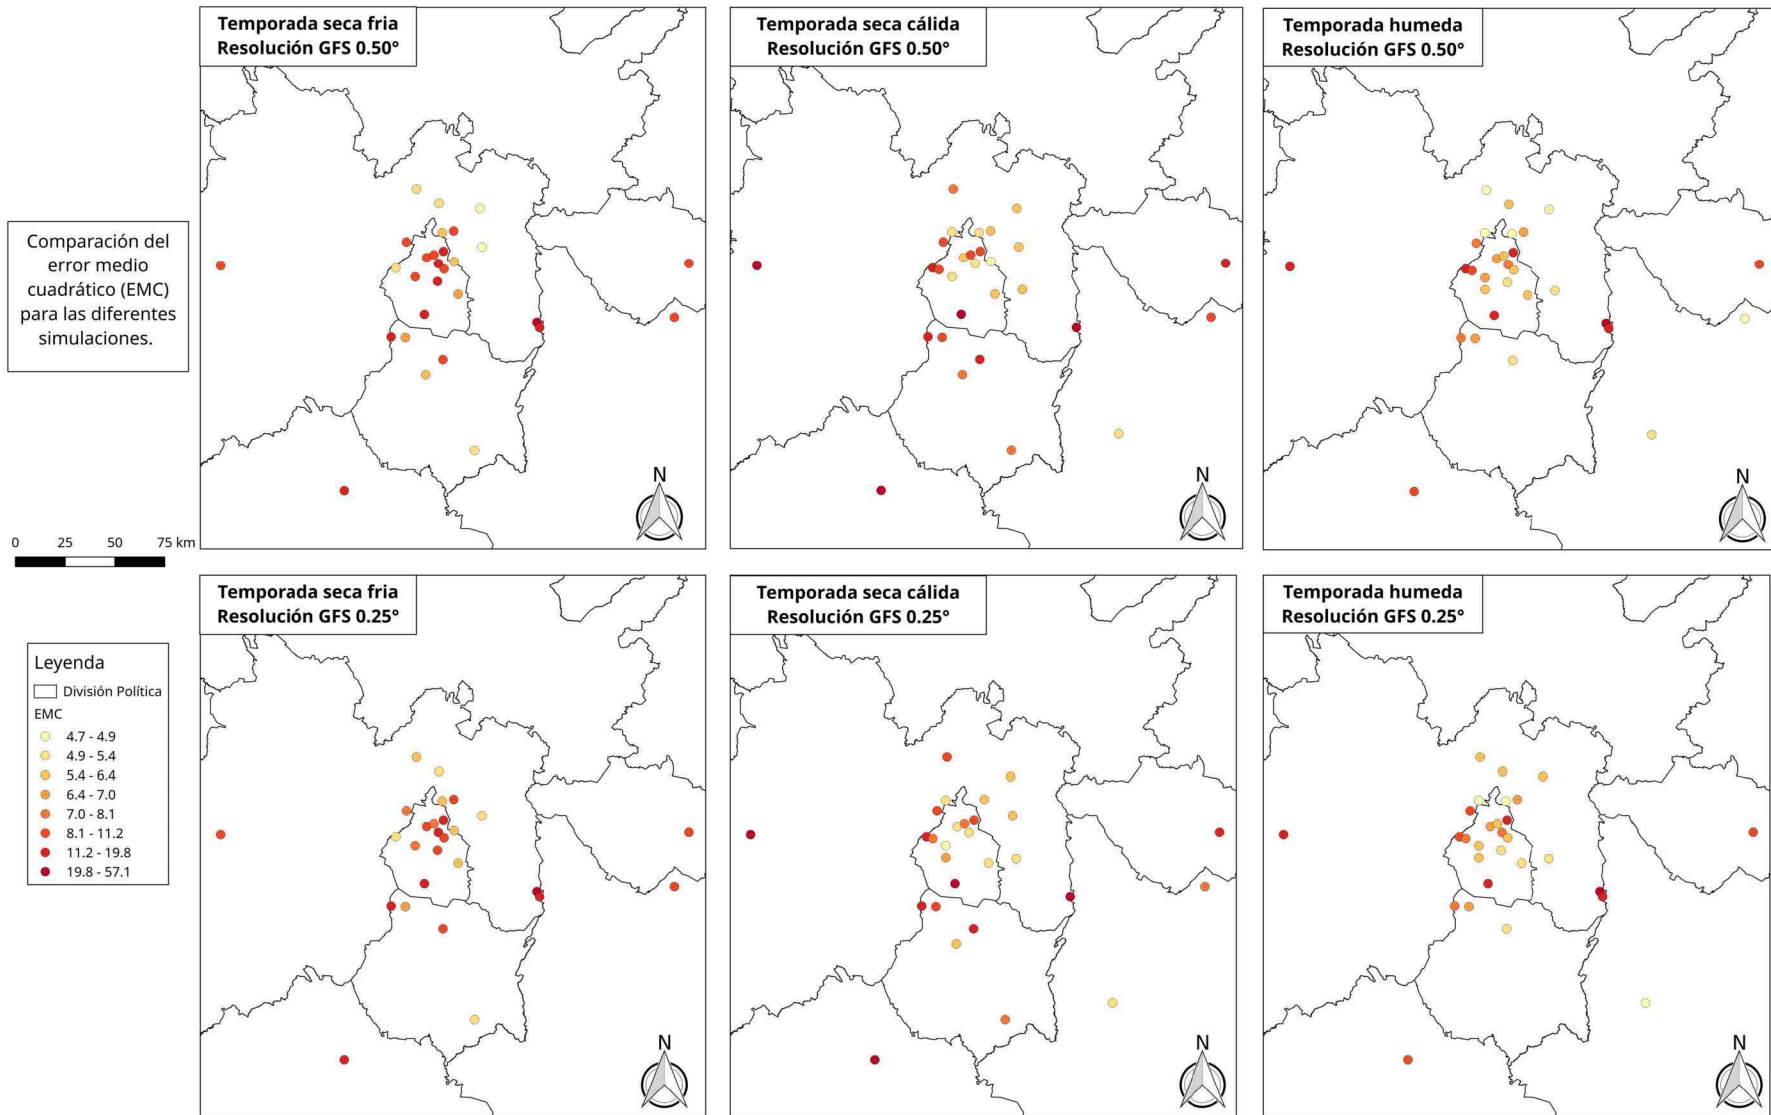


Figura 3.8: Comparación del error cuadrático medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación.



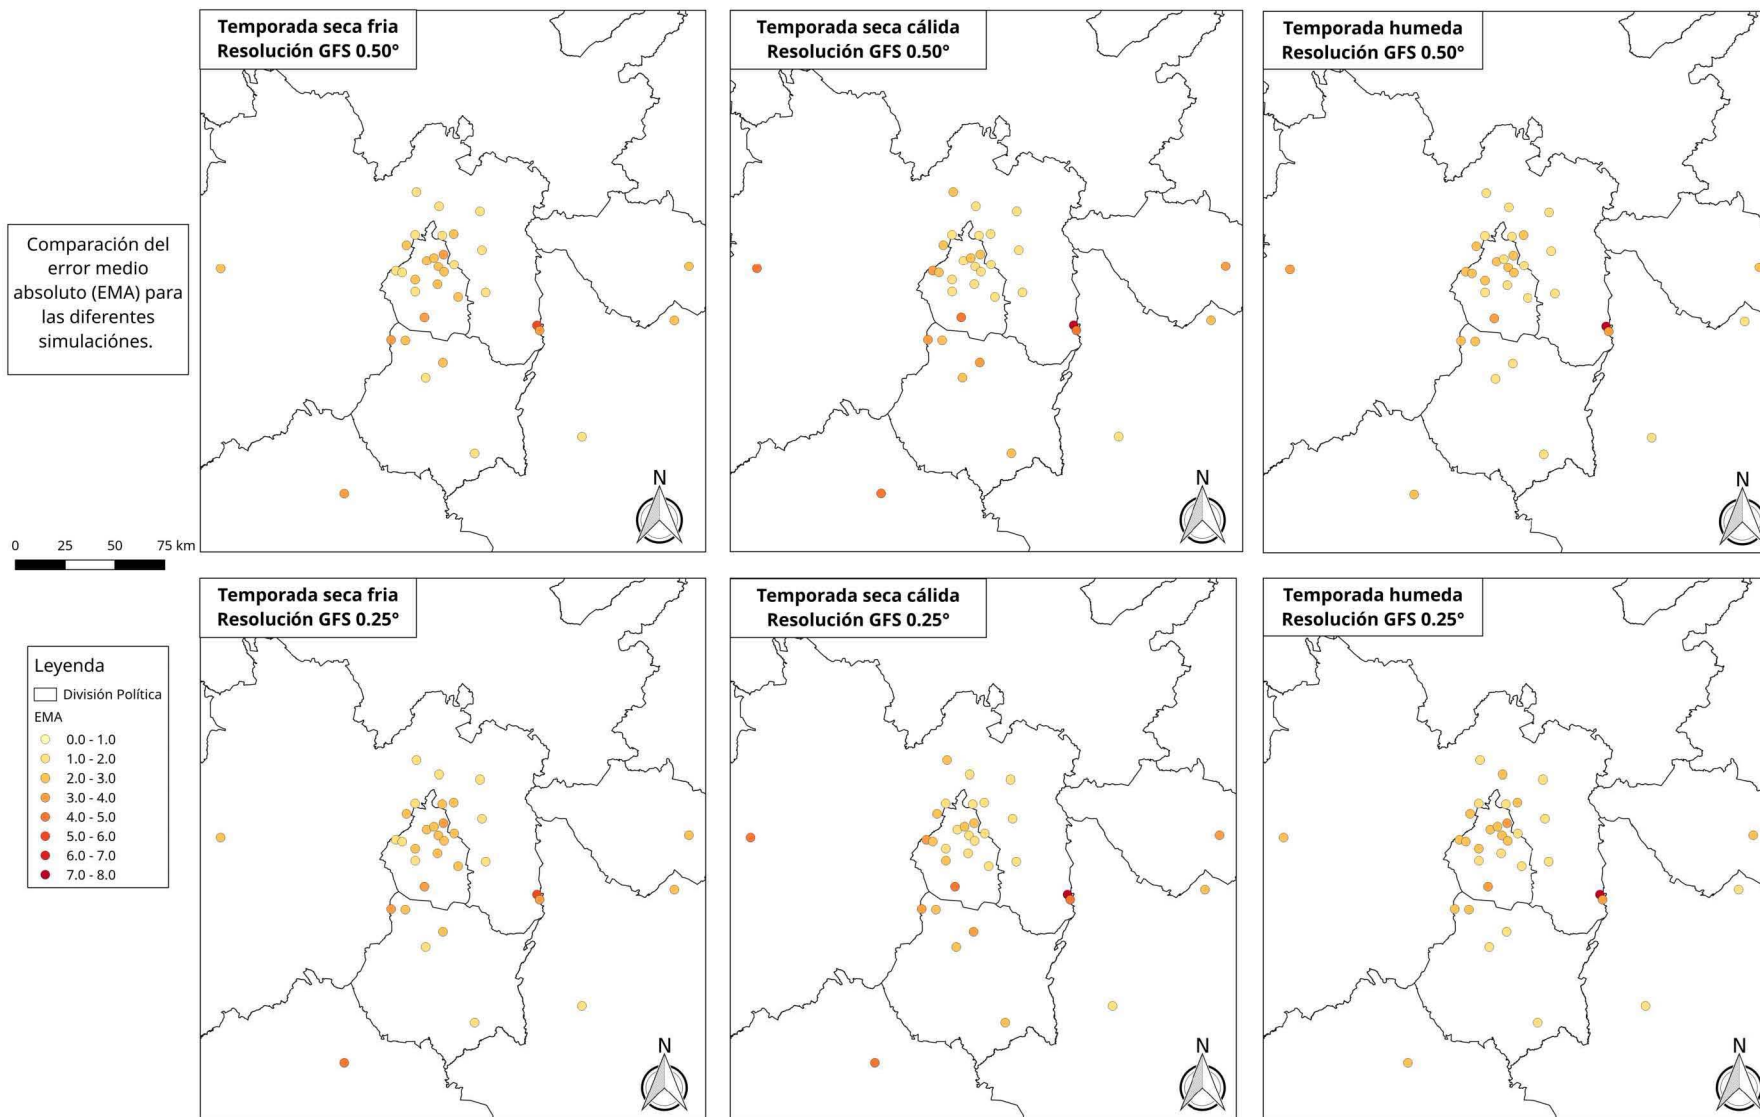


Figura 3.9: Comparación del error medio absoluto para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación.

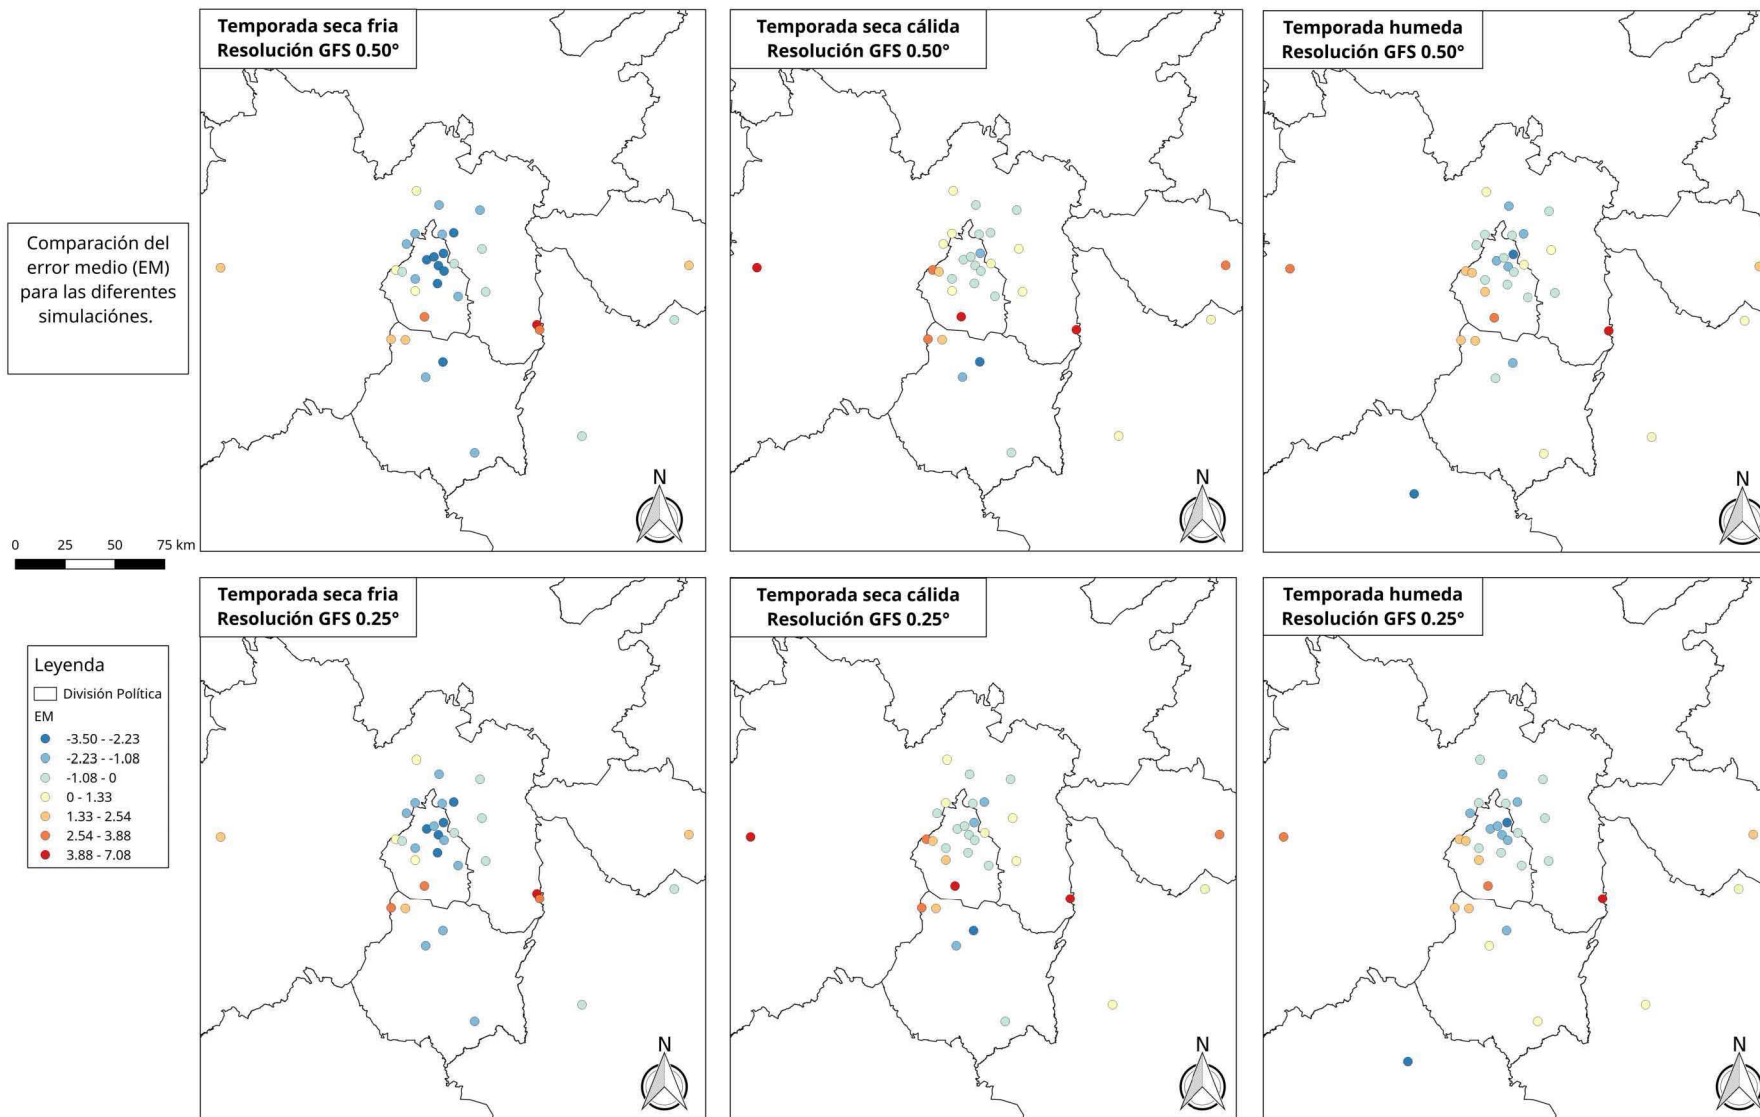


Figura 3.10: Comparación del error medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación.

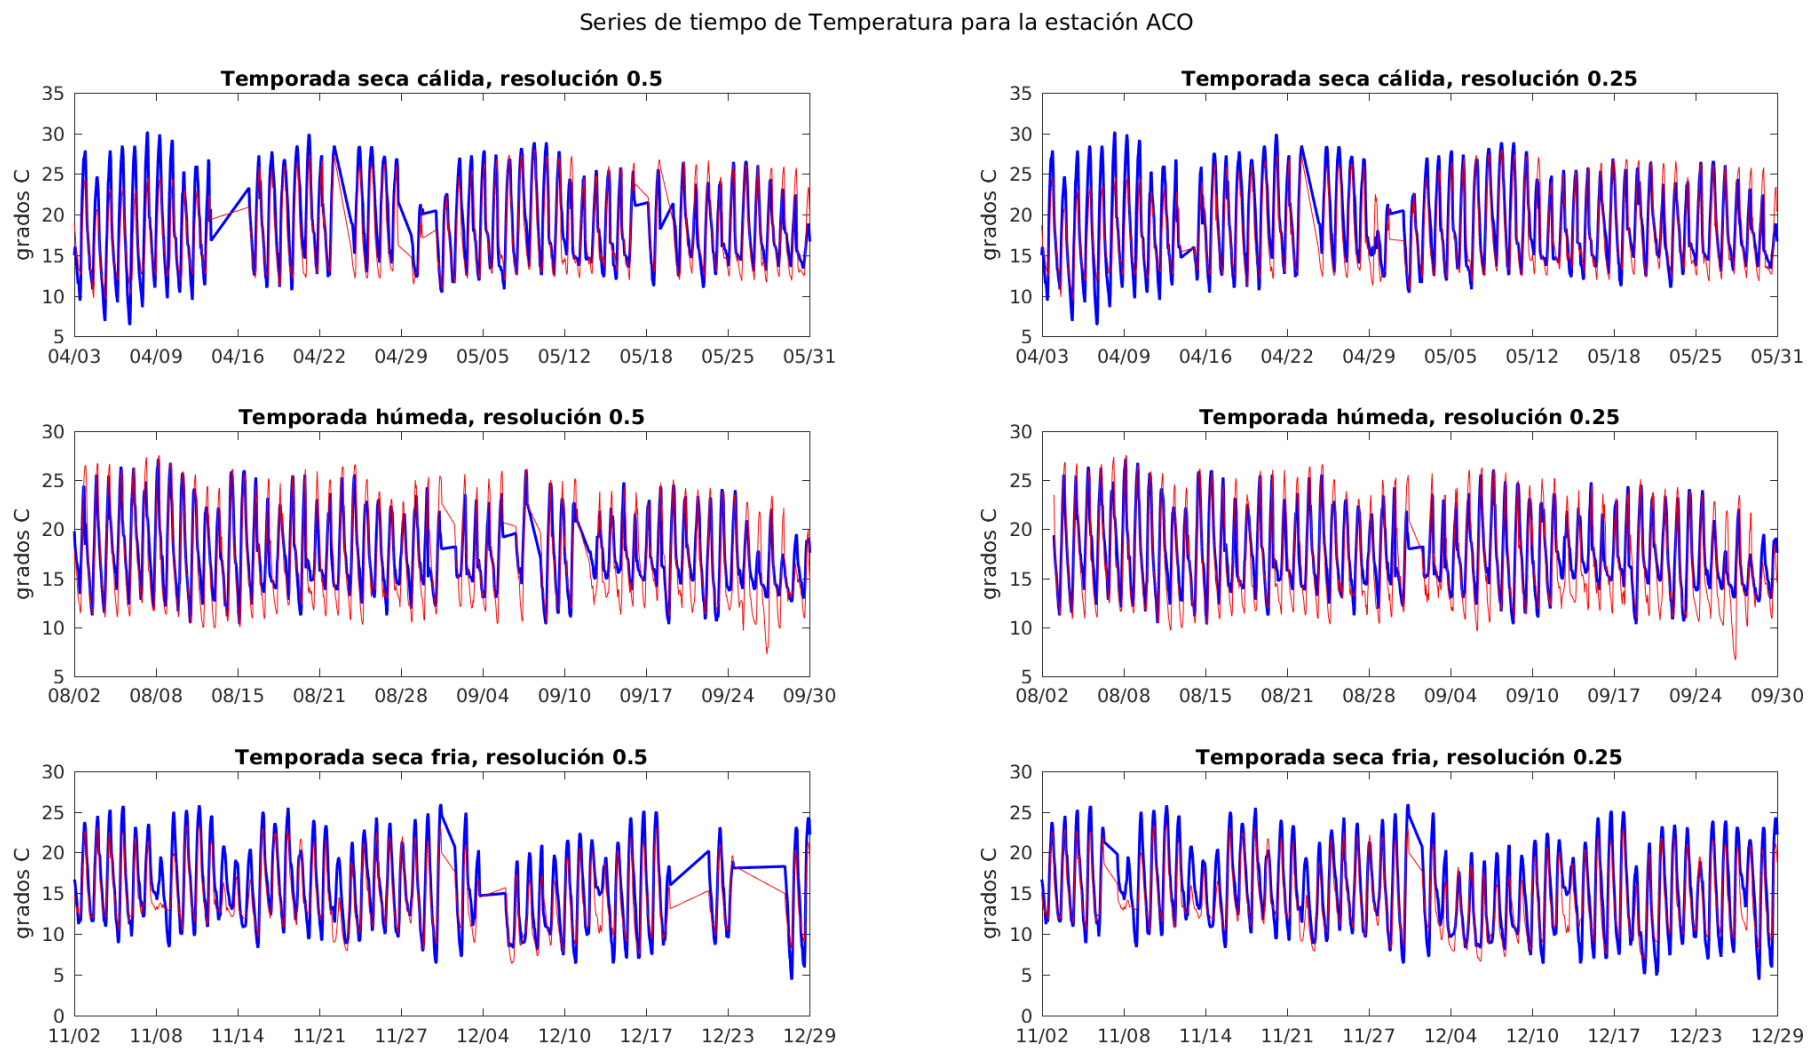


Figura 3.11: Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Acolman.



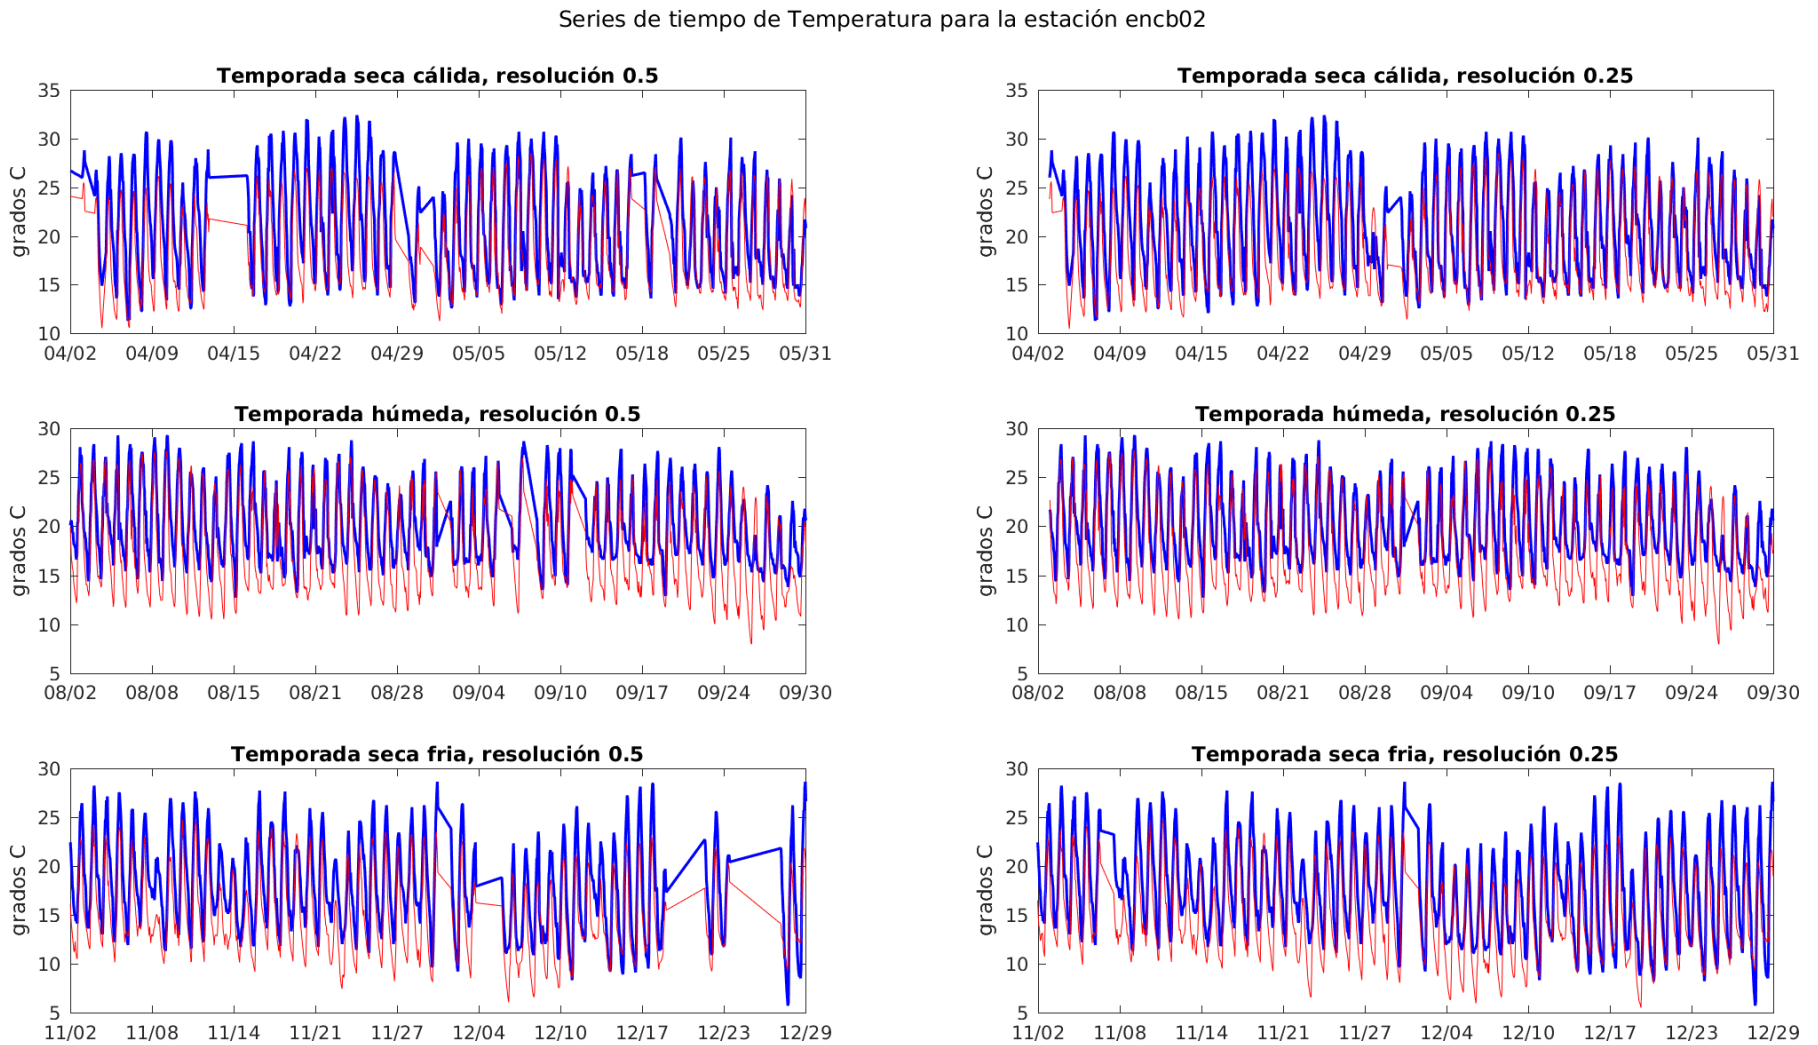


Figura 3.12: Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Escuela Nacional de Ciencias Biológicas 2.

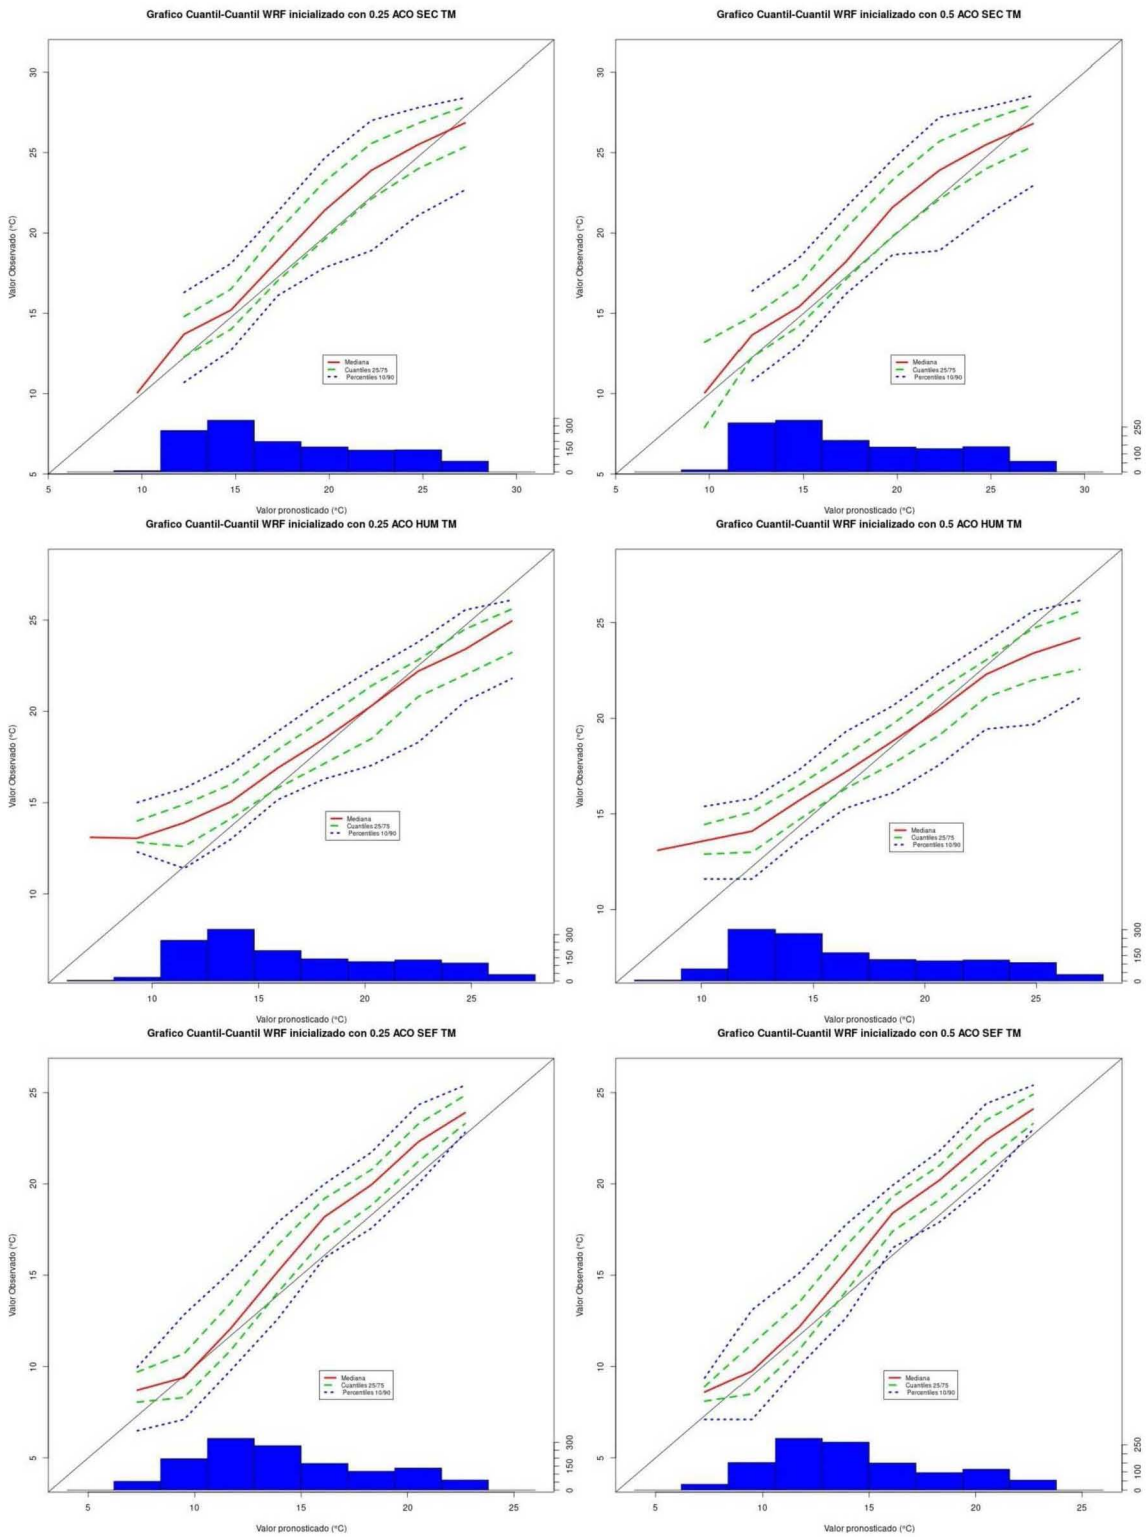


Figura 3.13: Diagrama cuantil-cuantil para la temperatura en la estación Acolman.

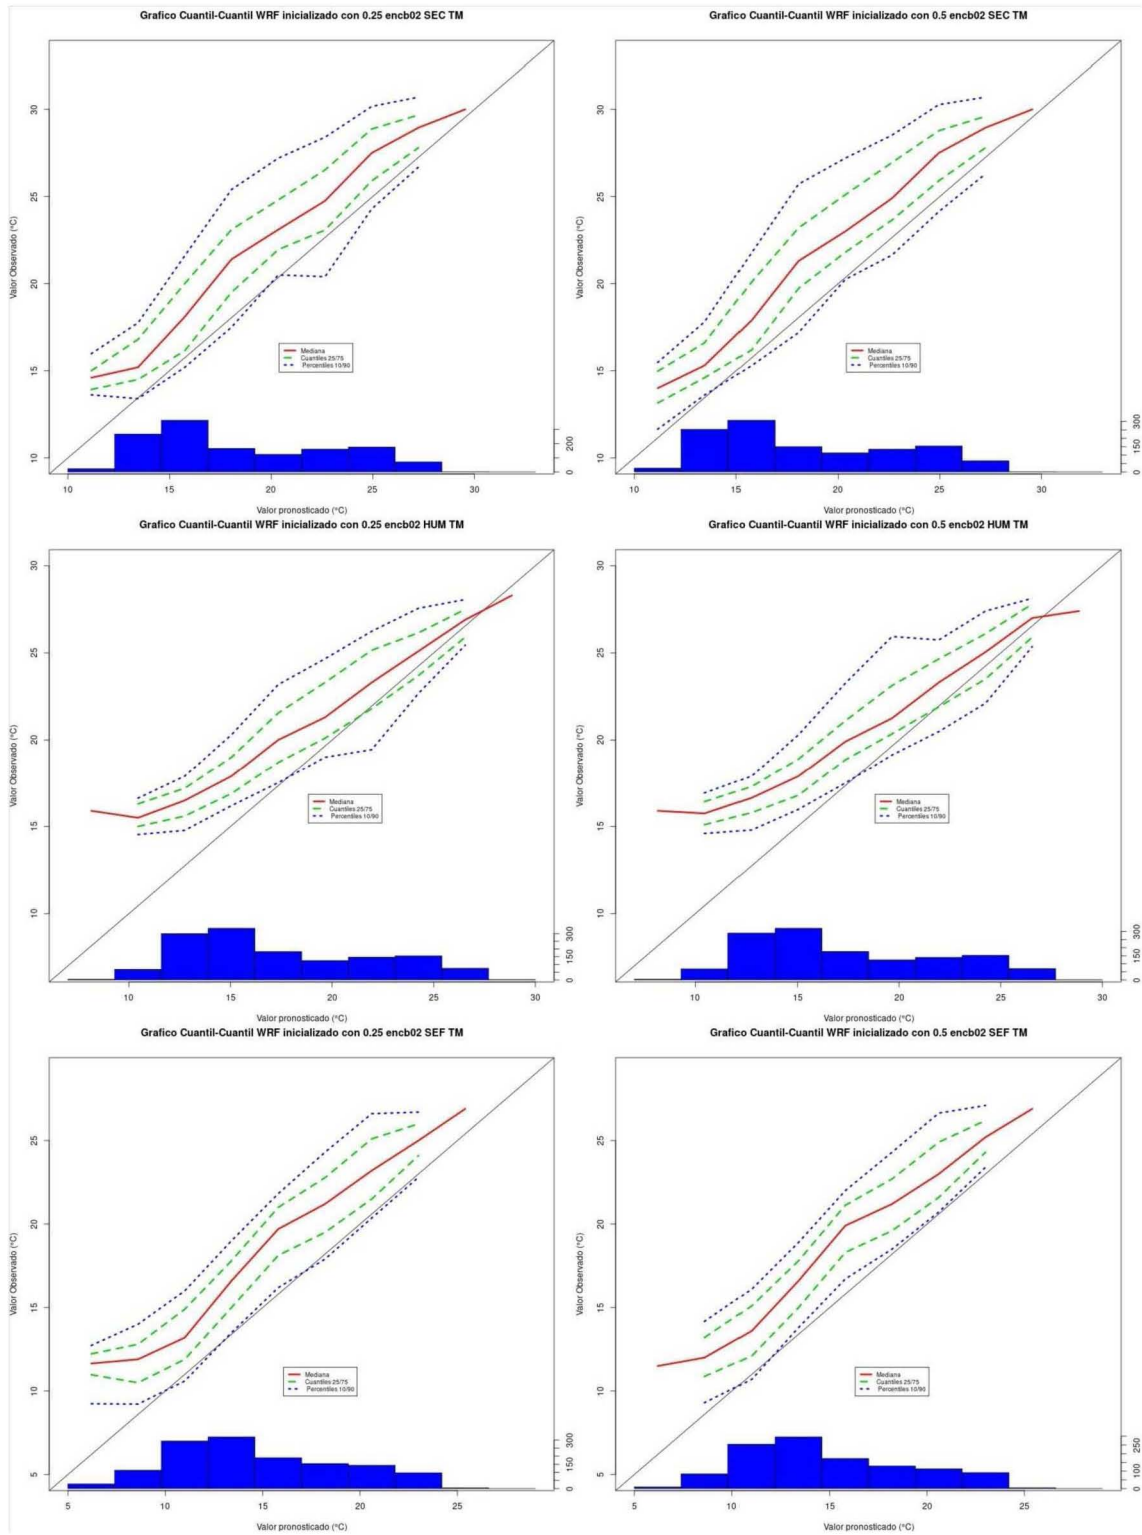


Figura 3.14: Diagrama cuantil-cuantil para la temperatura en la estación Encb02.

La temporada de secas cálidas muestra una distribución de puntos similar a la temporada de lluvias, con la diferencia de que el rango del coeficiente de correlación va de 0.2 a 0.4, mostrando una pequeña mejora con respecto de la temporada de lluvias. Las estaciones CuBal también subestiman la variabilidad, mientras que las CuMex las sobreestiman.

La temporada de secas frías es la que muestra una mayor diferencia en el diagrama de Taylor. En esta las estaciones están esparcidas en una región mayor de correlaciones y desviaciones estándar. El coeficiente de correlación va de valores ligeramente negativos hasta 0.7, el cual es el rango más amplio de las tres temporadas. Al igual que las otras dos temporadas, las estaciones CuBal caen por debajo de la desviación estándar de la muestra, mientras que las CuMex caen por encima. El que las tres temporadas muestren este patrón espacial de sub y sobre estimación sugiere que este error es indiferente ante variaciones estacionales del patrón de vientos, y se asocia a fenómenos locales de mesoescala, como pueden ser brisas de valle montaña (Jazcilevich et al., 2005).

En cuanto a la sensibilidad del modelo podemos observar una diferencia más grande que para la temperatura entre las dos resoluciones. En general los puntos de resolución de 0.25 se acercan más a el pronóstico perfecto, aunque en términos de error cuadrático medio centrado, caen casi sobre el mismo círculo de error constante. La mayor diferencia se puede observar para la temporada de secas frías sobre todo para las estaciones CuMex.

Los mapas de la distribución del error cuadrático medio muestran una concentración de errores de grandes magnitudes en la región norte/centro del Valle. Los errores tienden a ser menores en las regiones del norte, sobre todo en aquellas fuera de la mancha urbana. Los puntos ubicados en zonas de fuerte topografía, como altzom o AJU muestran también errores con magnitudes grandes. En términos de temporadas, la temporada de secas frías es la que muestra mayor concentración de error en la zona centro/norte. Entre resoluciones se aprecia una disminución de error muy ligera al pasar de 0.5 a 0.25 grados.

La distribución del error medio absoluto es muy similar a la del error cuadrático medio. Los errores de mayor magnitud se concentran en la región norte/centro del Valle (mancha urbana) así como en regiones de topografía complicada. Los puntos del noreste muestran las magnitudes de error más bajas, los cuales corresponden a puntos de topografía plana y fuera de la mancha urbana principal. La estación con el error más grande es la de secas frías. Entre ambas resoluciones no se observan cambios importantes.

El mapa de distribución de error medio indica una subestimación en regiones planas y una sobreestimación en regiones de topografía importante. Tanto puntos del norte/centro como del noreste muestran errores medios negativos (subestimación), con la magnitud más negativa en el norte/centro. Los puntos que están cerca de topografía compleja, como AJU, altzom o tresma muestran valores positivos grandes de error (sobreestimación). El error es más marcado en la temporada de secas frías, y menor en la de secas cálidas. La comparación entre resoluciones no muestra una diferencia importante entre los errores.

Para estudiar más profundamente el fenómeno de sobreestimar en las montañas y subestimar en el valle, se eligieron dos puntos para analizar series de tiempo y diagramas cuantil-cuantil. El primer punto es el de la estación AJU, representando un punto en topografía complicada. La serie de tiempo de AJU se puede observar en la Figura 3.21 y el diagrama cuantil-cuantil en la Figura 3.23. El segundo punto es el de la estación UAX, representando una región plana. La serie de tiempo de UAX se puede observar en la Figura 3.22 y el diagrama cuantil-cuantil en la Figura 3.24.

La serie de tiempo para el punto AJU confirma lo antes observado con el error medio

y el diagrama de Taylor, viendo que hay una constante sobreestimación de los valores de la magnitud del viento. Esta situación parece ser la misma para las dos resoluciones, algo que también muestra el diagrama cuantil-cuantil. Entre estaciones se observa que la temporada seca fría es donde la correlación entre series es mejor, aunque aún se presenta la sobreestimación.

Por otro lado, la serie de tiempo para el punto UAX muestra un mejor acoplamiento entre las series, pero con varias regiones de subestimación de la magnitud. El diagrama cuantil-cuantil nos ayuda a observar que en las regiones a la izquierda de la cola del histograma existe subestimación de los valores, y dado que esta región es donde se encuentra la mayor parte de los conteos, el error medio global resultante es negativo. Al ver el cambio entre resoluciones se observa que la cola del histograma tiende a concentrarse un poco hacia valores más pequeños. También se puede apreciar que la mayor calidad del pronóstico se alcanzó en la temporada de secas frías, y la peor en la temporada húmeda.

Dada la situación topográfica de las dos estaciones estudiadas, se cree que el error presentado por estas dos estaciones puede estar asociado al fenómeno de brisa de vallemontaña, donde se esperaría que la estación que esta en sotavento (UAX) tuviera magnitudes más grandes al llegar la corriente de gravedad. Ya que este fenómeno no es resuelto por el modelo con ninguna de las dos resoluciones, tendrían que hacerse simulaciones de mayor resolución para analizar fenómenos de ésta escala. La escala horizontal típica de estos fenómenos es del orden de 5 km.

En general la simulación del viento parece ser bastante inadecuada para la región del Valle de México. Los diagramas de Taylor muestran una muy baja correlación con fuertes problemas para replicar la variabilidad del viento. Los mapas de distribución de error también muestran fuertes errores en el centro del Valle y en las regiones con topografía complicada. La temporada con más errores globalmente fue la de secas frías, la cual es la temporada en donde se presentan la mayor parte de los eventos de frentes fríos que afectan a la región. Ya que estos frentes se asocian a cambios en la dirección y magnitud del viento, es posible que el modelo no sea capaz de resolver este fenómeno con la configuración usada para el pronóstico.

## 3.2. Sensibilidad ante condiciones iniciales y de frontera

### 3.2.1. Temperatura

Los diagramas de bosque que representan los intervalos de confianza calculados mediante el *bootstrap* para la diferencia de medias de los errores se muestran en las Figuras 3.25 a 3.27 para el error medio absoluto. Cada color representa una de tres posibles situaciones, que la estación esté en la mancha urbana con topografía plana, que la estación esté fuera de la mancha urbana con topografía plana o que la estación se encuentre en una montaña. Cuando la media se encuentra del lado derecho del cero existe una mejoría en la calidad del pronóstico debido al cambio de C.I. y de F. a 0.25, mientras que si se encuentra del lado izquierdo la calidad del pronóstico empeoró al emplear C.I. y de F. de 0.25.

El diagrama de la temporada húmeda (Figura 3.25) muestra que existe poca sensibilidad del modelo a C.I. y de F. para esta temporada. Esto se concluye porque casi todas las estaciones tienen al 0 dentro de sus intervalos de confianza, con la excepción de 4 estaciones en las montañas: AJU, altzom, tresma y pqizta. La mayor parte de las estaciones de montaña muestra pérdida de calidad, aunque como se mencionó solo 4 de estas muestran




Figura 3.15: Diagrama de Taylor para la variable magnitud del viento, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).

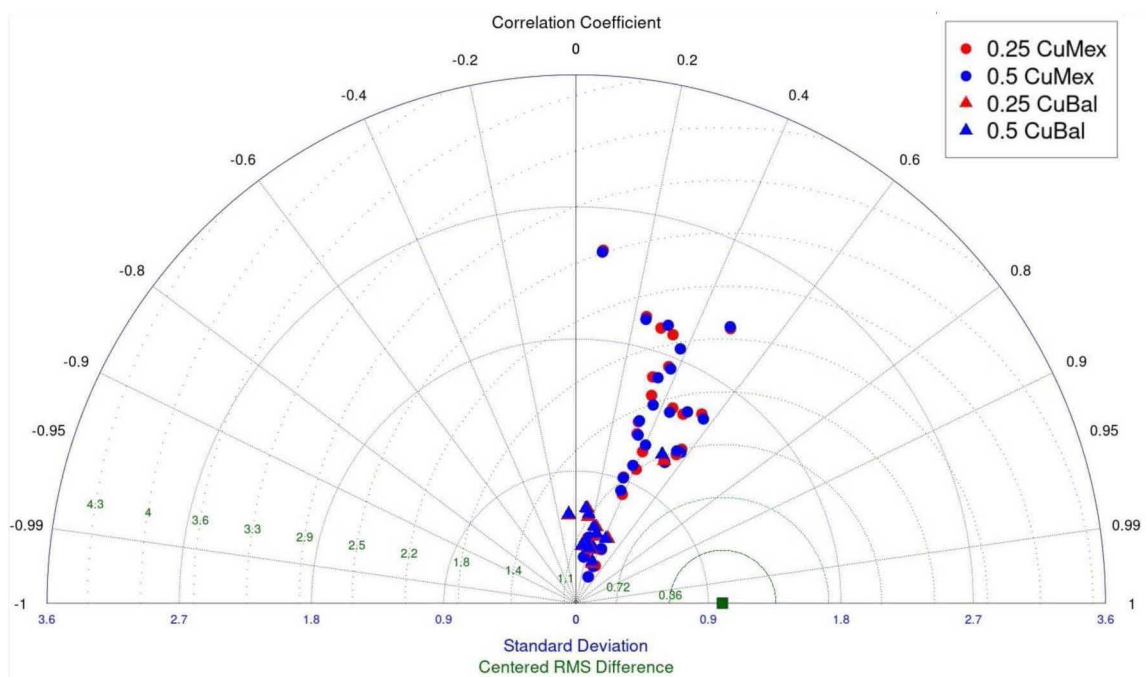


Figura 3.16: Diagrama de Taylor para la variable magnitud del viento, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).






Figura 3.17: Diagrama de Taylor para la variable magnitud del viento, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).

un cambio lo suficientemente grande como para ser estadísticamente significativo. Los puntos urbanos en cambio se muestran más centrados hacia el 0, donde sólo las estaciones TLA, XAL y SAG mostraron una desmejora estadísticamente significativa. Esto es notable ya que estos tres puntos se encuentran muy cercanos a la ladera del cerro de Guadalupe, al norte del Valle de México.

Para la temporada seca cálida (Figura 3.26), es posible observar una sensibilidad muy grande del modelo en los puntos de montaña, ya que quince de los veintinueve puntos de montaña (rojos) muestran un cambio estadísticamente significativo. De estos diez muestran desmejoría y cinco una mejora en calidad. Las estaciones de montaña que mostraron desmejoría son aquellas que se encuentran en las montañas que rodean al Valle. Lo anterior no ocurre para los puntos urbanos y no urbanos, ya que ninguno de estos muestra un cambio estadísticamente significativo. La tendencia de los intervalos de confianza para los puntos urbanos es de concentrarse del lado derecho del diagrama, sugiriendo una ligera ganancia de calidad para el modelo. Los puntos no urbanos en cambio se mantuvieron muy centrados, indicando una sensibilidad casi nula del modelo para las regiones fuera de la mancha urbana.

La tercer temporada analizada, secas frías, muestra en el diagrama de bosque (Figura 3.27) una sensibilidad moderada en los puntos de montaña con 12 de 21 puntos mostrando una diferencia estadísticamente significativa entre diferentes C.I. y de F. En este caso no hay un claro indicador de ganancia o pérdida de calidad, ya que casi el mismo número de puntos caen a la derecha y a la izquierda del cero (siete a la izquierda y cinco a la derecha). Los puntos urbanos muestran también una sensibilidad media ante el cambio de C.I., aunque en este caso es mucho más claro que la tendencia es a mejorar la calidad de los pronósticos. Los puntos no urbanos no muestran gran sensibilidad, aunque tienen una pequeña tendencia a moverse hacia la derecha del diagrama.

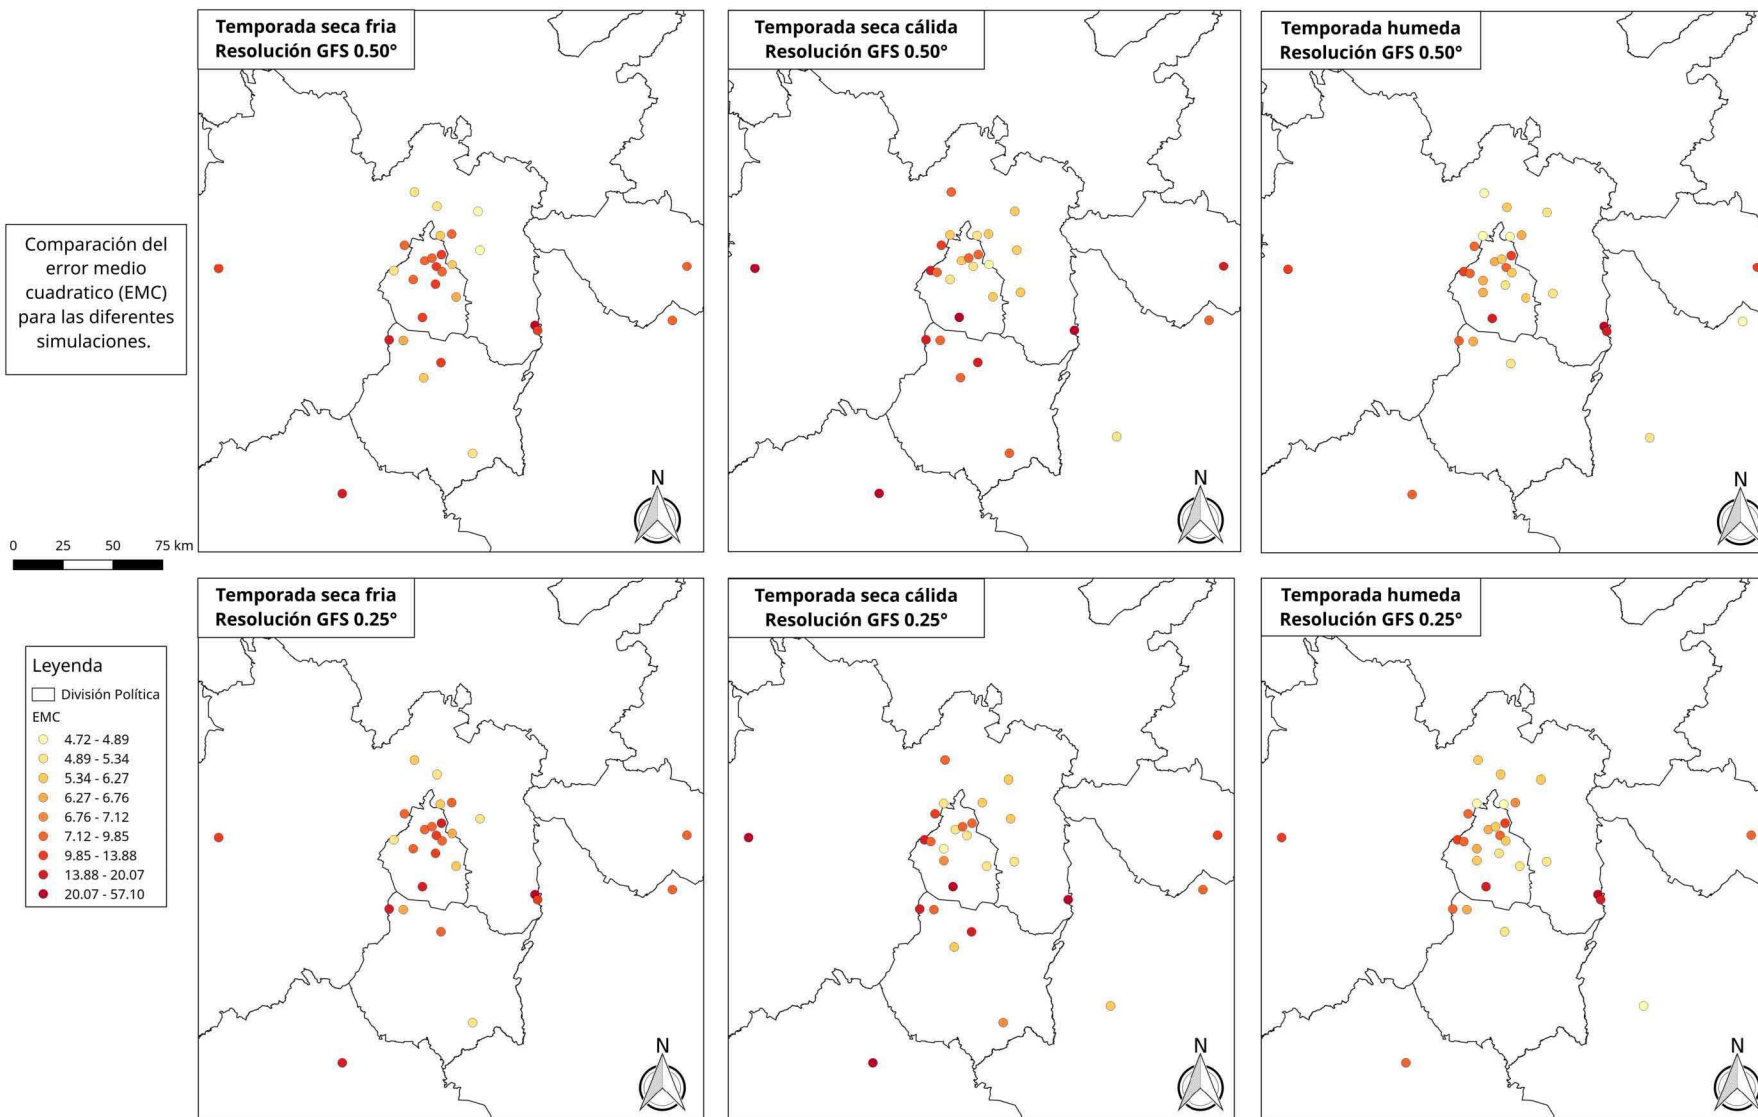


Figura 3.18: Comparación del error cuadrático medio para la variable magnitud del viento a lo largo de las temporadas analizadas para el dominio de simulación.



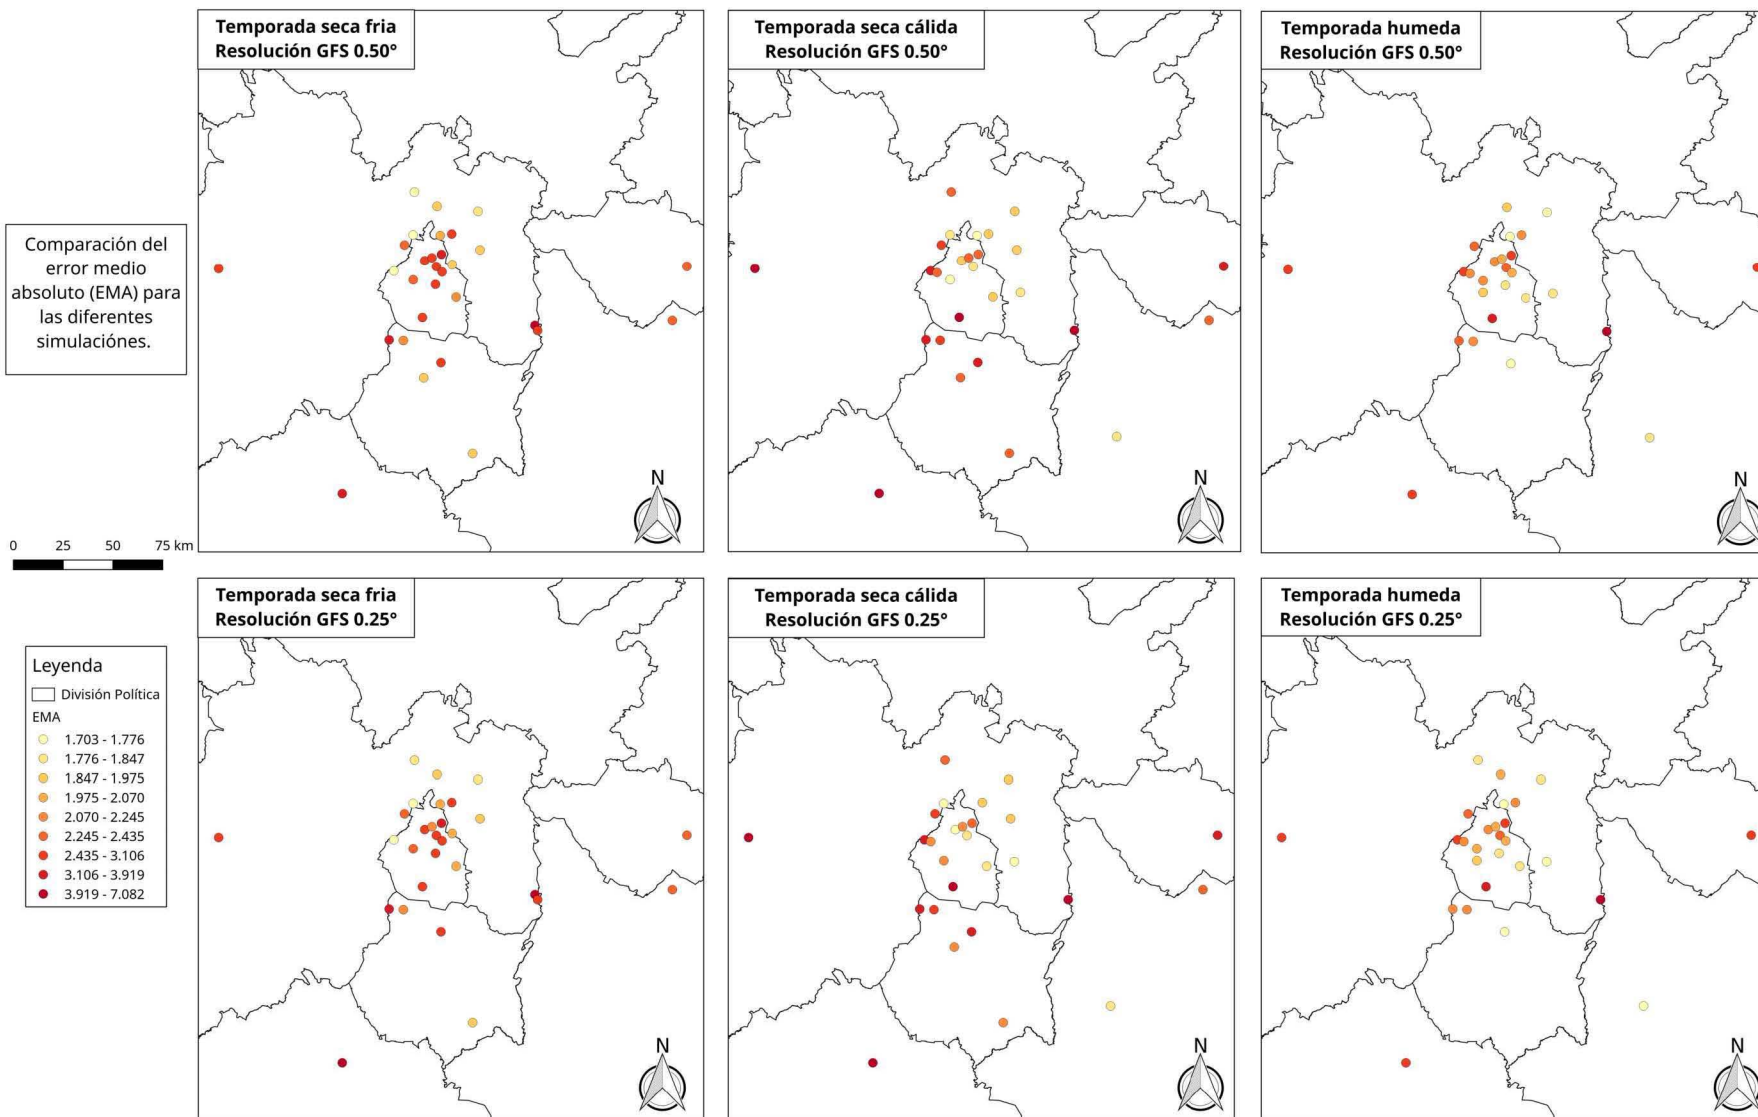


Figura 3.19: Comparación del error medio absoluto para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación.

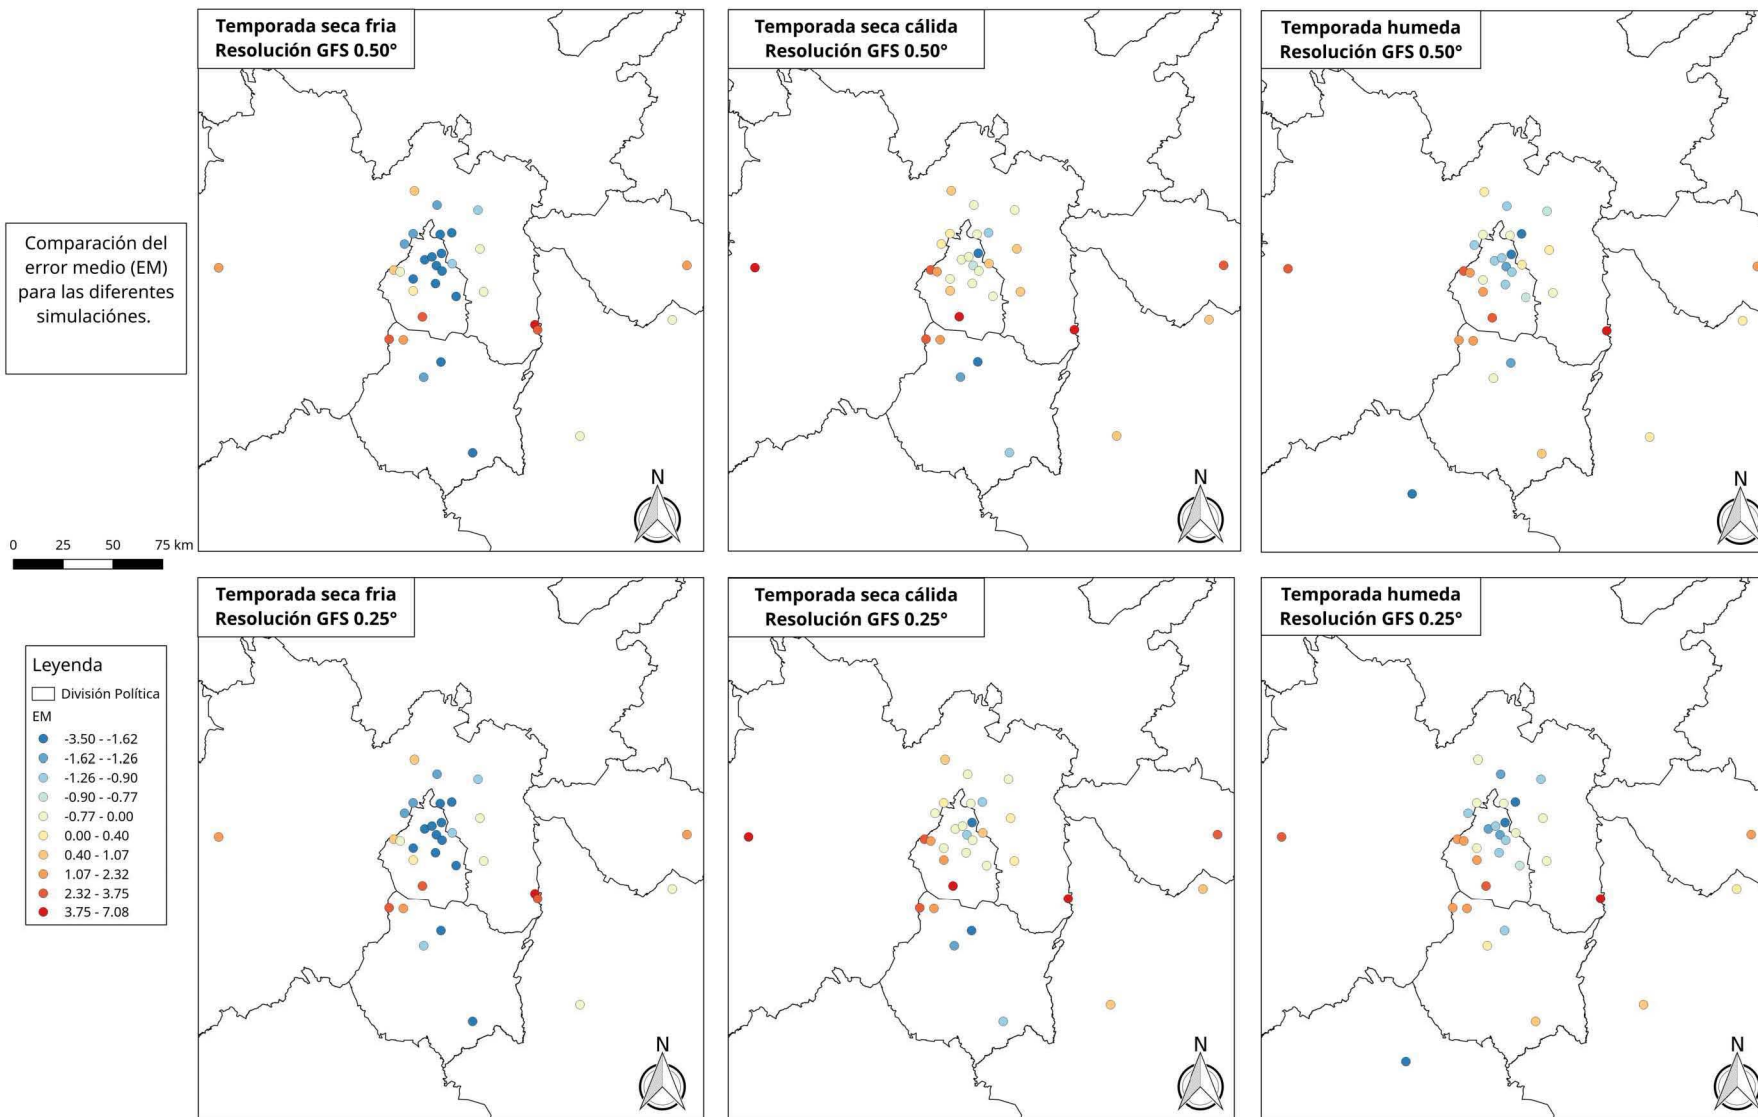


Figura 3.20: Comparación del error medio para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación.

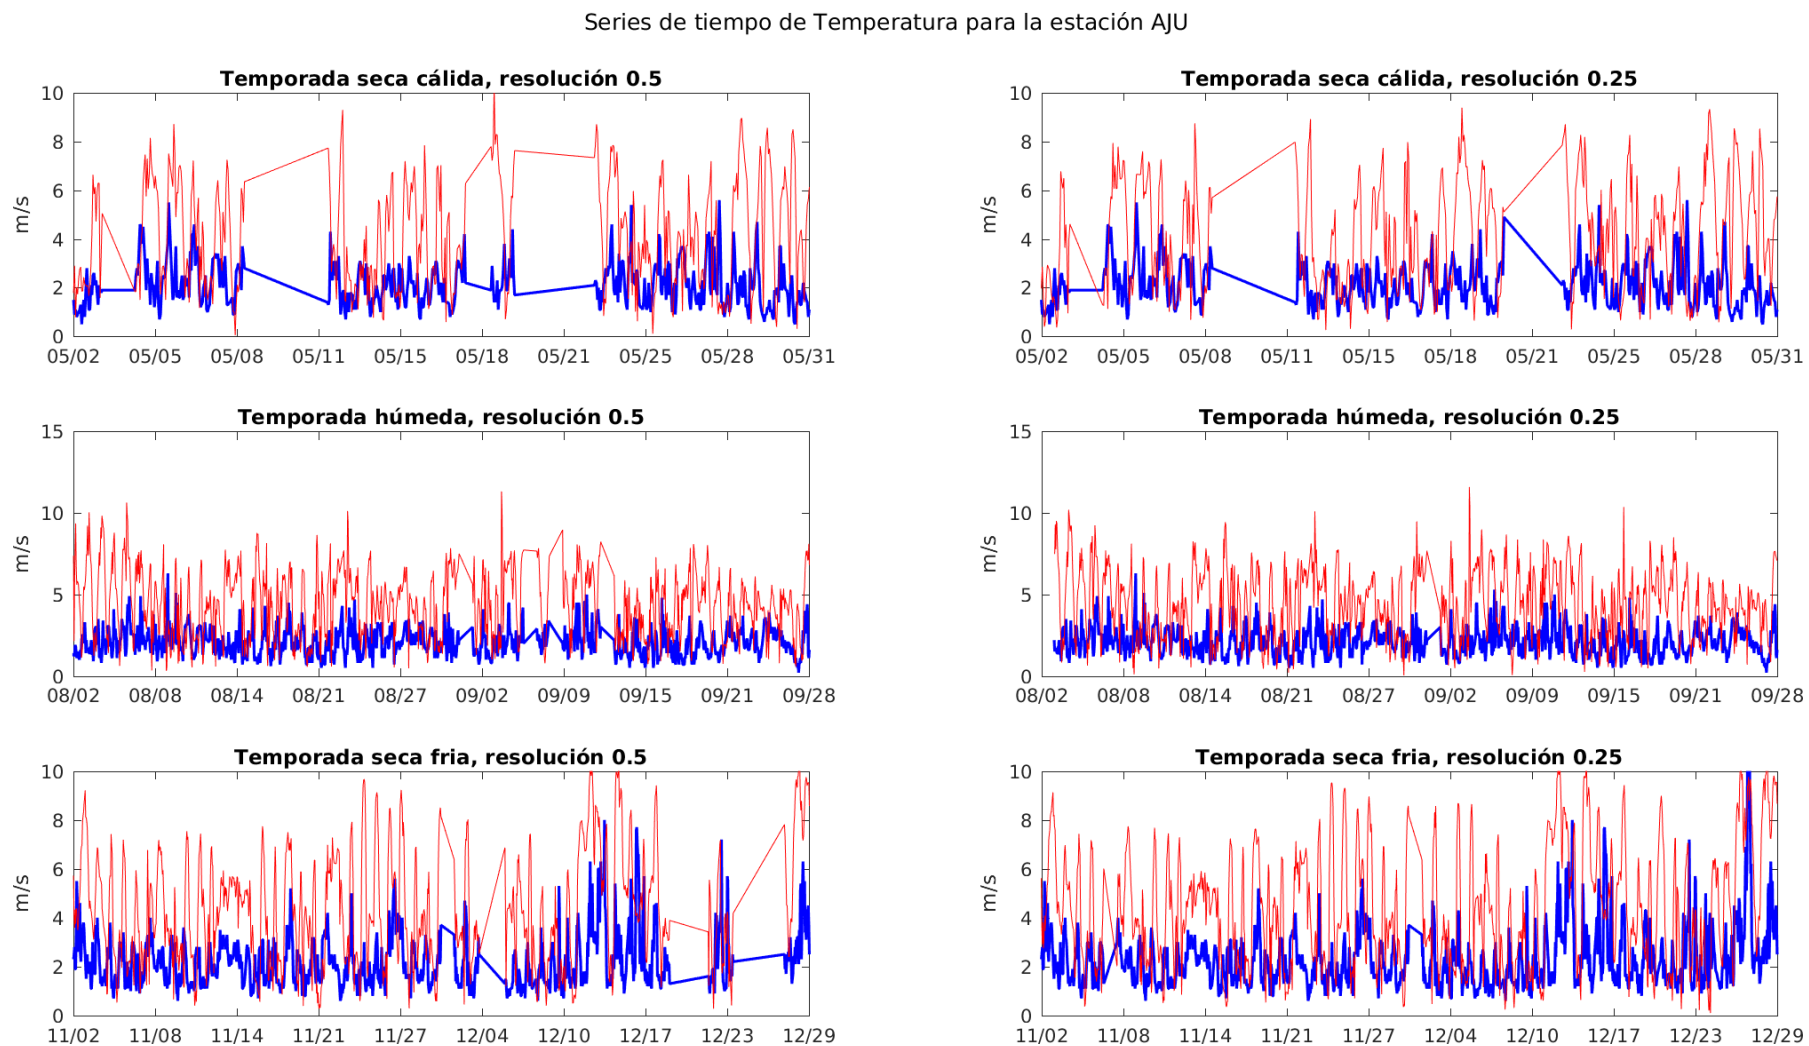


Figura 3.21: Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación Ajusco.

Series de tiempo de Temperatura para la estación UAX

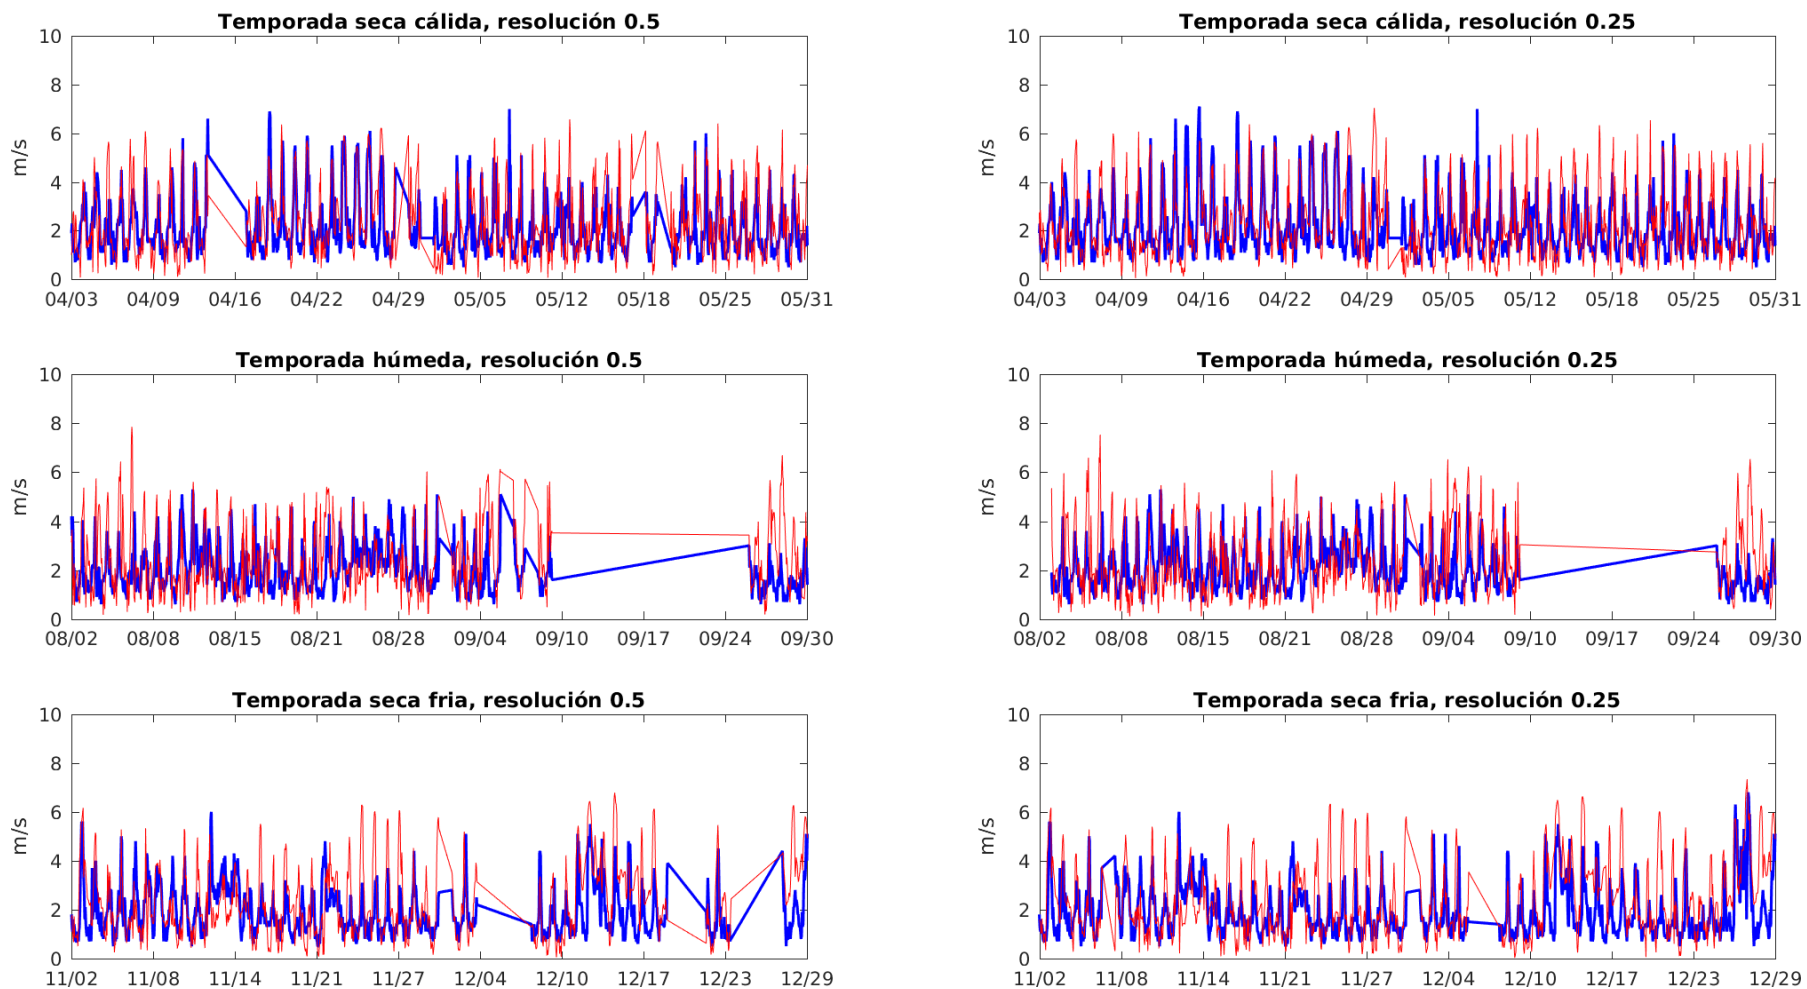


Figura 3.22: Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación UAM Xochimilco.

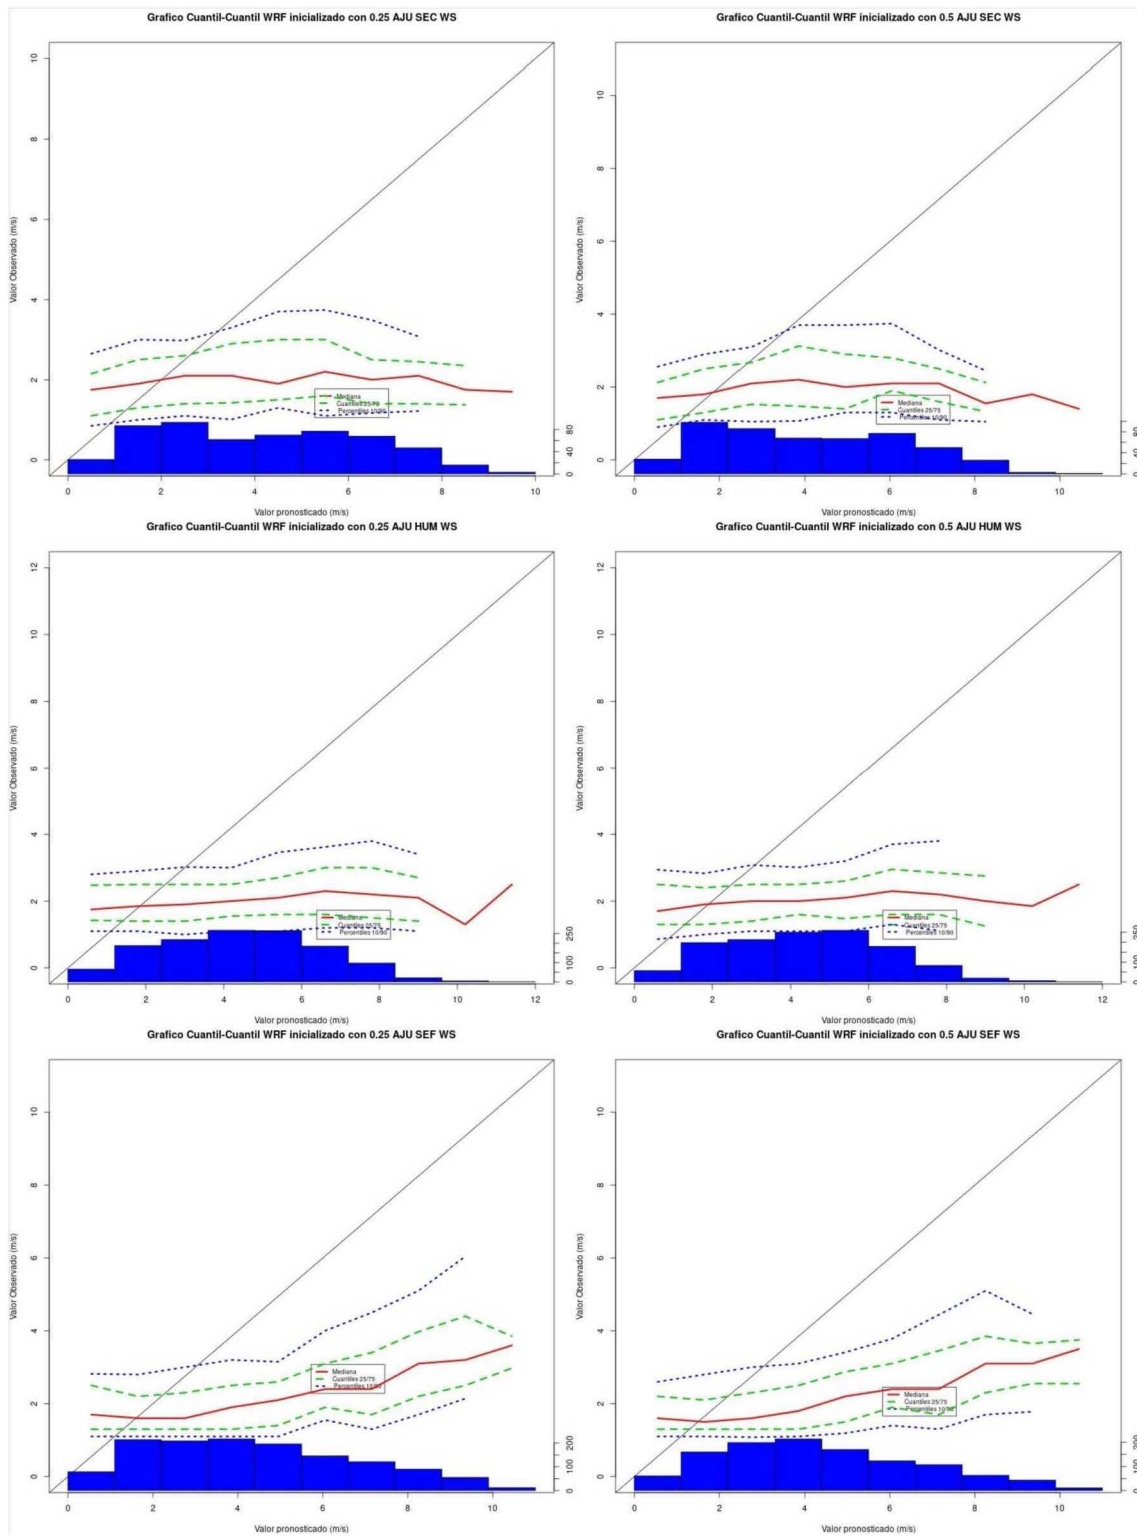


Figura 3.23: Diagrama cuantil-cuantil para la magnitud del viento en la estación Ajuusco.



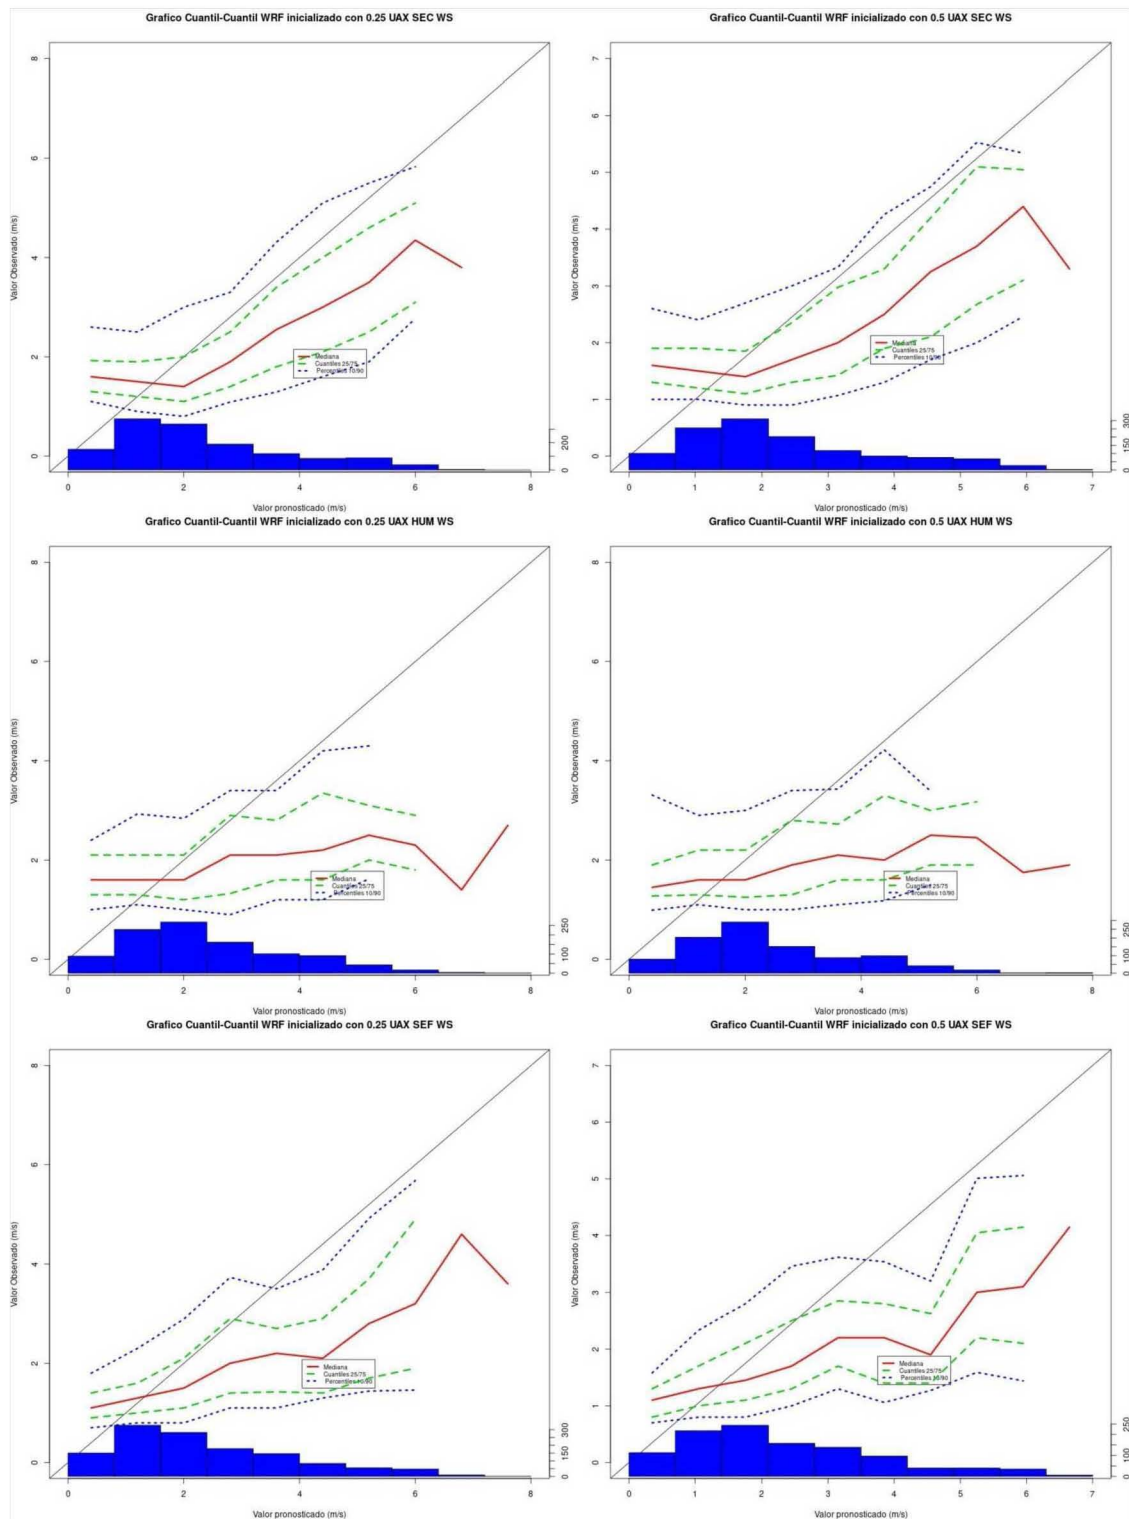


Figura 3.24: Diagrama cuantil-cuantil para la magnitud del viento en la estación de la UAM Xochimilco (UAX).

Globalmente se observa que la sensibilidad es muy baja para la temporada húmeda, relativamente alta para la temporada de secas cálidas e intermedia para la de secas frías. Para explicar esta variabilidad anual se propone explicar estos cambios en sensibilidad de acuerdo a los diferentes eventos meteorológicos que ocurren en el valle con cada temporada.

En la temporada húmeda existe una dominancia de eventos locales convectivos que dan lugar a precipitación, modificando la temperatura en el proceso. Los bajos valores de sensibilidad sugieren que la principal fuente de error para esta temporada no está asociado con las C.I. y de F., pudiendo ser que tengan una mayor relación con la parametrización de cúmulos y microfísica elegidos.

En la temporada seca fría existe un fuerte forzamiento sinóptico ocasionado por el paso de frentes fríos originados en latitudes medias. Está temporada mostró una sensibilidad mediana, algo que podemos explicar con el paso de los frentes fríos, los cuales son perturbaciones del campo de densidad horizontal que se generan fuera del dominio y se propagan a lo largo de este. La información necesaria para que un frente frío entre al dominio se encuentra en las C.F., por lo que se espera que al mejorar la resolución de las C.F., mejore la representación de los frentes fríos en el dominio, explicando el aumento en sensibilidad observado. Por otro lado, el que la sensibilidad no sea tan grande sugiere también que otros procesos, como la modelación de la isla de calor urbana, están involucrados también en la simulación, impidiendo una ganancia significativa de calidad para el modelo.

Por último la temporada seca cálida no está tan influenciada por forzamientos sinópticos o locales convectivos como las otras temporadas, y es donde la sensibilidad ante C.F. es mayor. En este caso se puede pensar que en esta temporada es donde las C.F. son más importantes para la simulación.

Otro aspecto de interés es que los puntos de montaña mostraron siempre una mayor sensibilidad al cambio de C.I. y de F. que los puntos en topografía plana. Esto puede ser explicado si pensamos en la distribución espacial esperada de la temperatura para el Valle de México. Para la parte plana no se espera un gradiente horizontal de temperaturas muy elevado, mientras que en las zonas montañosas se espera que el gradiente horizontal de temperatura sea grande. Al aumentar la resolución espacial de las C.I. y de F. puede ocurrir que no tengamos cambios muy grandes en temperatura que al usar las C.I. y de F. de menor resolución en la parte plana, aunque si existan diferencias grandes en las temperaturas de las zonas montañosas. Esto resulta en una mejor aproximación inicial en el campo de temperaturas para las zonas montañosas junto con una aproximación similar a la ya existente en las zonas planas, aumentando la sensibilidad de la zona montañosa ante C.I. y de F. de mayor resolución.

### 3.2.2. Viento

Los diagramas de bosque que representan intervalos de confianza para las diferencias de medias para la magnitud del viento se presentan en las Figuras 3.28 a 3.30. Al igual que con la temperatura, valores a la izquierda del cero representan una mejoría en la calidad del pronóstico debido al cambio de C.I. y de F. a 0.25, mientras que valores del lado izquierdo representan que la calidad del pronóstico empeoró al emplear C.I. y de F. de 0.25.

El análisis de la Figura 3.28 muestra una sensibilidad muy baja del modelo ante C.I. y de F. para la temporada húmeda. La mayor parte de los puntos se encuentran centrados alrededor del cero, con solo cuatro puntos de montaña mostrando cambios significativos (AJU, cdalta, huaman y lama02), así como dos urbanos (UAX, UIZ). No es claro si hay




Figura 3.25: Diagrama de bosque de temperatura para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.






Figura 3.26: Diagrama de bosque de temperatura para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.




Figura 3.27: Diagrama de bosque de temperatura para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.

una ganancia o pérdida global de calidad, ya que se observa la misma cantidad de puntos de ambos lados de la línea vertical (dieciocho de cada lado). Se puede apreciar que los intervalos de confianza para todos los puntos abarcan un intervalo más grande que para la temporada seca fría, indicando que la variabilidad de la diferencia del error es más grande en esta temporada.

Para la temporada seca cálida, el diagrama de la Figura 3.29 muestra una sensibilidad baja con variabilidad mayor de la diferencia de errores. Similar a la temporada húmeda, los intervalos de confianza no muestran diferencias significativas más que para dos estaciones (mona01, NEZ). En este caso los puntos de montaña parecen alinearse más a la izquierda, mientras que los puntos urbanos tienden a estar más a la derecha. Esto indica ligeras pérdidas de calidad en los puntos de montaña y ligeras ganancias de la misma para los puntos urbanos. Es notable que el rango para los intervalos de confianza crece notablemente, indicando mucha variabilidad en la diferencia de errores para estos puntos.

El diagrama de la temporada seca fría (Figura 3.30) muestra también sensibilidad muy baja ante C.I. y de F. del modelo. En este caso el rango de los intervalos es marcadamente menor que para las otras dos temporadas, indicando menor variabilidad en la diferencia de errores. Únicamente dos puntos mostraron un cambio significativo del error, siendo una de montaña (lagzem) y otro urbano (SAG). Los puntos de montaña tienden a estar centrados en el cero o ligeramente en el lado derecho, indicando mejoras muy ligeras en calidad. En cambio, los puntos urbanos y no urbanos se encuentran mayoritariamente a la izquierda, indicando una pérdida pequeña de calidad del pronóstico.

En general, se observó para todas las temporadas que el modelo exhibe una sensibilidad muy baja ante C.I. y de F. para el pronóstico de la magnitud del viento. Las tres temporadas mostraron muy pocos puntos con cambios significativos al emplear C.I. y de F. de mayor resolución, sin poder indicar si hubo ganancia o pérdida global de calidad en el modelo. La diferencia de errores mostró mayor variabilidad para la temporada seca cálida y húmeda, siendo menor en la de secas frías.

En la sección de verificación de pronóstico se mostró que para el dominio de estudio, el modelo WRF era muy inapropiado para simular adecuadamente la magnitud del viento con la configuración elegida. Estos últimos resultados nos indican que el problema no es un problema de condiciones iniciales, ya que los resultados no muestran cambios importantes al aumentar la resolución espacial de las C.I. Lo anterior sugiere que la fuente de error en la simulación está asociada con tres diferentes cuestiones: los procesos de parametrización para la magnitud del viento elegidos, la resolución utilizada para la simulación (la cual conviene recordar que cae en la zona gris de simulación para esta configuración) y la elección de uso de suelo, la cual es muy importante para el viento.




Figura 3.28: Diagrama de bosque de viento para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.




Figura 3.29: Diagrama de bosque de viento para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.




Figura 3.30: Diagrama de bosque de viento para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.

## Capítulo 4

# Conclusiones

El objetivo de este trabajo fue cuantificar la respuesta que muestra el modelo de PNT de escala regional *Weather Research & Forecasting* (WRF) (Skamarock et al., 2005) ante condiciones iniciales y de frontera de diferente resolución en la región del Valle de México. Se realizaron aproximadamente 360 simulaciones diarias para un dominio que engloba la región del Valle de México, alimentando una mitad con C.I. y de F. con resolución horizontal de 0.5 grados ( $\sim 50[km]$ ) y la otra con C.I. y de F. de resolución horizontal de 0.25 grados ( $\sim 25[km]$ ). Las simulaciones diarias se realizaron para las tres temporadas presentes en el clima del Valle de México durante 2015: seca fría, seca cálida y de lluvias. Se calcularon diferentes medidas de verificación de pronóstico para evaluar la calidad para todas las simulaciones usando las observaciones de las redes de Estaciones Automáticas (EMA) y REDMET. Se realizó una comparación cualitativa y cuantitativa de las diferencias entre las medidas al usar C.I. y de F. para estimar la sensibilidad que muestra el modelo WRF.

La verificación de pronóstico mostró que para todas las temporadas el modelo WRF era capaz de representar el ciclo diario de la temperatura, pero no era capaz de capturar adecuadamente la magnitud de la variabilidad de esta variable. La distribución espacial de errores mostró también una subestimación de la temperatura en las estaciones contenidas dentro de la mancha urbana, sugiriendo que el modelo no es capaz de representar adecuadamente procesos de superficie como la isla de calor urbana para esta región fuertemente urbanizada del Valle de México. Para la magnitud de la velocidad del viento los resultados de verificación mostraron una calidad muy baja para todas las simulaciones, ya que el modelo no fue capaz de representar adecuadamente la variabilidad o el ciclo diario de esta variable. La distribución espacial del sesgo, en donde las estaciones ubicadas en la ladera de una montaña muestran subestimación del viento, sugiere la existencia de un fenómeno de brisa de valle montaña que no está bien representado por el modelo. La verificación para precipitación mostró también una calidad deficiente para estimar adecuadamente eventos de precipitación, sobrestimando constantemente esta variable.

El análisis de sensibilidad para la temperatura mostró que globalmente ésta no era lo suficientemente grande para generar cambios significativos entre las dos resoluciones. Sin embargo, se observaron cambios relativos de sensibilidad entre las diferentes temporadas, pudiendo asociar cada una de estas con los forzamientos meteorológicos de diferentes escalas que dominan cada temporada. Cuando los procesos locales dominan se observó una baja sensibilidad ante las C.I. y C.F., mientras que cuando forzamientos sinópticos que provienen de las condiciones de frontera son dominantes, la sensibilidad aumentó. Se observó también que los puntos ubicados en montaña mostraron mayor sensibilidad que

aqueellos ubicados en terreno plano. Esta diferencia se adjudicó a la mayor capacidad que muestra el modelo GFS para resolver zonas de topografía complicada cuando aumenta su resolución espacial, mientras que en zonas con topografía plana este aumento de resolución posiblemente no generaría cambios importantes en la salida para regiones pequeñas.

Por otra parte, el análisis de sensibilidad para la magnitud de la velocidad del viento mostró que para todas las temporadas la sensibilidad fue muy baja, sin existir cambios significativos al usar las diferentes resoluciones de C.I. y de F. La verificación de pronóstico mostró también que el modelo fue muy deficiente para la simulación de esta variable, por lo que se adjudica esta baja sensibilidad a que la fuente principal de error no está asociada con la inicialización del modelo. Si la base física del modelo no es adecuada para representar los procesos atmosféricos que ocurren en el dominio, no importará entonces qué tan buena sea la calidad de las C.I. y de F que usemos para la simulación, ya que siempre obtendremos resultados erróneos. Es necesario realizar estudios de sensibilidad ante diferentes parametrizaciones de capa límite y procesos de superficie para el Valle de México para comprender mejor la fuente de error para esta variable.

La sensibilidad que mostró el modelo WRF ante condiciones iniciales y de frontera en el Valle de México fue muy baja. Derivado de lo anterior no se observó una mejoría significativa en la calidad de los pronósticos al usar condiciones iniciales y de frontera de mayor resolución espacial. La distribución temporal y espacial de los errores para las tres variables utilizadas sugieren que la principal fuente de error está relacionada con la manera de representar procesos de subescala en el dominio y con la resolución horizontal utilizada para la simulación. Más estudios sobre la sensibilidad del modelo ante estos procesos para la región del Valle de México deben ser realizados con fin de poder determinar el mejor diseño experimental para elaborar pronósticos operativos de mayor calidad en la región. Una recomendación inicial es evitar la resolución horizontal de simulación dentro de la zona gris (Gerard, 2007), proponiendo como solución el cambio de la resolución de 6,6/18 km (actuales) a 3/15 km o 3/9 km. Se recomienda también implementar un esquema operativo de verificación de pronóstico que corra a la par de la simulación operativa, de tal manera que se pueda juzgar constantemente si la calidad de los pronósticos es adecuada para la aplicación deseada. Esta estrategia podría llevar a un conocimiento más profundo de los procesos meteorológicos que ocurren en el Valle de México.





# Referencias

- Aligo, E. A., Gallus Jr, W. A., y Segal, M. (2007). Summer rainfall forecast spread in an ensemble initialized with different soil moisture analyses. *Weather and forecasting*, 22(2), 299–314.
- Blázquez, J., y Nuñez, M. N. (2009). Sensitivity to convective parameterization in the WRF regional model in southern South America. En *Ninth int. conf. on southern hemisphere meteorology and, oceanography, Melbourne, Australia* (p. 6).
- Brier, G. W., y Allen, R. A. (1951). Verification of weather forecasts. En *Compendium of meteorology* (pp. 841–848). Springer.
- Case, J. L., Crosson, W. L., Kumar, S. V., Lapenta, W. M., y Peters-Lidard, C. D. (2008). Impacts of high-resolution land surface initialization on regional sensible weather forecasts from the WRF model. *Journal of Hydrometeorology*, 9(6), 1249–1266.
- Coles, S., Heffernan, J., y Tawn, J. (1999). Dependence measures for extreme value analyses. *Extremes*, 2(4), 339–365.
- Crétat, J., Pohl, B., Richard, Y., y Drobinski, P. (2012). Uncertainties in simulating regional climate of Southern Africa: sensitivity to physical parameterizations using WRF. *Climate dynamics*, 38(3-4), 613–634.
- Cumming, G. (2013). *Understanding the new statistics: Effect sizes, confidence intervals, and meta-analysis*. Routledge.
- Daley, R. (1991). Atmospheric data analysis, Cambridge atmospheric and space science series. *Cambridge University Press*, 6966, 25.
- Danielson, J. J., y Gesch, D. B. (2011). *Global multi-resolution terrain elevation data 2010 (GMTED2010)* (Inf. Téc.). US Geological Survey.
- Domínguez Mora, R. (2000). Las inundaciones en la Ciudad de México. problemática y alternativas de solución. *Volumen 1*.
- Dudhia, J. (1989). Numerical study of convection observed during the winter monsoon experiment using a mesoscale two-dimensional model. *Journal of the Atmospheric Sciences*, 46(20), 3077–3107.
- Dudhia, J. (1996). A multi-layer soil temperature model for MM5. En *Preprints, the sixth psu/ncar mesoscale model users' workshop* (pp. 22–24).
- Etherton, B., y Santos, P. (2008). Sensitivity of WRF forecasts for South Florida to initial conditions. *Weather and forecasting*, 23(4), 725–740.

- Fast, J. D., De Foy, B., Rosas, F. A., Caetano, E., Carmichael, G., Emmons, L., ... others (2007). A meteorological overview of the MILAGRO field campaigns. *Atmospheric Chemistry and Physics Discussions*, 7(1), 2037–2089.
- Fenn, M. E., De Bauer, L., y Hernández-Tejeda, T. (2002). *Urban air pollution and forests: Resources at risk in the Mexico City air basin* (Vol. 156). Springer Science & Business Media.
- Finley, J. P. (1884). Tornado predictions. *American Meteorological Journal*, 1, 85–88.
- Flaounas, E., Bastin, S., y Janicot, S. (2011). Regional climate modelling of the 2006 West African monsoon: sensitivity to convection and planetary boundary layer parameterisation using WRF. *Climate Dynamics*, 36(5-6), 1083–1105.
- for Environmental Prediction, N. C. (2015). *Global Forecasting System implementations* (Inf. Téc.). Descargado de <http://www.emc.ncep.noaa.gov/GFS/impl.php> (Accesado el: 2016-04-12)
- Gerard, L. (2007). An integrated package for subgrid convection, clouds and precipitation compatible with meso-gamma scales. *Quarterly Journal of the Royal Meteorological Society*, 133(624), 711–730.
- Gustafsson, N., Källén, E., y Thorsteinsson, S. (1998). Sensitivity of forecast errors to initial and lateral boundary conditions. *Tellus A*, 50(2), 167–185.
- Heidke, P. (1926). Berechnung des Erfolges und der Güte der Windstärkevorhersagen im Sturmwarnungsdienst. *Geografiska Annaler*, 301–349.
- Hong, S.-Y., Dudhia, J., y Chen, S.-H. (2004). A revised approach to ice microphysical processes for the bulk parameterization of clouds and precipitation. *Monthly Weather Review*, 132(1), 103–120.
- Hong, S.-Y., Noh, Y., y Dudhia, J. (2006). A new vertical diffusion package with an explicit treatment of entrainment processes. *Monthly Weather Review*, 134(9), 2318–2341.
- Imaz, M. (1989). Historia natural del Valle de México. *Ciencias*(015).
- Jarraud, M. (2008). Guide to meteorological instruments and methods of observation (WMO-no. 8). *World Meteorological Organisation: Geneva, Switzerland*.
- Jauregui, E. (1997). Heat island development in Mexico City. *Atmospheric Environment*, 31(22), 3821–3831.
- Jazcilevich, A. D., García, A. R., y Caetano, E. (2005). Locally induced surface air confluence by complex terrain and its effects on air pollution in the Valley of Mexico. *Atmospheric Environment*, 39(30), 5481–5489.
- Jin, J., Miller, N. L., y Schlegel, N. (2010). Sensitivity study of four land surface schemes in the WRF model. *Advances in Meteorology*, 2010.
- Jolliffe, I. T., y Stephenson, D. B. (2012). *Forecast verification: a practitioner's guide in atmospheric science*. John Wiley & Sons.
- Kain, J. S. (2004). The Kain–Fritsch convective parameterization: An update. *J. Appl. Meteor.*, 43, 170-181.

- Laing, A. E. J. (2011). *Introduction to Tropical Meteorology: A comprehensive online & print textbook*. COMET program, NCAR.
- López-Espinoza, E., Zavala-Hidalgo, J., y Gómez-Ramos, O. (2012). Weather forecast sensitivity to changes in urban land covers using the WRF model for Central Mexico. *Atmósfera*, 25(2), 127–154.
- Lorenz, E. N., y Martin, P. (1995). *The essence of chaos*. AIP.
- Lynch, P. (2006). *The emergence of numerical weather prediction: Richardson's dream*. Cambridge University Press.
- Machenhauer, B. (1977). On the dynamics of gravity oscillations in a shallow water model with applications to normal mode initialization. *Beitr. Phys. Atmos*, 50, 253–271.
- Magaña, V., López, L. C., y Vázquez, G. (2013). El pronóstico de lluvias intensas para la Ciudad de México. *TIP*, 16(1), 18–25.
- Mlawer, E. J., Taubman, S. J., Brown, P. D., Iacono, M. J., y Clough, S. A. (1997). Radiative transfer for inhomogeneous atmospheres: RRTM, a validated correlated-k model for the longwave. *Journal of Geophysical Research: Atmospheres*, 102(D14), 16663–16682.
- Murphy, A. H. (1988). Skill scores based on the mean square error and their relationships to the correlation coefficient. *Monthly weather review*, 116(12), 2417–2424.
- Murphy, A. H. (1993). What is a good forecast? an essay on the nature of goodness in weather forecasting. *Weather and forecasting*, 8(2), 281–293.
- Murphy, A. H., y Winkler, R. L. (1987). A general framework for forecast verification. *Monthly Weather Review*, 115(7), 1330–1338.
- National Centers for Environmental Prediction, N. W. S. N. (2015). *Ncep gfs 0.25 degree global forecast auxiliary grids historical archive* (Inf. Téc.). Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. Descargado de <http://dx.doi.org/10.5065/D6W09402>
- Rabier, F., Klinker, E., Courtier, P., y Hollingsworth, A. (1996). Sensitivity of forecast errors to initial conditions. *Quarterly Journal of the Royal Meteorological Society*, 122(529), 121–150.
- Ruiz, J. J., Saulo, C., y Nogués-Paegle, J. (2010). WRF model sensitivity to choice of parameterization over South America: validation against surface variables. *Monthly Weather Review*, 138(8), 3342–3355.
- Servicio Meteorológico Nacional, M. (s.f.). *Verificación objetiva de modelos numéricos de la atmósfera*. (Inf. Téc.). Descargado de <http://preview.tinyurl.com/verificacionSMN> (Accessado el: 2017-01-15)
- Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Barker, D. M., Wang, W., y Powers, J. G. (2005). *A description of the advanced research WRF version 2* (Inf. Téc.). DTIC Document.
- Smirnova, T., Peckham, S., Benjamin, S., y Brown, J. M. (2009). Implementation and testing of WRF digital filter initialization (DFI) at NOAA/Earth system research laboratory. En *23rd conf. on weather analysis and forecasting/19th conf. on numerical weather prediction*.

Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, 106(D7), 7183–7192.

Warner, T. T. (2010). *Numerical weather and climate prediction*. Cambridge University Press.

Warner, T. T., Peterson, R. A., y Treadon, R. E. (1997). A tutorial on lateral boundary conditions as a basic and potentially serious limitation to regional numerical weather prediction. *Bulletin of the American Meteorological Society*, 78(11), 2599–2617.

Wilks, D. S. (2011). *Statistical methods in the atmospheric sciences* (Vol. 100). Academic press.

Willmott, C. J., Ackleson, S. G., Davis, R. E., Feddema, J. J., Klink, K. M., Legates, D. R., ... Rowe, C. M. (1985). Statistics for the evaluation and comparison of models.

Zhang, Y., Dubey, M., Olsen, S., Zheng, J., y Zhang, R. (2009). Comparisons of WRF/-Chem simulations in Mexico City with ground-based RAMA measurements during the 2006-MILAGRO. *Atmospheric Chemistry and Physics*, 9(11), 3777–3798.

# Anexos

## Anexo A

# namelist.input

```
&time_control
run_days           = 1,
run_hours          = 0,
run_minutes        = 0,
run_seconds        = 0,
start_year         = 2015, 2015,
start_month        = 04, 04,
start_day          = 27, 27,
start_hour         = 00, 00,
start_minute       = 00, 00,
start_second       = 00, 00,
end_year           = 2015, 2015,
end_month          = 04, 04,
end_day            = 29, 29,
end_hour           = 00, 00,
end_minute         = 00, 00, 00,
end_second         = 00, 00, 00,
interval_seconds   = 10800
input_from_file    = .true., .true.,
history_interval   = 60, 60,
frames_per_outfile = 1000, 1000,
restart            = .false.,
restart_interval   = 10000,
io_form_history     = 2
io_form_restart    = 2
io_form_input      = 2
io_form_boundary   = 2
debug_level        = 0
/

&domains
time_step          = 60,
time_step_fract_num = 0,
time_step_fract_den = 1,
max_dom            = 2,
```

```

e_we           = 108,   43,
e_sn           = 70,    37,
e_vert        = 30,    30,
num_metgrid_levels = 27,
num_metgrid_soil_levels = 4,
dx            = 20000, 6666.666,
dy            = 20000, 6666.666,
grid_id       = 1,     2,
parent_id     = 1,     1,
i_parent_start = 1,    48,
j_parent_start = 1,    11,
parent_grid_ratio = 1,   3,
parent_time_step_ratio = 1, 3,
feedback      = 0,
smooth_option = 2
/

&physics
mp_physics    = 3,     3,
ra_lw_physics = 1,     1,
ra_sw_physics = 1,     1,
radt          = 30,    30,
sf_sfclay_physics = 1,  1,
sf_surface_physics = 1,  1,
bl_pbl_physics = 1,    1,
bldt         = 0,     0,
cu_physics    = 1,     1,
cudt         = 5,     5,
isfflx       = 1,
ifsnow       = 0,
icloud       = 1,
surface_input_source = 1,
num_soil_layers = 5,
sf_urban_physics = 0,
mp_zero_out  = 0,
maxiens      = 1,
maxens       = 3,
maxens2      = 3,
maxens3      = 16,
ensdim       = 144,
slope_rad    = 0,
topo_shading = 0,
/

&dynamics
w_damping    = 0,
diff_opt     = 1,
km_opt       = 4,
diff_6th_opt = 0,

```

```

diff_6th_factor      = 0.12 ,
base_temp            = 290.
damp_opt             = 0,
zdamp                = 5000., 5000.,
dampcoef             = 0.01, 0.01,
khdif                = 0, 0,
kvdif                = 0, 0,
non_hydrostatic     = .true., .true.,
moist_adv_opt        = .true., .true.,
scalar_adv_opt       = .true., .true.,
/

&bdy_control
spec_bdy_width      = 5,
spec_zone           = 1,
relax_zone          = 4,
specified           = .true., .false.,
nested              = .false., .true.,
/

&namelist_quilt
nio_tasks_per_group = 0,
nio_groups = 1,
/

```





Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

## Agradecimientos

Agradezco a la UNAM por todo el apoyo y oportunidades que me han brindado a lo largo de toda mi carrera académica. Agradezco también a la Facultad de Ciencias y a todos mis profesores por toda la ayuda, preparación y orientación que me brindaron durante la licenciatura. Gracias al Centro de Ciencias de la Atmósfera por toda la preparación y experiencia que me ha brindado estos últimos años. Agradezco también al Laboratorio de Fluidos Geofísicos del CCA, por toda la práctica y experiencia que me brindó en mis proyectos de la maestría. Gracias al CONACyT por todo el apoyo que me brindaron para la realización de mis estudios de posgrado.

Gracias a mi asesor, el Dr. Angel Ruiz Angulo por su guía, consejos, regaños y amistad durante la elaboración de esta tesis. Agradezco también al Dr. Arturo Quintanar y al Dr. Benjamín Martínez por todo su apoyo desde la licenciatura. Agradezco también al Dr. Arón Jazcilevich por su ayuda en mi comité tutorial del posgrado. Muchas gracias a la Dra. Claudia Inés Rivera Cárdenas, al Dr. Harry Alvarez Ospina y al Taller de Meteorología de la Facultad de Ciencias por su invaluable apoyo para llevar a cabo el proyecto del club de meteorología de la Facultad de Ciencias, nimbus, el cual fue un gran contribuyente a muchas de las ideas desarrolladas en este trabajo. Gracias también a la Dra. Erika Danaé López y el Dr. Cuauhtémoc Turrent Thompson por su participación como mis sinodales, cuyas valiosas contribuciones e ideas hicieron posible el completar este trabajo de tesis.

Muchas gracias también a todas aquellas personas que me brindaron su amistad, consejos y ayuda en estos interesantes años de maestría. HM, tu sabes que este logro no hubiera sido posible sin ti. A mis compañeros de laboratorio, quienes hicieron que estar en el CCA siempre fuera toda una aventura: Andrea, Víctor, Abril y Josue. A mis amigos de CT, por toda su ayuda y consejos: Diego, Xanath, Lupita, Jardín, Citlali, Javier, Luis, Andrea, Edgar, Raiza, Bernardo y todos los demás. Gracias a Biotita y Adularia por no comerse mis papeles de titulación.

Agradezco también a mis padres, Alma y Beto, así como a mis abuelos, Rosita, Ricardo, María y Humberto, por todo su apoyo y dedicación, los cuales me permitieron llegar hasta donde estoy. ¡Este logro es suyo!

# Resumen

El propósito de este trabajo es cuantificar la respuesta que muestra el modelo de Pronóstico Numérico del Tiempo (PNT) de escala regional más utilizado en el Valle de México: Weather Research & Forecasting (WRF) ante condiciones iniciales y de frontera de diferente resolución espacial. La finalidad de esto es determinar como se ve afectada la calidad de la salida del pronóstico numérico al cambiar las condiciones iniciales. Dos resoluciones diferentes del modelo de PNT global Global Forecasting System (GFS) son utilizadas como condiciones iniciales y de frontera para inicializar el modelo WRF. Las salidas del modelo WRF son comparadas con las observaciones existentes dentro del dominio mediante un esquema de verificación de pronóstico para determinar la diferencia en calidad entre estas, permitiendo entonces estimar cuantitativamente la sensibilidad del modelo WRF para la región de estudio.

El esquema de verificación aplicado a los pares observación-pronóstico utilizó 5 medidas para datos discretos (probabilidad de precipitación y temperatura): proporción correcta, puntaje de amenaza, sesgo, probabilidad de detección, probabilidad de falsa detección, razón de falsa alarma y del puntaje de habilidad de Heidke. Para los datos continuos (temperatura y magnitud de la velocidad del viento) se evaluaron: el error cuadrático medio, el error medio absoluto y el error medio. También se estudiaron dos métodos gráficos: diagramas de Taylor y gráficos cuantil-cuantil. Los resultados fueron representados gráficamente en un mapa para observar la distribución espacial de los errores y comparar entre las salidas iniciadas con ambas resoluciones, observando un error generalizado del modelo en ambas resoluciones para pronosticar adecuadamente las tres variables utilizadas, sobre todo en la temporada de lluvias.

Posteriormente se realizó una prueba de diferencia de medias para determinar si existía una diferencia significativa entre los errores resultantes de las simulaciones con ambas resoluciones, usando un método no paramétrico de re-muestreo con bootstrap para determinar intervalos de confianza de la media de las diferencias. Los resultados mostraron que en la región mas plana de la ZMVM no hubo una diferencia significativa entre los errores; mientras que en las regiones con topografía más marcada, i.e. las montañas que rodean al Valle. La mayor parte de las estaciones mostraron una diferencia significativa entre los errores. Esta diferencia se adjudica a la mayor capacidad que muestra el modelo GFS para resolver zonas de topografía complicada cuando aumenta su resolución espacial, mientras que en zonas con topografía plana este aumento de resolución posiblemente no generaría cambios importantes en la salida para regiones pequeñas.

Se concluye que el modelo muestra una sensibilidad baja ante condiciones iniciales y de frontera para el dominio utilizado. Esto conlleva a que mejorar la resolución espacial de las condiciones iniciales y de frontera no mejora el pronóstico al ser comparados con las observaciones. El uso de condiciones iniciales de mayor resolución no mostró una mejoría en la comparación estudiada en esta tesis. En base a estudios previos, se asocia la mayor

fuerza de error a que la máxima resolución simulada pertenece a la denominada “zona gris” de modelación de procesos convectivos y de microfísica. Se propone como solución el cambio de la resolución de 6,6/18km (actuales) a 5/15km o 3/9km. Otra posibilidad es el cambio en el uso de las parametrizaciones, cambiando de un esquema mixto de microfísica y cúmulos a únicamente el uso de uno de estos, dependiendo de la resolución. Finalmente, se sugiere que la implementación operacional de verificación para los pronósticos numéricos en el Valle de México sea llevada a cabo lo antes posible para tener una mejor idea de como mejorar los pronósticos basados en estos modelos.

# Índice general

<b>Índice de figuras</b>	<b>7</b>
<b>1. Introducción</b>	<b>11</b>
1.1. Antecedentes . . . . .	11
1.1.1. La Cuenca de México . . . . .	12
1.1.2. Pronóstico numérico en la Cuenca de México . . . . .	13
1.1.3. Estudios de sensibilidad para el modelo WRF . . . . .	13
1.2. Marco Teórico . . . . .	14
1.2.1. Pronósticos Numéricos del Tiempo . . . . .	14
1.2.2. Predecibilidad de la atmósfera . . . . .	15
1.2.3. Inicialización de los modelos numéricos . . . . .	16
1.2.4. Verificación de pronóstico . . . . .	18
<b>2. Método</b>	<b>29</b>
2.1. Diseño del experimento numérico . . . . .	29
2.2. Base de datos observación-pronóstico . . . . .	30
2.2.1. Observaciones de superficie . . . . .	30
2.2.2. Pares de datos observación-pronóstico . . . . .	32
2.3. Verificación de pronóstico . . . . .	35
2.3.1. Datos continuos . . . . .	35
2.3.2. Datos discretos . . . . .	35
2.4. Análisis de sensibilidad . . . . .	36
2.4.1. Estimación de intervalos de confianza. . . . .	36
2.4.2. Diagramas de bosque . . . . .	37
<b>3. Resultados y Discusión</b>	<b>41</b>
3.1. Verificación de pronóstico . . . . .	41
3.1.1. Precipitación . . . . .	41
3.1.2. Temperatura . . . . .	45
3.1.3. Magnitud de la velocidad del viento . . . . .	47
3.2. Sensibilidad ante condiciones iniciales y de frontera . . . . .	57

ÍNDICE GENERAL	6
3.2.1. Temperatura . . . . .	57
3.2.2. Viento . . . . .	67
<b>4. Conclusiones</b>	<b>75</b>
<b>Referencias</b>	<b>77</b>
<b>Anexos</b>	<b>81</b>
<b>A. namelist.input</b>	<b>83</b>

# Índice de figuras

1.1.	Mapa representativo de la región de estudio. . . . .	12
1.2.	Izquierda: Simulación temperatura GFS con 0.50 grados de resolución horizontal. Derecha: Simulación temperatura GFS con resolución horizontal de 0.25 grados. . . . .	19
1.3.	Ejemplo de una tabla de contingencia de 2x2. . . . .	24
2.1.	Dominio de la simulación mostrando el dominio principal de 20 km y el dominio anidado de 6.6 km. . . . .	31
2.2.	Mapa de estaciones analizadas en el Valle de México y alrededores. . . . .	31
2.3.	Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA iguala para el mes de Noviembre 2015. . . . .	33
2.4.	Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA imteag para el mes de Noviembre 2015. . . . .	33
2.5.	Mapa de estaciones y puntos de malla más cercanos. . . . .	34
2.6.	Distribución de las estaciones en la Cuenca de México y en la Cuenca del río Balsas. . . . .	38
2.7.	Histograma de la distribución empírica resultante al usar el método de remuestreo de <i>bootstrap</i> para la media $t^*$ de las diferencias del EMA para la estación CUA en la temporada húmeda. . . . .	39
3.1.	Mapas de Proporción Correcta (PC) para la temporada húmeda. . . . .	43
3.2.	Mapas de Puntaje de Amenaza (PA) para la temporada húmeda. . . . .	43
3.3.	Mapas de Razón de Falsa Alarma (RFA) para la temporada húmeda. . . . .	44
3.4.	Mapas de Sesgo para la temporada húmeda. . . . .	44
3.5.	Diagrama de Taylor para la variable temperatura, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	47
3.6.	Diagrama de Taylor para la variable temperatura, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	48



3.7. Diagrama de Taylor para la variable temperatura, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	48
3.8. Comparación del error cuadrático medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	49
3.9. Comparación del error medio absoluto para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	50
3.10. Comparación del error medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	51
3.11. Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Acolman. . . . .	52
3.12. Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Escuela Nacional de Ciencias Biológicas 2. . . . .	53
3.13. Diagrama cuantil-cuantil para la temperatura en la estación Acolman. . . . .	54
3.14. Diagrama cuantil-cuantil para la temperatura en la estación Encb02. . . . .	55
3.15. Diagrama de Taylor para la variable magnitud del viento, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	58
3.16. Diagrama de Taylor para la variable magnitud del viento, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	58
3.17. Diagrama de Taylor para la variable magnitud del viento, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal). . . . .	59
3.18. Comparación del error cuadrático medio para la variable magnitud del viento a lo largo de las temporadas analizadas para el dominio de simulación. . . . .	60
3.19. Comparación del error medio absoluto para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación. . . . .	61
3.20. Comparación del error medio para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación. . . . .	62
3.21. Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación Ajusco. . . . .	63
3.22. Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación UAM Xochimilco. . . . .	64
3.23. Diagrama cuantil-cuantil para la magnitud del viento en la estación Ajusco. . . . .	65
3.24. Diagrama cuantil-cuantil para la magnitud del viento en la estación de la UAM Xochimilco (UAX). . . . .	66
3.25. Diagrama de bosque de temperatura para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	68

3.26. Diagrama de bosque de temperatura para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	69
3.27. Diagrama de bosque de temperatura para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	70
3.28. Diagrama de bosque de viento para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	72
3.29. Diagrama de bosque de viento para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	73
3.30. Diagrama de bosque de viento para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana. . . . .	74



# Capítulo 1

## Introducción

Los modelos de predicción numérica del tiempo (PNT) son una de las herramientas más utilizadas por meteorólogos para emitir pronósticos del tiempo (Warner, 2010). Esto es una consecuencia directa de los grandes avances en la computación y el almacenamiento digital: el avance en poder de cómputo puro hizo que el pronóstico operacional con base en modelos numéricos fuera viable. Los modelos de PNT son de gran importancia en regiones tropicales en donde el uso de otras fuentes de información puede no estar disponible, no ser confiable o ser muy pobre para dar una interpretación completa de la atmósfera (Laing, 2011). Un ejemplo se da en la región del Valle de México, en donde el pronóstico del tiempo diario es auxiliado por salidas de modelos de PNT de escala regional. Dichos modelos regionales son inicializados usando salidas de modelos de PNT de escala global. Cabe destacar que aunque se ha observado que los modelos regionales son muy sensibles ante las condiciones iniciales y de frontera usados para inicializarlos, no existen estudios para cuantificar dicha sensibilidad para el Valle de México.

El propósito de este trabajo es cuantificar la respuesta que muestra el modelo de predicción numérica del tiempo (PNT) de escala regional más utilizado en el Valle de México, *Weather Research & Forecasting* (WRF) (Skamarock et al., 2005), ante un cambio en la resolución espacial de condiciones iniciales y de frontera. Este estudio tiene como finalidad determinar como se ve afectada la calidad de la salida del pronóstico numérico al cambiar estos parámetros. Dos resoluciones diferentes del modelo de PNT global *Global Forecasting System* (GFS) son usadas como condiciones iniciales y de frontera para inicializar el modelo WRF. Las salidas del modelo WRF fueron comparadas contra observaciones en la región mediante un esquema de verificación de pronóstico para determinar la diferencia en calidad entre éstas al inicializar con una resolución o con otra. De esta manera se estimó cuantitativamente la sensibilidad del modelo WRF para la región de estudio.

### 1.1. Antecedentes

Para el presente estudio se eligió la región que comprende al Valle de México. El Valle de México es una subcuenca endorreica dentro de la Cuenca de México, siendo uno de los cuatro valles principales de la cuenca. Este valle es de interés ya que comprende casi en su totalidad a la Zona Metropolitana del Valle de México (ZMVM), que a su vez está conformada por la Ciudad de México y municipios aledaños. La mancha urbana de la ZMVM se puede apreciar en la Figura 1.1.

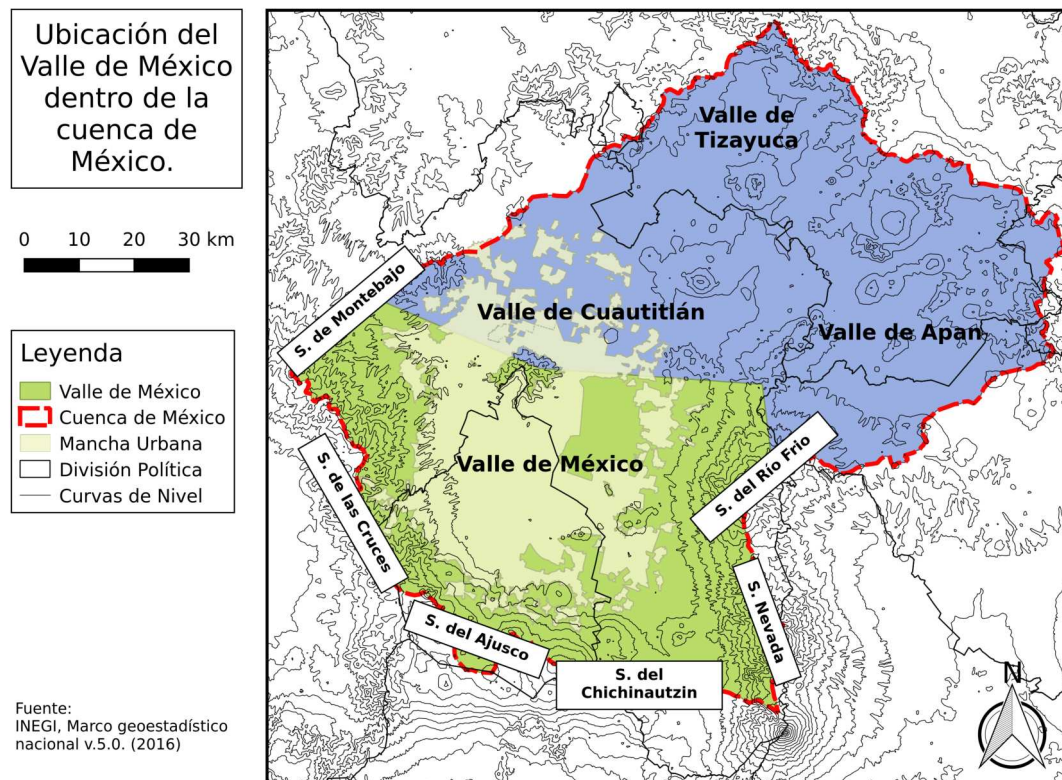


Figura 1.1: Mapa representativo de la región de estudio.

### 1.1.1. La Cuenca de México

La Cuenca de México es una cuenca endorreica con diferentes salidas hidrológicas artificiales (Imaz, 1989). A lo largo de su historia, diferentes modificaciones antropogénicas han modificado la distribución espacial de ríos a favor de un sistema de drenaje que transporta el agua afuera del valle.

Geográficamente, la Cuenca del Valle de México se puede pensar como una “unidad atmosférica”. Esto es debido a que es una región semiplana situada a una altura de 2240 m s.n.m. en promedio rodeada casi por completo por una cadena montañosa integrada por las formaciones de la Sierra de Monte Bajo, Sierra de las Cruces, Sierra del Ajusco, Sierra del Chichinautzin, Sierra Nevada y la Sierra de Río Frío, como se observa en la Figura 1.1.

La climatología de la Cuenca de México está comprendida por 4 subtipos de clima principales: seco, templado húmedo, subhúmedo y templado, lo cual es resultado de las diferencias de elevación y relieve del terreno (Fenn et al., 2002).

De acuerdo con Fenn et al. (2002) y Fast et al. (2007), el clima de la cuenca está determinado por dos flujos regionales de gran escala que se alternan durante el año. El primero está formado por los vientos del oeste (usualmente secos) que llegan a la región durante el invierno y primavera. El segundo está constituido por la corriente de vientos alisios que trae humedad a la región de mayo a octubre. Esta dinámica permite distinguir tres estaciones en la Cuenca de México:

- La estación seca cálida, de marzo a mayo;
- La estación seca fría, de noviembre a febrero; y

- La estación húmeda (o de lluvias), que se presenta desde mediados de mayo y se vuelve más evidente entre junio y octubre.

### 1.1.2. Pronóstico numérico en la Cuenca de México

Las condiciones histórico-geográficas de la ZMVM han resultado en una fuerte vulnerabilidad de la ciudad ante eventos hidrometeorológicos, en particular inundaciones (Domínguez Mora, 2000). Lo anterior es la razón por la cual el pronóstico del tiempo tiene un papel crucial en el desarrollo de muchas actividades sociales y económicas de la región. Debido a esto, la calidad que ofrecen los sistemas de pronóstico operativos en la región han sido cuestión de gran interés para la comunidad meteorológica.

Actualmente, diversos organismos gubernamentales y privados hacen uso del modelo WRF como herramienta principal de pronóstico. Un ejemplo de lo anterior es el pronóstico numérico diario emitido por el Servicio Meteorológico Nacional (SMN) mexicano, el Sistema de Monitoreo Atmosférico de la Ciudad de México (SEDEMA), el Centro de Ciencias de la Atmósfera de la UNAM, el Instituto Mexicano de Tecnología del Agua (IMTA), etc. Sin embargo, pocos estudios se han realizado en la región sobre la calidad que ofrecen dichos pronósticos numéricos. (Magaña et al., 2013) realizaron una evaluación de la calidad del pronóstico de precipitación obtenido con el modelo MM5 (antecesor del modelo WRF) llegando a la conclusión de que era poco adecuado para estimar tanto la intensidad como la región de la precipitación. Zhang et al. (2009) realizaron una verificación del modelo WRF-chem para las variables meteorológicas medidas durante la campaña MILAGRO, encontrando que era capaz de resolver relativamente bien la variabilidad temporal de temperatura, humedad relativa y magnitud del viento, presentando un fuerte sesgo en la temperatura durante el día y un error grande en la dirección del viento. El SMN recientemente comenzó un programa de verificación numérico para la precipitación, haciendo uso de varias de las técnicas utilizadas en este trabajo (Servicio Meteorológico Nacional, s.f.).

### 1.1.3. Estudios de sensibilidad para el modelo WRF

Diversos estudios han determinado la sensibilidad del modelo WRF ante varios factores en diferentes regiones. Aligo et al. (2007) estudiaron la sensibilidad del modelo al cambiar las condiciones iniciales de humedad del suelo, haciendo uso de diferentes medidas de verificación para cuantificar los cambios entre simulaciones. Aligo et al. (2007) encontraron una sensibilidad elevada ante cambios de humedad del suelo en regiones con sistemas convectivos, pero no encontraron que el cambio fuera tan amplio para modificar la precipitación significativamente en todo el dominio analizado. Etherton y Santos (2008) realizaron un estudio de sensibilidad del modelo ante un cambio de resolución espacial de condiciones iniciales para evaluar campos de precipitación en Florida del Sur, encontrando una mejoría importante en los pronósticos para las primeras horas al usar una resolución espacial mas pequeña. Para este estudio se realizó una comparación de diversas medidas de verificación de pronóstico como el puntaje de amenaza y el error cuadrático medio al cambiar las condiciones iniciales (C.I.) para cada simulación. Case et al. (2008) estudiaron la sensibilidad en la misma región, pero en este caso cambiando el tipo de modelo de humedad y de suelo entre simulaciones. Para evaluar la sensibilidad, los autores usaron diferencias entre error cuadrático medio y sesgo de las simulaciones, observando una sensibilidad fuerte del modelo ante el cambio de tipos de suelo. Jin et al. (2010) realizaron un estudio de sensibilidad del modelo ante diferentes parametrizaciones de superficie para la

región oeste de Estados Unidos. Estos autores hicieron uso de 4 esquemas de superficie diferentes, comparando los resultados con diagramas de Taylor para determinar qué tan sensible era el modelo ante estos cambios. Ruiz et al. (2010) estudiaron la sensibilidad del modelo ante diferentes parametrizaciones convectivas, de capa límite y de suelo usando cambios en error cuadrático medio y en sesgo comparando con las observaciones. Estos autores hacen hincapié en que las mejoras en la calidad de los pronósticos dependerán siempre de identificar adecuadamente qué errores en el diseño de la simulación conllevan a la propagación de los mismos. Globalmente todos estos estudios hicieron uso de alguna medida de verificación para estimar la sensibilidad del modelo, encontrando diferentes conclusiones de acuerdo al diseño y el objetivo de cada experimento. Otros estudios han hecho uso de ensambles y el método adjunto como lo hicieron Blázquez y Nuñez (2009) para el estudio de la sensibilidad del modelo ante el cambio de parametrizaciones de convección, encontrando una sensibilidad moderada en un dominio sur de Sudamérica.

La sensibilidad del modelo WRF para regiones tropicales es un tema menos estudiado que para las latitudes medias. (Flaounas et al., 2011) realizaron un estudio de sensibilidad ante diferentes esquemas de convección y capa límite para la región tropical de África afectada por el monzoon de África del este. En este estudio se usaron diferentes parametrizaciones de convección y capa límite para determinar qué salida se aproximaba más a las observaciones. Se observó una fuerte sensibilidad del modelo para simular escalas de alrededor de 50 km, especialmente en temporada de monzoon. Como conclusión del estudio, los autores recomiendan diseñar el experimento numérico de acuerdo a las propiedades de la región y los fenómenos a modelar, ya que cada uno requiere de una representación física diferente. De manera similar a este estudio, (Crétat et al., 2012) realizaron un estudio de sensibilidad ante parametrizaciones de cumulos, microfísica y capa límite en la región de África del Sur. En este caso el sesgo con respecto de las observaciones se usó para determinar la sensibilidad, empleando mapas para evaluar los cambios. Se observó una sensibilidad importante del modelo a la elección de esquemas de microfísica y convección, sin llegar a una conclusión definitiva de cuál es el mejor esquema para el pronóstico de precipitación.

En relación al Valle de México, López-Espinoza et al. (2012) realizaron un estudio de sensibilidad ante cambios de uso de suelo en las condiciones iniciales, observando una mejoría en la temperatura pronosticada al usar una base de datos de suelo más actualizada. Hasta el momento de elaboración de este trabajo, ningún estudio de sensibilidad ante diferentes resoluciones de las condiciones iniciales y de frontera para el Valle de México fue encontrado.

## 1.2. Marco Teórico

### 1.2.1. Pronósticos Numéricos del Tiempo

El pronóstico del tiempo es una de las piezas de información más utilizadas por la población en general, sirven para responder preguntas básicas como la vestimenta que conviene usar durante el día o para responder preguntas más complejas como el lugar más óptimo para colocar una planta de energía eólica. Es por esto que la *calidad* del pronóstico (que se puede pensar como la aproximación de lo pronosticado con lo observado) es un aspecto de gran interés para muchos científicos. Aunque se han logrado grandes avances desde el siglo XIX con Bjerkness y la fundación de la escuela de meteorología sinóptica, se podría argumentar que un gran avance se ha logrado gracias a la llegada de la llamada



*Predicción Numérica del Tiempo* (PNT o *NWP*, por sus siglas en inglés) (Warner, 2010; Lynch, 2006).

La PNT parte de que la atmósfera es un sistema físico bien conocido, en donde se conocen las ecuaciones que rigen tanto el movimiento como la conservación de masa y energía. Si resolvemos este sistema de ecuaciones utilizando como condiciones iniciales y de frontera observaciones provenientes de estaciones meteorológicas en superficie, radiosondeos, datos de satélite y radar, será posible conocer la evolución de la atmósfera. En teoría, esta idea podría funcionar idealmente si conociéramos el estado inicial de la atmósfera *en cada punto*, así como una solución a las ecuaciones primitivas que la describen. Ambas condiciones tienen limitaciones físicas importantes. En primera, conocer por completo las condiciones iniciales implicaría tener estaciones de medición en cada punto de la Tierra. En segunda las ecuaciones primitivas son ecuaciones diferenciales parciales no lineales de segundo orden, lo que hace que encontrar una solución analítica sea muy difícilmente alcanzable. Ante estas dificultades, una estrategia surgió para obtener soluciones por medio de métodos numéricos para integrar en el tiempo las ecuaciones primitivas (Lynch, 2006), (Warner, 2010). Dicha estrategia requiere realizar una discretización de las ecuaciones y del dominio que se desea simular, un problema que no es trivial.

El uso de esta estrategia para la PNT requiere de una cantidad gigantesca de operaciones en un periodo corto de tiempo. Aunque en la época de Richardson (pionero en el uso de estos modelos) esto era casi imposible, hoy en día el gran desarrollo que ha tenido el hardware de las computadoras permite la implementación de los modelos de PNT para ayudar a los meteorólogos a generar pronósticos del tiempo diarios y cada vez con mayor calidad. Es importante notar que esta mejoría proviene de dos aspectos: la gran rapidez con la que se pueden realizar las operaciones requeridas por los métodos numéricos para resolver las ecuaciones primitivas (poder crudo); así como la rápida integración de la información proveniente de todos los sensores meteorológicos que existen (estaciones, radiosondas, satélites, radares, etc) en un producto que pueda ser utilizado para alimentar los métodos numéricos (observaciones).

El uso de la PNT como auxiliar para realizar pronósticos del tiempo es especialmente marcado en regiones donde la red de observaciones meteorológicas es insuficiente, poco confiable o inexistente. Un ejemplo de esta región está en la región tropical, la cual presenta una escasez de estaciones de medición atmosférica (Laing, 2011). Debido a esto es común que los meteorólogos en la región dependan de salidas de modelos de PNT como su principal fuente de información. Como se mencionó anteriormente, la ZMVM es un ejemplo de una región tropical en donde el PNT es usado de manera habitual para emitir pronósticos.

### 1.2.2. Predecibilidad de la atmósfera

Los modelos de predicción numérica del tiempo tienen un tiempo finito de validez (Lynch, 2006). Esta característica fue ampliamente estudiada por Lorenz, quien realizó diversos estudios sobre la estabilidad de sistemas dinámicos resumiendo sus resultados en su libro *The Essence of Chaos* (Lorenz y Martin, 1995). Lorenz postuló el teorema fundamental de la predecibilidad: los sistemas inestables tienen un límite finito de predecibilidad, mientras que los sistemas estables son infinitamente predecibles, ya sea por soluciones estacionarias o periódicas. Adicionalmente, Lorenz argumenta que la atmósfera es un sistema inestable, dando origen a la idea de que "el aleteo de las alas de una mariposa en Brasil podría afectar la aparición de un tornado en Texas", el comportamiento de la

atmósfera es inestable ante pequeñas perturbaciones en la misma.

El descubrimiento de Lorenz fue de vital importancia para el desarrollo de la PNT, poniendo un límite temporal superior a la predecibilidad que pueden alcanzar dichos métodos (estimado como dos semanas por el mismo Lorenz). Dicha predecibilidad está directamente relacionada con las condiciones iniciales y de frontera usadas para inicializar el modelo, ya que pequeñas diferencias en las condiciones iniciales (C.I.) eventualmente resultan en diferencias significativas en los resultados del pronóstico. Esto da pie al concepto de *sensibilidad* de un modelo de PNT ante condiciones iniciales, definido como la cuantificación de qué tan grande es la diferencia entre salidas de un mismo modelo inicializado con condiciones iniciales *ligeramente* diferentes. Para el campo del PNT la sensibilidad de un modelo es una de las propiedades más importantes, dado que las condiciones iniciales usualmente provienen de instrumentos de medición sujetos a incertidumbre (e.g errores en los equipos, de medición, de comunicación). Lo ideal para un PNT es que muestre una especie de “resistencia” ante la incertidumbre en las condiciones iniciales, de tal manera que al avanzar en el tiempo el pronóstico no difiera mucho de las observaciones.

En un aspecto más operacional, Rabier et al. (1996) determinaron el efecto en el error del pronóstico debido a la sensibilidad mostrada por un modelo de PNT ante cambios ligeros de condiciones iniciales. Este estudio fue realizado teniendo en mente modelos de PNT de escala regional. Rabier demostró que cambios ligeros en las condiciones iniciales pueden tener una contribución importante en los errores de pronóstico dado por los modelos de PNT. Este estudio particular se enfocó en el modelo ECMWF (*European Center for Medium-Range Weather Forecasts*). Posteriormente Gustafsson et al. (1998) demostraron que no solamente las condiciones iniciales jugaron un papel en el error de dichos modelos, sino que las condiciones de frontera aportaron gran parte del error. Warner et al. (1997) realizaron un resumen destacando la gran importancia que tienen las condiciones de frontera como limitante de los modelos de PNT regionales, enumerando varias recomendaciones para minimizar el error causado por un mal uso de estas condiciones.

Tanto Rabier como Gustafsson utilizaron para el estudio de sensibilidad el método adjunto. Dicho método (desarrollado para la asimilación de datos) calcula primero el gradiente del error del pronóstico con respecto a las condiciones iniciales. Posteriormente se sustrae de las condiciones iniciales un vector proporcional a dicho gradiente para generar un nuevo “análisis”. Dicho análisis es entonces utilizado como condición inicial para una nueva simulación, la cual puede verse como una integración en sensibilidad. Los resultados de esta simulación, al compararlos con los de la primera simulación, sirven como un diagnóstico de la sensibilidad. Rabier propone el uso de dicho “análisis” para mejorar de manera iterativa y en tiempo real el pronóstico de los modelos de PNT operacionales de escala regional. Otra estrategia para el estudio de sensibilidad es aquella utilizada para la mayor parte de estudios de esta propiedad del modelo WRF, consistiendo en usar diferencias en medidas de verificación como un proxy para medir la sensibilidad del modelo (Aligo et al., 2007), (Etherton y Santos, 2008), (Case et al., 2008).

### 1.2.3. Inicialización de los modelos numéricos

Los estudios mencionados muestran que los modelos de PNT regionales muestran una sensibilidad ante las condiciones iniciales y de frontera utilizadas para alimentarlos. Conviene entonces ahondar un poco en como son inicializados los modelos de PNT de escala regional. Esto debido a que para el pronóstico a corto plazo, dicha escala es la más utilizada por meteorólogos para emitir un pronóstico.

La habilidad de un pronóstico *adecuado* requiere que el modelo sea una representación adecuada de la realidad y que las condiciones iniciales y de frontera sean conocidas con certeza. Las condiciones iniciales necesitan cumplir adicionalmente con una suposición muy importante: deben de estar *balanceadas*. El balance de las condiciones iniciales implica eliminar movimientos oscilantes con frecuencias que no se disipan rápidamente en la atmósfera. A grandes rasgos, dos tipos de movimientos prevalecen en la atmósfera. En primera están aquellas perturbaciones de alta frecuencia que viajan con velocidad de fase de cientos de metros por segundo (ondas de inercio-gravedad). En segunda tenemos aquellos movimientos de baja frecuencia del orden de diez metros por segundo. Estas últimas perturbaciones son de mayor interés meteorológico, ya que la mayor parte de la energía esta contenida en estos grandes movimientos rotacionales, aproximados usualmente mediante el balance geostrófico. Esta distinción es importante ya que en la atmósfera existe un balance sutil y delicado entre el viento y el campo de presión, tal que las perturbaciones de alta frecuencia son disipadas rápidamente cuando se crean con tal de favorecer que su amplitud sea siempre mucho menor que los movimientos de baja frecuencia (Lorenz y Martin, 1995). Las condiciones iniciales no siempre cumplen esta suposición, por lo que es necesario modificarlas de tal manera que no contengan movimientos de alta frecuencia que se puedan propagar sin disipación. Cuando las condiciones iniciales cumplen con esta condición, se dice que están balanceadas.

Si las condiciones iniciales no están balanceadas de tal manera que no contengan perturbaciones de alta frecuencia, las perturbaciones se propagaran en el modelo. Esto usualmente resultará en que la simulación muestre resultados muy diferentes a lo observado. Un ejemplo muy famoso de esto fue la primer predicción numérica de Richardson, en donde estos tipos de movimientos hicieron que pronosticara una presión superficial 146 veces más grande que la observada (Lynch, 2006).

La *inicialización* es la técnica mediante la cual se asegura que las condiciones iniciales cumplirán con la condición de balance necesaria para un modelo de PNT. El objetivo de dicha técnica es definir los campos iniciales de tal manera que las ondas de inercio-gravedad sean pequeñas durante toda la simulación. Nótese que esto no implica que las condiciones iniciales estarán mas aproximadas a la realidad, simplemente se busca que no contengan movimientos de alta frecuencia.

Dentro de los métodos de inicialización más utilizados se encuentra el desarrollado en Machenhauer (1977). Dicho método propone fijar la tasa de crecimiento de perturbaciones de frecuencia alta en cero, con el proposito de que éstas mantengan amplitudes pequeñas durante toda la simulación. Este método, conocido como el método de inicialización de modos normales no lineal (NNMI por sus siglas en inglés), es sumamente eficaz. Posteriormente Daley en 1991 formuló un método basado en procesamiento digital de señales conocido como el *filtro digital* (Daley, 1991). Este método fue formulado para inicializar modelos de área limitada, ya que el método NNMI es complicado de usar con estos modelos. Un ejemplo de un modelo de área limitada que utiliza esta técnica de inicialización es el modelo WRF (a partir de su versión 3.1) (Smirnova et al., 2009).

## Inicialización de modelos regionales

Los modelos de escala regional comúnmente hacen uso de salidas de los modelos globales como los datos para su inicialización. Dichos modelos globales a su vez son inicializados usando campos provenientes de observaciones, mediante un proceso conocido como *asimilación de datos*. La asimilación de datos es un problema no trivial, ya que posee problemas

matemáticos complejos de interpolación y validación de datos. En cierta manera podemos decir que las observaciones se van permeando dentro del modelo global para llegar al regional, llevando consigo los errores que podrían tener de la asimilación. Es por esto que se le ha dado especial atención en años recientes a el desarrollo de modelos globales, tanto en su integración como en su inicialización. Un ejemplo de esta dinámica lo encontramos nuevamente con el modelo regional WRF, el cual muy comúnmente es inicializado usando campos provenientes de la salida del modelo *Global Forecasting System* (GFS).

Al ir integrando en tiempo el modelo regional, es necesario actualizar las condiciones de frontera en las paredes del dominio. Lo anterior comúnmente se realiza utilizando valores provenientes del modelo global como condiciones de frontera. El diseño de estas condiciones de frontera puede repercutir fuertemente en errores en la simulación, por lo que se debe de diseñar de acuerdo al caso particular que se desea estudiar (Warner et al., 1997).

Para este trabajo, salidas provenientes del modelo GFS fueron seleccionadas para ser usadas como condiciones iniciales y de frontera de las simulaciones usando el modelo WRF. Lo anterior es debido a que en el 2015, el Centro Nacional de Predicción Ambiental de los EE.UU. (NCEP por sus siglas en inglés), anunció una mejora importante en la resolución horizontal del modelo GFS (for Environmental Prediction, 2015). El modelo GFS es un modelo del tipo *espectral*, el cual representa el estado de la atmósfera como una superposición de funciones de onda. La salida cruda de este tipo de modelos está en la forma de coeficientes espectrales, los cuales pueden ser convertidos mediante una síntesis espectral en valores puntuales de una malla. Una mayor resolución espacial se consigue al aumentar el número de funciones base usadas para truncar los coeficientes espectrales.

La mejora realizada por NCEP permitió aumentar la resolución de las salidas de GFS de 0.5 a 0.25 grados. Para esto se cambió de un integrador con dinámica de tipo Euleriano (resolución  $\sim 27$  km), a uno con dinámica Semi-Lagrangiana (resolución  $\sim 13$  km). Al pasar de coeficientes espectrales a una malla regular la resolución espacial de la salida disminuye un poco, quedando en 0.25 grados ( $\sim 27$  km). Sin embargo, esto es aún una disminución del 50% en la resolución disponible previamente, como se puede observar en la Figura 1.2. Ya que el integrador resolvió las ecuaciones con mayor resolución espacial, se espera también que las soluciones se aproximen mejor a la realidad.

#### 1.2.4. Verificación de pronóstico

Siguiendo el método utilizado por los otros estudios para el análisis de sensibilidad del modelo WRF, se hará uso de diferencias en medidas de verificación de pronóstico como estimador de sensibilidad. La verificación de pronóstico es la rama auxiliar de las ciencias atmosféricas encargada de la *validación* de los pronósticos (Jolliffe y Stephenson, 2012). Esta validación se realiza cuantificando qué tan hábil o valioso fue el pronóstico emitido *a posteriori*. Lo anterior sigue la idea de que tener información sobre eventos en el futuro siempre es mejor que ser completamente ignorantes de lo que va a suceder. Finley (1884) fue el primero en cuestionar la validez de esta idea, proponiendo las técnicas que se convirtieron en la base de esta rama auxiliar.

Brier y Allen (1951) identificaron tres ventajas asociadas con la verificación de pronóstico. La primera ventaja es la *administrativa*, ya que los resultados de verificación son una herramienta útil para tomar decisiones en cuanto el manejo de recursos humanos de los centros de pronóstico. La segunda ventaja es la *científica*, ya que los resultados ayudan a comprender la razón por la cual funcionan (o no) los pronósticos. La tercer ventaja se relaciona con lo *económico*, ya que siempre existe una relación (no siempre sencilla) entre

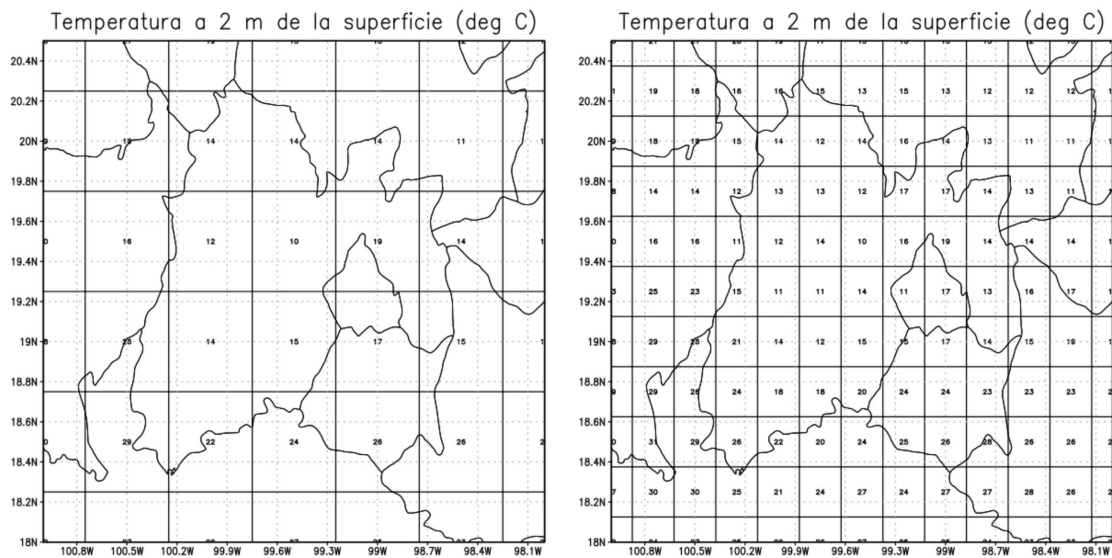


Figura 1.2: Izquierda: Simulación temperatura GFS con 0.50 grados de resolución horizontal. Derecha: Simulación temperatura GFS con resolución horizontal de 0.25 grados.

las necesidades de los usuarios y la habilidad de los pronósticos.

En este trabajo se hará un énfasis en la ventaja científica. Esto con el fin de tener una mejor comprensión de los efectos que las condiciones iniciales y de frontera (C.I. y de F.) junto con las parametrizaciones tienen sobre la calidad del pronóstico realizado con el modelo WRF en una región orográficamente compleja como lo es el Valle de México.

## Tipos de datos

Diferentes esquemas de verificación existen para diferentes tipos de datos. Las variables meteorológicas existen en un amplio espectro de tipos de datos, siendo importante distinguir entre estos. Para este trabajo nos interesan dos tipos de datos:

- Datos de tipo discreto (e.g. Precipitación o No precipitación).
- Datos de tipo continuo (e.g. Temperatura del aire).

Para cada uno de estos tipos de datos existen diferentes esquemas de verificación, como veremos más adelante.

Cabe mencionar que los datos siempre se pueden ordenar de tal manera que caigan dentro de uno u otro tipo de datos, de acuerdo al objetivo del usuario. Por ejemplo un agricultor puede estar interesado únicamente en saber cuando habrá una helada, sin importarle mucho el valor puntual de la temperatura mayor a 0 °C. En este caso una variable que inicialmente es continua (temperatura) puede convertirse a una variable binaria mediante un umbral, quedando como:

$$T \leq 0 = a$$

$$T > 0 = b.$$

Cada tipo de dato puede también clasificarse en dos subcategorías: determinístico o probabilístico. Esta distinción es determinante para la elección de un esquema de verificación. En general la salida “cruda” de un modelo de PNT como el WRF da como resultado un pronóstico determinístico, en donde no se toma en cuenta la incertidumbre asociada al pronóstico. En contraste un pronóstico probabilístico se obtiene como resultado de un ensamble de salidas de un PNT. Debido al gran costo computacional que presentan los ensambles para ser usados de modo operativo, en este trabajo no se hará uso de éstos.

### Esquemas de verificación

Un esquema de verificación es el conjunto de métricas elegidas para evaluar la bondad de un pronóstico del tiempo. (Murphy, 1993) identificó tres diferentes tipos de bondad, cada una asociada al objetivo del usuario para la verificación:

1. La **consistencia** es una medida de qué tanto el pronóstico esta de acuerdo con el juicio del pronosticador;
2. el **valor** mide los beneficios económicos para él usuarios derivados del pronóstico y;
3. la **calidad** es una medida de qué tanto se acercó el pronóstico a las observaciones.

Cada uno de estos tipos de bondad se puede asociar a una de las tres ventajas de la verificación: La consistencia con lo administrativo, el valor con lo económico y la calidad con lo científico. Sin embargo cada tipo de bondad está también relacionada con las otras ventajas. Debido a esto la definición de lo que es un “buen” pronóstico no es estática, sino que obedece siempre al objetivo y la necesidad particular de los usuarios para cada estudio (Finley, 1884).

Las salidas crudas de un modelo de PNT permiten únicamente la evaluación de la calidad. Un estudio de consistencia requeriría que un experto evaluará la información del PNT y la integrara junto con otras fuentes para elaborar un pronóstico completo, ya que la salida de un PNT no es más que una aproximación a la realidad. Ya que las computadoras (aún) no son capaces de realizar este análisis, no es posible estudiar la consistencia de salidas crudas de un modelo de PNT. El presente estudio se limitará a evaluar las salidas del PNT, directamente relacionado con la calidad del pronóstico. En cuanto al valor, la parte económica queda fuera de los alcances de este trabajo, por lo que no será explorado.

### Atributos de la calidad del pronóstico

Tradicionalmente, la bondad de la calidad es cuantificada mediante una función que depende de la distancia que existe entre los pronósticos y las observaciones. Ejemplos de esto son el error cuadrático medio (RMSE), error medio absoluto (MAE), etc. Estas medidas son parte de una familia denominada como la aproximación basada en observaciones (Murphy y Winkler, 1987).

Mas recientemente, Wilks (2011) propone el uso de una aproximación basada en distribuciones. Esta aproximación, en vez de tomar distancias entre datos puntuales, hace

uso de la distribución conjunta de los pronósticos (denotado por  $y$ ) y de las observaciones (denotado por  $o$ ):

$$p(y, o). \quad (1.1)$$

Esta aproximación tiene una ventaja sobre la aproximación basada en observaciones al tener toda la información no dependiente del tiempo contenida en una distribución conjunta. Ya que la distribución conjunta es difícil de usar directamente, dos maneras diferentes de factorizar esta distribución, aprovechando las propiedades de la probabilidad, fueron concebidas por Murphy y Winkler (1987). La primera de estas es la *factorización de calibración-refinamiento*:

$$p(y_i, o_j) = p\{o_j|y_i\}p\{y_i\}; i = 1, \dots, I; j = 1, \dots, J. \quad (1.2)$$

Esta factorización es la más intuitiva de las dos, ya que el primer término es la probabilidad de que dado un pronóstico  $y_i$  ocurra cualquiera de las observaciones  $o_j$ . Esto se puede pensar como qué tan *calibrados* se encuentran los pronósticos  $y_i$ . El segundo término es la distribución marginal  $p(y_i)$ , qué indica que tan probable es que se pronostique cualquiera de los  $I$  valores posibles. Mientras mayor sea la extensión de la probabilidad a lo largo de los  $I$  valores posibles, más *refinado* será el pronóstico.

Por otro lado, la *factorización de verosimilitud-tasa base* (Murphy y Winkler, 1987) toma la siguiente forma:

$$p(y_i, o_j) = p\{y_i|o_j\}p\{o_j\}; i = 1, \dots, I; j = 1, \dots, J. \quad (1.3)$$

En este caso el primer término indica la probabilidad para cada uno de los  $I$  pronósticos de haber sido indicados dada una única observación  $o_j$ . El segundo término es la distribución marginal de probabilidades para cada una de las  $J$  observaciones, conocida usualmente como la *climatología muestral*.

La información contenida en cada una de las dos factorizaciones permite reconstruir completamente la distribución (1.1). La elección de alguna de estas dos depende del objetivo de la verificación. Los diferentes atributos escalares asociados a la calidad del pronóstico están indicados en la tabla (1.1), junto con la factorización necesaria para calcularlos (Murphy, 1993).

Las métricas de calidad de pronóstico comunmente cuantifican uno de los 10 atributos descritos con anterioridad, aunque a veces una misma métrica puede evaluar dos o hasta más al mismo tiempo. Cada esquema de verificación de calidad debe definir tanto los atributos a medir como las métricas a utilizar. En este trabajo se evaluarán cada uno de los atributos descritos para los diferentes tipos de datos haciendo uso de las diferentes medidas de verificación descritas por (Wilks, 2011).

## Medidas de calidad para datos continuos

A continuación se describen las medidas de calidad más comunes para evaluar datos discretos, el error medio, el error medio absoluto y el error cuadrático medio. Adicionalmente se describen dos medidas gráficas para evaluar la calidad de datos continuos, los cuales son muy útiles para hacer una evaluación rápida, sobre todo al comparar modelos.

**Error medio** El error medio,  $EM$ , es una medida tradicional del sesgo, calculado como el promedio de las diferencias entre el pronóstico y la observación. Para un número  $n$  de pronósticos dados en un punto a lo largo del tiempo:



$$EM = \frac{1}{n} \sum_{k=1}^n (f_k - o_k) = \bar{f} - \bar{o}. \quad (1.4)$$

Esta medida es útil para identificar si un pronóstico sobrestima o subestima las observaciones. Los pronósticos que en promedio sobrestimen las observaciones exhibirán  $EM > 0$ . En cambio, aquellos que en promedio subestimen las observaciones exhibirán  $EM < 0$ . Si los pronósticos y las observaciones tienen el mismo valor en promedio,  $EM = 0$ .

Debemos tomar en cuenta que el EM es una medida muy limitada para describir la calidad del pronóstico. Esto es una consecuencia directa de utilizar promedios para calcular el EM, los cuales eliminan toda la variabilidad de los datos subyacentes. Por ejemplo, un pronóstico que en los extremos siempre subestime las observaciones pero en la parte media siempre las sobrestime, tendrá un valor de EM muy cercano al 0.

**Error medio absoluto** El error medio absoluto (*EMA*) es una medida de la exactitud y la asociación de la calidad de un pronóstico. Matemáticamente se define como el promedio de la diferencia absoluta de las observaciones y los pronósticos,

$$EMA = \frac{1}{n} \sum_{k=1}^n |f_k - o_k|, \quad (1.5)$$

en donde  $k$  indica el  $k$ -ésimo par de observaciones y pronósticos para los cuales estamos evaluando la calidad. Si los pronósticos fueran perfectos ( $f_k = o_k$ ), el valor de EMA sería igual a cero. Este valor aumenta conforme las diferencias entre pronósticos y observaciones son mayores, teniendo las mismas unidades que la variable original.

El EMA es una medida útil y rápida de la exactitud, sobre todo para evaluar situaciones en donde no se espera que el pronóstico se aleje mucho del valor climatológico.

**Error cuadrático medio** De manera similar al EMA, el error cuadrático medio (*ECM*) es una medida de la exactitud y asociación de la calidad del pronóstico, definido como

$$ECM = \frac{1}{n} \sum_{k=1}^n (f_k - o_k)^2. \quad (1.6)$$

El ECM es el promedio de la diferencia al cuadrado de los pronósticos y las observaciones, siendo casi igual al EMA, pero aplicando la función cuadrática a las diferencias. Dicha función cuadrática resulta en que el ECM sea más sensible a los errores grandes, en particular a los valores atípicos.

Para ver como el ECM se relaciona con la asociación de la calidad, debemos primero considerar la manipulación algebraica del ECM propuesta por Murphy (1988):

$$ECM = EM^2 + s_f^2 + s_o^2 - 2s_f s_o r_{fo}, \quad (1.7)$$

en donde  $r_{fo}$  es el coeficiente de correlación de Pearson entre las observaciones y los pronósticos (representando la asociación) y  $s$  es la desviación estándar de la distribución marginal.

El cuarto término de (1.7) indica que mientras mayor sea la correlación entre pronósticos y observaciones, menor será el ECM. Sin embargo, es posible que tengamos un pronóstico en donde  $r_{fo} = 1$  pero el EM sea muy elevado, dando como resultado un ECM grande. Es debido a este tipo de situaciones que el uso de un solo atributo para evaluar la calidad usualmente no aporta toda la información necesaria para hacer una buena evaluación.

**Diagrama Cuantil Condicional** Este diagrama muestra en una representación gráfica los dos componentes de la factorización de calibración-refinamiento de la distribución conjunta definida en (1.1). Un ejemplo de este tipo de diagrama se puede ver en la Figura (3.13). En el eje horizontal se muestran los valores pronosticados, mientras que en el eje vertical se encuentran los valores observados. Un pronóstico perfecto sería aquel en donde los puntos de pares  $(f, o)$  cayeran exactamente en la línea diagonal con pendiente 1 originada en  $(0,0)$ . Aquellos puntos que caigan por debajo de la línea son aquellos que *sobrestimaron* la observación, mientras que los que están por encima de la línea son aquellos que *subestimaron* la observación. Adicionalmente el eje horizontal muestra un histograma de los valores pronosticados, el cual representa la nitidez del pronóstico. Por último, líneas correspondientes a diferentes percentiles suavizados se agregan a la gráfica, los cuales ayudan a discernir la exactitud del pronóstico en valores medios o en valores extremos. La primer parte de la distribución (1.1) esta representada por los puntos y las líneas de los cuantiles, mientras que la segunda parte se ve reflejada en el histograma de los pronósticos.

**Diagrama de Taylor** La segunda herramienta gráfica utilizada fue el diagrama diseñado por Taylor en 2001 (Taylor, 2001). Este es un diagrama de gran utilidad para evaluar a simple vista la calidad del pronóstico de datos continuos, usando los principios de la descomposición del RMSE mencionados anteriormente. Una ejemplo de este tipo de diagrama puede verse en la Figura 3.5.

Para comprender este diagrama, es necesario observar primero que la factorización descrita en la ecuación (1.7), removiendo el error debido al sesgo EM, es muy similar a la ley de los cosenos:

$$C^2 = A^2 + B^2 - 2AB \cos \theta. \quad (1.8)$$

En este caso podemos ver que las desviaciones estándar  $s_f, s_o$  toman el lugar de los catetos de un triángulo, en donde el coeficiente de correlación  $r$  toma el lugar del ángulo  $\theta$ . De acuerdo a nuestro símil, el EMC será entonces el valor de la “hipotenusa”, o en este caso, de la línea que completa el triángulo entre los dos catetos. Esto se representa de manera gráfica al colocar los vértices de este triángulo en coordenadas polares, en donde el ángulo de la horizontal es el coseno de la correlación, y la distancia radial del origen está definida por las desviaciones estándar. Para comparar con un pronóstico perfecto, en donde  $f = o$ , este diagrama también incluye siempre el valor de  $s_o$  en la horizontal, ya que la correlación de las observaciones consigo mismas (el caso ideal) por definición es 1 y entonces  $\cos(1) = 0$ .

En general, un pronóstico es bueno cuando cumple con dos condiciones: se encuentra cercano a el círculo de radio definido por  $s_o$  y su correlación es cercana al 1.0. Mientras más lejano al círculo de  $s_o$ , mayor será el valor de EMC (esto da pie a graficar círculos de distintos valores de EMC, para facilitar la lectura del diagrama). Es útil recordar en este punto que un pronóstico puede presentar un valor de correlación muy elevado junto con un valor de sesgo elevado también, resultando en valores altos de EMC.

## Medidas de calidad para datos discretos

La evaluación de los datos discretos es comunmente realizada mediante el uso de tablas de contingencia, un método desarrollado por (Finley, 1884). Este método divide a los pares observación/pronóstico en una tabla con I x J categorías de conteos de las I x J combinaciones posibles de pares observación/pronóstico. Ya que los conteos son básicamente frecuencias absolutas de cada evento, basta con dividir cada uno de estos entre

		Observado	
		Sí	No
Pronosticado	Sí	a Aciertos	b Falsas Alarmas
	No	c Errores	d Correcto Negativo

Figura 1.3: Ejemplo de una tabla de contingencia de 2x2.

el tamaño de la muestra para obtener las frecuencias relativas, que da como resultado la distribución conjunta definida en (1.1). Un ejemplo sencillo se muestra en la Figura (1.3) usando una tabla de contingencia de 2x2, representando un pronóstico de ocurrencia *si* y no ocurrencia *no*. Como ejemplo la precipitación se puede dividir en dos eventos: Hubo precipitación o no hubo precipitación.

**Proporción Correcta (PC)** La proporción correcta (*proportion correct* en inglés) es una medida de la exactitud del pronóstico. Se define simplemente como el cociente de los conteos en donde el pronóstico coincidió con la observación y el número total de conteos. Para la tabla de 2x2 corresponde a:

$$PC = \frac{a + d}{n}. \quad (1.9)$$

El mejor valor posible es 1, mientras que el peor valor posible es 0. Esta medida le da el mismo peso a los pronósticos de ocurrencia “sí” y de no ocurrencia “no”, por lo que en situaciones donde el pronóstico “sí” sea muy raro (como pronosticar lluvia en temporada de secas) esta medida podrá estar muy inflada por los pronósticos de “no”, los cuales son mucho más sencillos de hacer.

**Puntaje de amenaza (PA)** El puntaje de amenaza (*threat score* en inglés) es otra medida de la exactitud de pronóstico. Esta medida fue creada para tomar en cuenta el problema de la PC al manejar pronósticos en donde una situación sea mucho más frecuente que otra. El PA se define como el cociente entre el evento de menor ocurrencia y la suma de el número total de ocasiones en donde dicho evento sea observado o pronosticado. Para nuestro ejemplo de 2X2, en donde el evento “a” es el más raro:

$$PA = \frac{a}{a + b + c}. \quad (1.10)$$

El mejor valor posible de PA es 1, mientras que el peor valor posible es de 0.

**Sesgo** El sesgo es una medida del atributo del mismo nombre. Este es simplemente la razón existente entre los pronósticos que anuncian un cierto evento entre las observaciones de dicho evento. Por ejemplo, para el ejemplo 2x2 usando como evento la ocurrencia *si*,

$$S = \frac{a + b}{a + c}. \quad (1.11)$$

Cuando el evento de interés es pronosticado el mismo número de veces que es observado,  $S = 1$  es el valor óptimo, y si el evento es pronosticado más veces que es observado entonces  $S > 1$  (*sobrepronosticado*) y viceversa para cuando es pronosticado menos veces de lo que es observado (*subpronosticado*).

**Probabilidad de Detección (PD) y de Falsa Detección (PFD)** La discriminación es evaluada utilizando la probabilidad condicional  $p(f_i|o_j)$ . Diferentes métricas se han nombrado para cada una de las combinaciones posibles. Por ejemplo, cuando el evento de interés es la ocurrencia en una tabla 2x2, en donde  $f_1, o_1$  son la ocurrencia del evento, la probabilidad condicional se escribe como:

$$p(f_1|o_1) = PD = \frac{a}{a + c}. \quad (1.12)$$

Esta cantidad es comúnmente conocida como la probabilidad de detección (*Probability of Detection* en inglés), definida como la proporción de los pronósticos de ocurrencia correctos entre el número de veces que dicho evento ocurrió. El PD toma valores de 0 cuando ningún pronóstico de ocurrencia fue correcto, y de 1 cuando todos los pronósticos de ocurrencia fueron adecuados.

En cambio, si los pronósticos de interés fueran aquellos en donde se pronosticó la ocurrencia pero no se observó, tendríamos la probabilidad de falsa detección (*Probability of False Detection* en inglés):

$$p(f_1|o_2) = PFD = \frac{b}{b + d}. \quad (1.13)$$

El PFD es la proporción de los pronósticos que resultaron en falsa alarma entre el número total de no ocurrencias del evento. Esta medida toma un valor de 0 para pronósticos perfectos donde no hay falsas alarmas, y de 1 para pronósticos en donde siempre hubo falsas alarmas.

**Razón de Falsa Alarma (RFA)** La razón de falsa alarma (*False Alarm Ratio* en inglés) es una medida tanto de la confiabilidad como de la resolución. Esta está basada en la probabilidad condicional  $p(o|f)$  cuando se toma en cuenta el pronóstico de ocurrencia con la observación de no ocurrencia. En la tabla de 2x2 esto sería:

$$p(o_2|f_1) = RFA = \frac{b}{a + b}. \quad (1.14)$$

Podemos ver que la RFA es la proporción de los pronósticos de falsa alarma entre el número de veces que dicho evento fue pronosticado. Para un pronóstico con muy alta confiabilidad es preferible tener valores de RFA muy pequeños, mientras que un valor de RFA de 1 es el peor valor posible.

## Puntajes de habilidad

La habilidad de un pronóstico es una medida de la calidad relativa de un conjunto de pronósticos con respecto a otro conjunto de pronósticos de referencia. Un ejemplo de esto es el uso de la climatología muestral o de la persistencia como pronósticos de referencia, en donde veremos si nuestro conjunto de pronósticos fueron mejores o peores que haber pronosticado el valor climatológico o usar el valor anterior. En nuestro caso haremos uso de dos pronósticos de referencia; el primero será la climatología muestral, calculada usando todas las observaciones. El segundo será el pronóstico resultante de una de las dos resoluciones, de tal manera que la habilidad sea relativa a los pronósticos de la otra resolución. De esta manera podremos ver fácilmente si hubo o no una mejoría en la calidad del pronóstico al usar una resolución u otra.

Una manera común de representar la habilidad del pronóstico es mediante el uso del puntaje de habilidad (*skill score*). Aunque existen diferentes maneras de definir este puntaje, todos se basan en la forma general

$$PH_{ref} = \frac{A - A_{ref}}{A_{perf} - A_{ref}} \times 100\%; \quad (1.15)$$

en donde *ref* se refiere al pronóstico de referencia usado, *A* es la medida de habilidad usada (como PC por ejemplo, y *perf* es el valor de *A* que obtendría un pronóstico perfecto (i.e. 1 para PC).

El valor de PH estará determinado de acuerdo a la ganancia o pérdida de habilidad de un pronóstico con respecto a la referencia. Cuando el pronóstico es mejor que la referencia,  $PH > 0$ . Cuando el pronóstico es peor que la referencia,  $PH < 0$ . Cuando el pronóstico y la referencia tienen la misma habilidad,  $PH = 0$ .

A continuación se hará una breve descripción de los 4 diferentes PH, los cuales son muy utilizados en el campo de verificación de pronóstico:

**Puntaje de habilidad de Heidke (PHH)** El puntaje de habilidad de Heidke (*Heidke Skill Score*), definido por Heidke (1926) es un PH en donde la PC es usada como medida de calidad. En este puntaje el pronóstico de referencia es la PC que obtendrían un conjunto de pronósticos aleatorios que sean estadísticamente independientes de las observaciones. Para la tabla 2x2:

$$PHH = \frac{2(ad - bc)}{(a + c)(c + d) + (a + b)(b + d)}. \quad (1.16)$$

**Puntaje de habilidad de Gilbert (PHG)** También conocido como la razón de éxito, el puntaje de habilidad de Gilbert (*Gilbert Skill Score*) es un puntaje construido con base en el PA. En la tabla de 2x2,

$$PHG = \frac{a - a_{ref}}{a - a_{ref} + b + c}. \quad (1.17)$$

En este caso  $a_{ref}$  hace referencia a el valor de *a* para un conjunto de pronósticos aleatorios,

$$a_{ref} = \frac{(a + b)(a + c)}{n}. \quad (1.18)$$

**Puntaje de Dependencia Extrema (PDE)** Para eventos en donde la ocurrencia sea extremadamente rara ( $p(o_1) \rightarrow 0$ ), puntajes como el PHH o el PHG se aproximan también al cero, aunque los pronósticos tengan buena habilidad. Para estos casos, Coles et al. (1999) creó el llamado puntaje de dependencia extrema (*Extreme dependency score*), definido para la tabla 2x2 como

$$PDE = \frac{2 \ln \left[ \frac{(a+c)}{n} \right]}{\ln[a/n]} - 1. \quad (1.19)$$

**Puntaje de habilidad de Gandin-Murphy (PHGM)** Hasta ahora los puntajes descritos han usado la tabla 2x2 como ejemplo, sin embargo, en el caso de tablas más grandes es importante tomar consideraciones adicionales. Un ejemplo de un puntaje de habilidad generado en especial para tablas de varias categorías es el puntaje de habilidad de Gandin-Murphy (*Gandin-Murphy Skill Score*). Este se define de la siguiente manera:

$$PHGM = \sum_{i=1}^I \sum_{j=1}^J p(f_i, o_j) s_{i,j}. \quad (1.20)$$

En donde  $p(f_i, o_j)$  son las diferentes probabilidades conjuntas de 1.1 y  $s_{i,j}$  es una función de pesos generados de tal manera que se recompensen los pronósticos acertados y se penalicen los pronósticos erróneos. Diferentes maneras de realizar estos pesos han sido propuestos, pero en este trabajo usaremos el método propuesto por Gerrity en 1992.

Tabla 1.1: Atributos escalares de la calidad.

<b>Atributo</b>	<b>Definición</b>	<b>Distribuciones Relevantes</b>
Sesgo	Correspondencia entre pronóstico medio y observación media.	$p(f), p(x)$
Asociación	Correspondencia lineal entre pares individuales de pronósticos y observaciones.	$p(f, x)$
Exactitud	Correspondencia promedio entre pares individuales de pronósticos y observaciones.	$p(f, x)$
Habilidad	Exactitud de pronósticos relativos a la exactitud de pronósticos producidos por un estándar de referencia.	$p(f, x)$
Confiabilidad	Correspondencia entre la observación condicional media y el pronóstico condicionante, promediado entre todos los pronósticos.	$p(x f), p(f)$
Resolución	Diferencia entre la observación condicional media y la observación incondicional media, promediado entre todos los pronósticos.	$p(x f), p(f)$
Nitidez	Variabilidad de los pronósticos descrita por su distribución marginal.	$p(f)$
Discriminación 1	Correspondencia entre el pronóstico condicional medio y la observación condicionante, promediado entre todas las observaciones.	$p(f x), p(x)$
Discriminación 2	Diferencia entre el pronóstico condicional medio y el pronóstico incondicional medio, promediado entre todas las observaciones.	$p(f x), p(x)$
Incertidumbre	Variabilidad de las observaciones descrita por su distribución marginal.	$p(x)$

# Capítulo 2

## Método

El objetivo de este trabajo es cuantificar la sensibilidad del modelo WRF (versión 3.8) al ser inicializado y alimentado con condiciones iniciales y de frontera (C.I. y de F.) de dos resoluciones diferentes. El primer paso fue cuantificar la calidad del pronóstico obtenido por el modelo considerando cada una de las dos resoluciones diferentes. Posteriormente se utilizó la diferencia entre la calidad como *proxy* de sensibilidad. Pruebas estadísticas derivadas de la verificación de pronóstico fueron usadas para determinar si la sensibilidad es lo suficientemente grande para cambiar significativamente la calidad del pronóstico.

### 2.1. Diseño del experimento numérico

En la presente investigación se implementó el modelo WRF en su versión 3.8 (Skamarock et al., 2005). Todos los experimentos numéricos fueron realizados en el cluster *Ometeótl* del Centro de Ciencias de la Atmósfera (CCA), UNAM. Para ello se utilizaron dos dominios anidados, un dominio principal que engloba gran parte de la República Mexicana con una resolución horizontal de 20 km (Figura 2.1), y un dominio anidado dentro del Valle de México con resolución horizontal de 6.6 km. La sensibilidad del modelo se estudió con base a los resultados del dominio de 6.6 km (mayor resolución), ya que es muy similar al dominio que actualmente se utiliza en el pronóstico del tiempo operativo del grupo Interacción Océano Atmósfera del CCA.

El dominio anidado fue elegido de tal manera que incluyera la mayor parte de la topografía representativa del Valle de México, cuidando que la frontera lateral no omitiera alguna montaña. Para todas las simulaciones se utilizaron 23 niveles verticales con un tope superior en 10 hPa.

Los datos estáticos geográficos utilizados para estas simulaciones están incluidos en el sistema de pre-procesamiento WPS (versión 3.8), con la base de datos de MODIS de uso de suelo de 2008. La topografía del WRF proviene del modelo digital de elevación global USGS GMTED 2010 (Danielson y Gesch, 2011), con una resolución horizontal de 30 segundos de arco para ambos dominios.

El modelo fue inicializado con las salidas del modelo global GFS versión 12.0.0. (National Centers for Environmental Prediction, 2015). Las condiciones iniciales corresponden al campo interpolado de la salida GFS para el primer paso de tiempo del modelo. Posteriormente, se actualizan las condiciones de frontera del modelo WRF cada tres horas haciendo uso del pronóstico correspondiente proveniente del modelo GFS. Ya que la agencia responsable de correr el modelo GFS libera cuatro salidas al día, cada una con 384 horas



de pronóstico se decidió usar siempre la salida correspondiente a las 00z, para mantener consistencia. De esta salida se tomaron los archivos correspondientes a las primeras 48 horas de pronóstico.

Todos los experimentos se llevaron a cabo usando las mismas parametrizaciones (ver apéndice A), con fin de evitar cambios en la salida del modelo debido a diferencias en la representación física de procesos de subescala.

Se seleccionaron 6 meses del año 2015 para la simulación. Este fue el año en donde el pronóstico GFS comenzó a generar salidas con una resolución de 0.25 grados. Los 6 meses fueron elegidos para ser representativos de las tres temporadas reportadas en el dominio por (Fenn et al., 2002): la temporada seca cálida, seca fría y de lluvias. El criterio para seleccionar los 6 meses se explicará a detalle en la siguiente sección.

La transferencia de radiación fue parametrizada usando el esquema RRTM para la onda larga (Mlawer et al., 1997) y el esquema Dudhia para la onda corta (Dudhia, 1989). Adicionalmente un esquema de microfísica de momento sencillo de tercera clase (Hong et al., 2004) junto con una parametrización de cúmulos usando el esquema Kain-Fritsch (Kain, 2004). La elección de usar un esquema de cúmulos junto a uno de microfísica se realizó debido a la incertidumbre asociada con la resolución horizontal de 6 km, que es la región conocida como "zona gris" de la simulación de convección (Gerard, 2007). Los procesos de superficie fueron parametrizados mediante el esquema YSU (Hong et al., 2006) para la capa límite planetaria, el esquema de difusión térmica de 5 capas para la superficie (Dudhia, 1996) y el esquema de similaridad de MM5 para los flujos de superficie.

El postprocesamiento de las salidas se realizó con el software ARWPost (versión 3) junto con el software GrADS para su visualización. Se realizó una inspección visual para determinar que no existieran problemas con las salidas del modelo, observando que el modelo se comportara de la manera esperada.

## 2.2. Base de datos observación-pronóstico

### 2.2.1. Observaciones de superficie

Los datos de observaciones en superficie fueron obtenidos de dos redes de observación existentes en el Valle de México: la red meteorológica del sistema de monitoreo atmosférico de la Ciudad de México (conocida como REDMET), y la red de estaciones meteorológicas automatizadas del Servicio Meteorológico Nacional Mexicano (conocidas como EMA's). Todos los datos fueron proporcionados por las dependencias gubernamentales correspondientes. Tres variables fueron seleccionadas para realizar la verificación: temperatura a 2 metros del suelo, magnitud de la velocidad del viento a 10 metros del suelo y la precipitación acumulada horaria. Esta última variable se encuentra disponible únicamente para estaciones EMA.

El primer paso para el uso de estos datos fue determinar cuáles de las estaciones se encontraban dentro del dominio descrito en la figura 2.1. Este criterio arrojó 37 estaciones, 15 de la red de EMAs y 22 de REDMET. La distribución espacial de estas estaciones se puede observar en el mapa de la Figura 2.2. Se incluyen las curvas de nivel de acuerdo a la topografía usada en el modelo.

Después de identificar las estaciones que podían ser usadas por ubicación, se procedió a homogeneizar la resolución temporal de los datos de ambas redes. Esto debido a que las estaciones EMA reportan datos cada 10 minutos, mientras que las REDMET reportan

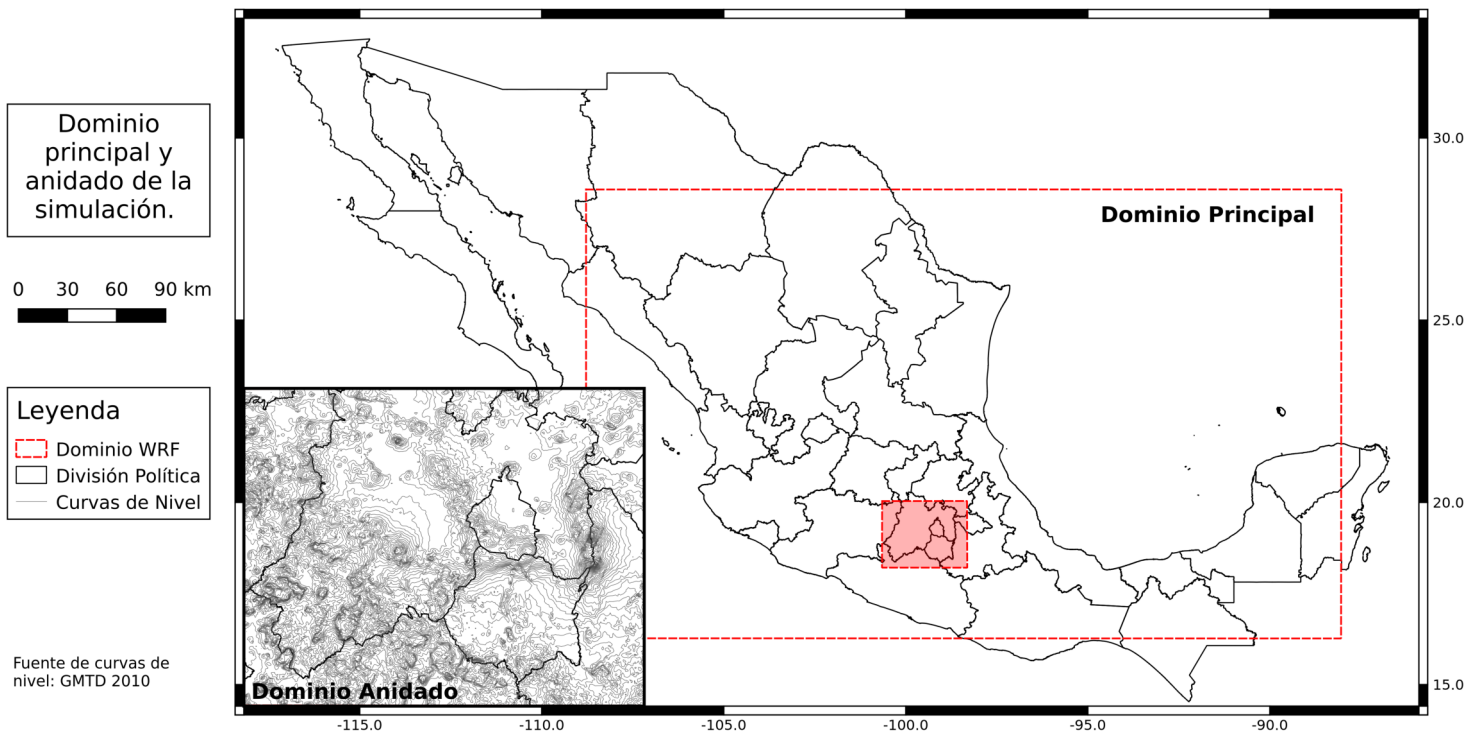


Figura 2.1: Dominio de la simulación mostrando el dominio principal de 20 km y el dominio anidado de 6.6 km.

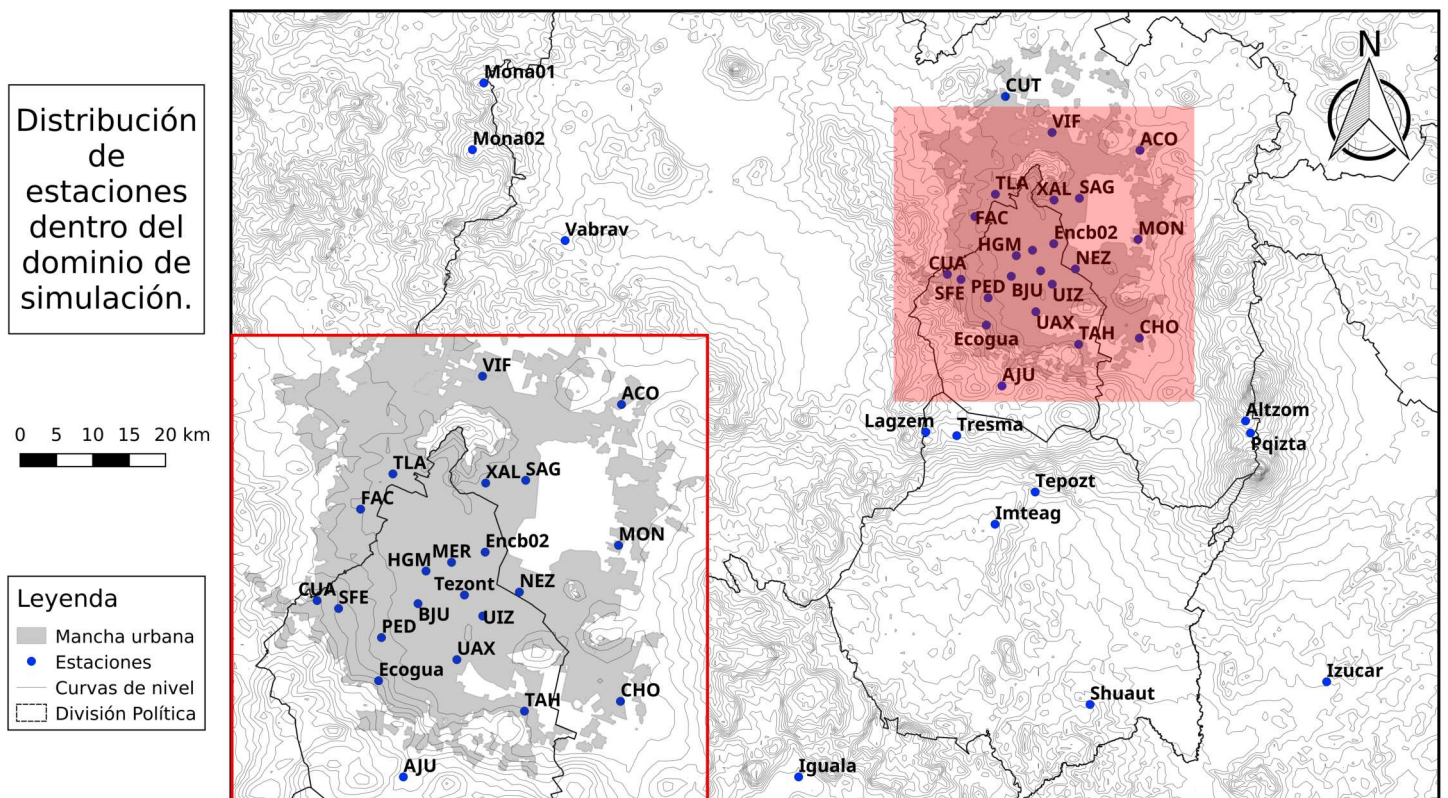


Figura 2.2: Mapa de estaciones analizadas en el Valle de México y alrededores.

cada hora. Con base a la frecuencia más baja (1 hora), se transformaron las series de las estaciones EMA para tener solo datos horarios. El criterio de esta transformación fue el de usar valores instantáneos para la velocidad del viento, valores horarios acumulados para la precipitación y medias horarias centradas en el valor de la hora para la temperatura. Ya que el modelo WRF trabaja con horario UTC, se realizó un cambio de horario de los datos REDMET de hora local de la Ciudad de México (GMT-5,6) a hora UTC. Los datos EMA no requirieron este cambio de horario.

Una vez que ambas series de datos presentaron la misma frecuencia temporal, se realizó un control de calidad. Este control considera como criterio únicamente el porcentaje de datos faltantes para cada estación en cada mes del año. Un porcentaje mínimo de 90 % fue el umbral requerido para no descartar la estación en el mes evaluado. Lo anterior se puede ver ilustrado en la figura (2.3) que representa una estación con suficientes datos, en contraste de la estación ilustrada en la Figura (2.4) la cual muestra una ausencia de datos. Aunque se realizó un análisis visual para ver que no existieran picos o valores fuera de un rango esperado, no se aplicó ningún filtro más allá del descrito anteriormente.

Los 6 meses de simulación fueron elegidos al determinar qué meses contiguos presentarían la mayor probabilidad de tener series de datos completas en todas las estaciones meteorológicas. Esto se calculó utilizando el porcentaje total de datos para todas las estaciones en dos meses seguidos (p. ej. enero-febrero, marzo-abril, etc) como una probabilidad de que dicho par de meses tuviera datos completos. De este análisis los 3 pares de meses contiguos para cada temporada con la mayor probabilidad de estar completos fueron:

1. Abril-Mayo, representando la temporada seca cálida,
2. Agosto-Septiembre, representando la temporada de lluvias y,
3. Noviembre-Diciembre, representando la temporada seca fría.

### 2.2.2. Pares de datos observación-pronóstico

Los pares de observación-pronóstico fueron elaborados utilizando el punto de malla de la simulación más cercano a cada estación al igual que Ruiz et al. (2010). Esta aproximación requiere considerar que la representatividad de las estaciones meteorológicas de superficie es de máximo 5 kilómetros a la redonda (Jarraud, 2008). Esta condición es válida cuando el terreno es plano, cosa que ocurre en el interior del Valle de México pero no en los alrededores. Ya que los puntos de la malla del modelo no correspondían exactamente con las estaciones de superficie, se utilizó el punto del modelo más cercano a la estación, siempre que este estuviera adentro de la zona de representatividad. Se decidió utilizar esta aproximación en vez de interpolar valores con los vecinos más cercanos para no introducir errores de estimación al interpolar la precipitación. La Figura 2.5 muestra la posición de las estaciones con su radio de representatividad de 5 km, junto con los puntos de malla del modelo más cercanos.

La comparación de las observaciones y los pronósticos se realizó utilizando las últimas 24 horas resultantes de cada simulación. Las simulaciones numéricas se hicieron a 48 horas de pronóstico (empalmándose siempre 24 horas de días contiguos), por lo que era posible escoger diferentes intervalos para la comparación. Se permitió al modelo “calentarse” las primeras 24 horas para disminuir lo más posible errores por falta de *spin-up*.

Para facilitar la evaluación de medidas de precipitación los resultados numéricos las estaciones fueron agrupados de acuerdo a su localización espacial en las diferentes cuen-




Figura 2.3: Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA iguala para el mes de Noviembre 2015.




Figura 2.4: Series de tiempo de temperatura, magnitud de la velocidad del viento y precipitación para la estación de la red EMA imteag para el mes de Noviembre 2015.



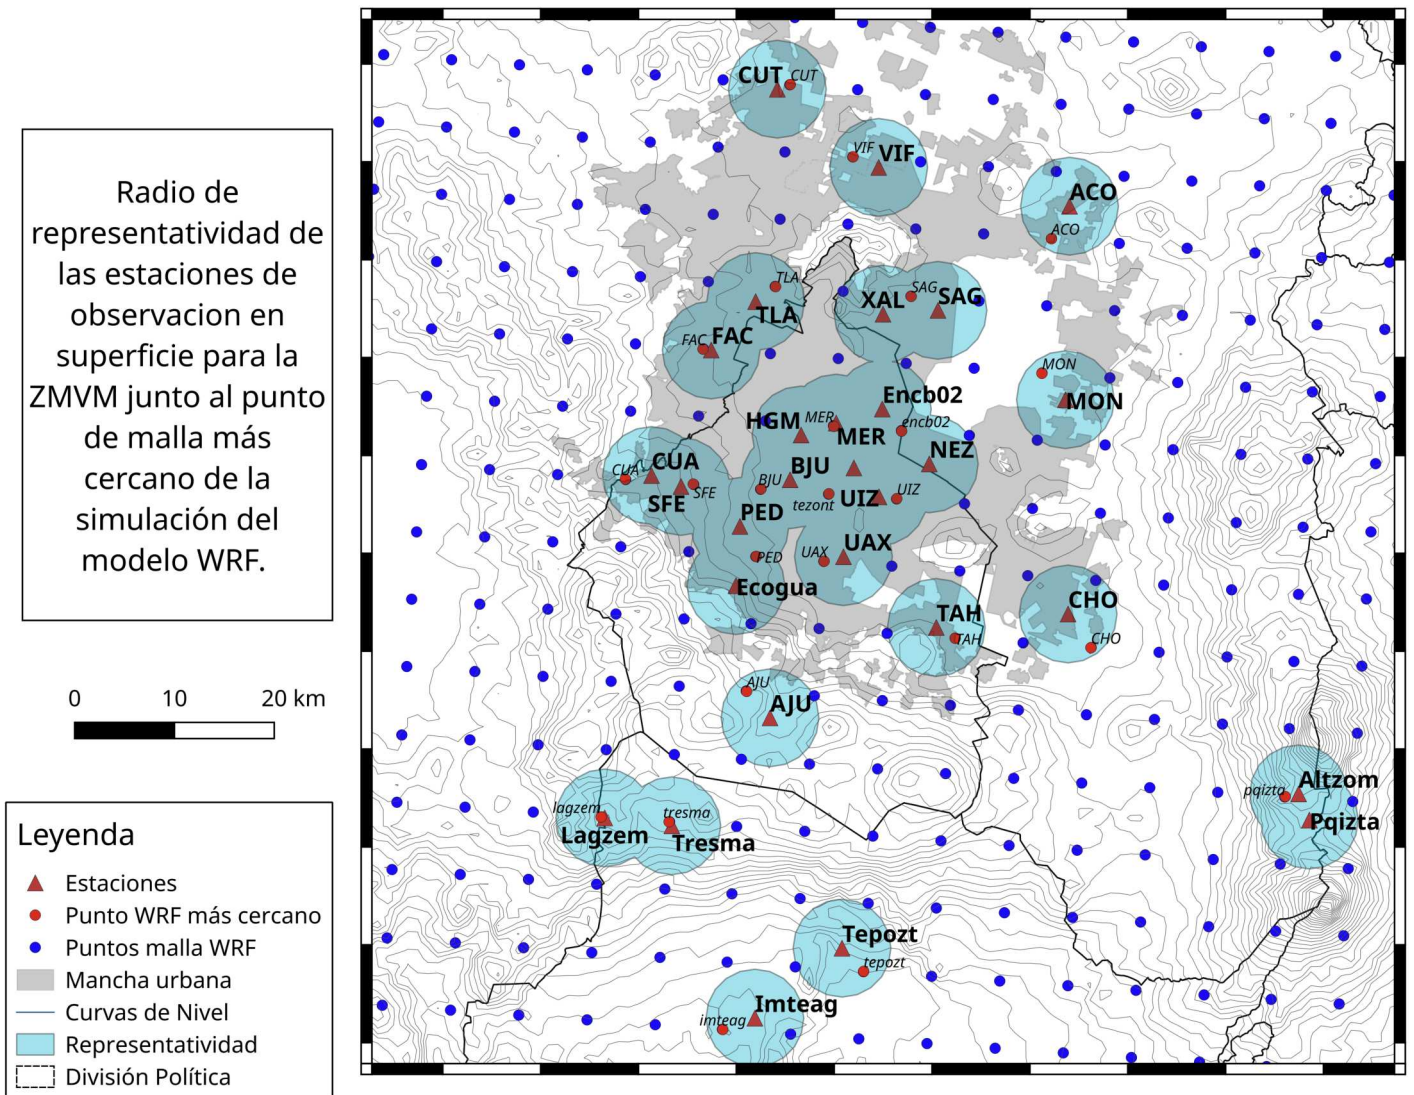


Figura 2.5: Mapa de estaciones y puntos de malla más cercanos.

cas hidrográficas del Valle de México. Dos cuencas fueron localizadas para el dominio: la Cuenca de México (22 estaciones), en donde se encuentra la mayor parte de la ZMVM, y la Cuenca del río Balsas (12 estaciones). La distribución de estaciones en cada cuenca se puede apreciar en la Figura 2.6. Para cada cuenca se tomaron todos los pares observación/pronóstico correspondientes y se calcularon las medidas de verificación como si fueran todas del mismo punto.

La distribución espacial de los errores resultantes de la verificación se analizó observando mapas con cada estación con una barra de color proporcional a la magnitud de la medida de calidad utilizada. Lo anterior se realizó con la ayuda de un sistema de información geográfica. Un ejemplo de este tipo de mapas se puede apreciar en la figura 3.8. Esto permite realizar una apreciación espacial de los errores del pronóstico a lo largo de las estaciones. Este método es similar a aquel usado en Case et al. (2008) para evaluar la diferencia entre errores de dos simulaciones distintas.

Teniendo ya los pares observación-pronóstico, fue posible realizar el procedimiento de verificación del pronóstico.

### 2.3. Verificación de pronóstico

Un esquema de verificación para dos variables continuas y una discreta fue elaborado para analizar los resultados de la simulación. Como se mencionó en el capítulo anterior, 10 diferentes criterios de verificación de pronóstico existen para evaluar la calidad de éste (tabla 1.1). De las 3 variables disponibles para la verificación podemos calcular dos tipos de datos: continuos para la temperatura y la magnitud del viento, y discretos para la precipitación.

El esquema de verificación elaborado se enfocó en evaluar la calidad de los pronósticos. Dentro de este esquema se hizo una distinción entre las medidas a utilizar de acuerdo al tipo de dato que están describiendo. A continuación se describen cada una de las métricas implementadas en el esquema.

#### 2.3.1. Datos continuos

Dos variables del tipo continuo fueron evaluadas: temperatura a dos metros y magnitud de la velocidad del viento a diez metros de superficie. Para estas variables se hizo uso de tres medidas:

- Error medio,
- Error medio absoluto y
- Error cuadrático medio.

Para facilitar la interpretación de los resultados se elaboraron también diagramas de Taylor y de cuantil condicional. Estos diagramas se hicieron para cada una de las 3 temporadas evaluadas.

#### 2.3.2. Datos discretos

La precipitación acumulada fue convertida en datos del tipo discreto al delimitar dos diferentes categorías: 1) Sin presencia de precipitación y 2) Presencia de precipitación. Pos-

teriormente se elaboraron tablas de contingencia para evaluar esta variable.

Las tablas de contingencia fueron evaluadas las siguientes medidas escalares:

- Proporción correcta,
- Puntaje de amenaza,
- Sesgo,
- Probabilidad de detección,
- Probabilidad de falsa detección y
- Razón de falsa alarma.

Para cada uno de los atributos descritos por 1.1 existe una o varias de estas medidas. Al igual que con las medidas de datos continuos, no es suficiente el uso de un solo atributo escalar para caracterizar completamente la calidad de un pronóstico. A continuación se mencionan las diferentes medidas utilizadas, junto con el atributo que describen. La nomenclatura y formulación de estas medidas se hizo siguiendo el método propuesto por Wilks (2011).

Se hizo uso también del puntaje de habilidad de Heidke y del puntaje de dependencia extrema para determinar el cambio en habilidad al pasar de una resolución a otra.

## 2.4. Análisis de sensibilidad

Los resultados de la verificación de pronóstico arrojaron resultados de la calidad para la resolución de 0.5 y 0.25 grados. Con la finalidad de responder nuestra pregunta de investigación (¿Qué tan sensible es el modelo al cambio de condiciones iniciales y de frontera?) se aplicó una prueba estadística que permitió inferir esta sensibilidad. En este caso la sensibilidad se entiende como el cambio en calidad al pasar de una resolución de C.I y de F. a otra, sin importar si el cambio fue negativo o positivo.

### 2.4.1. Estimación de intervalos de confianza.

La sensibilidad se evaluó al ver si existió un cambio entre una de las medidas de calidad obtenidas en la sección anterior al cambiar las C.I. y de F. Un ejemplo de esto es calcular el cambio del EMA entre las dos resoluciones de entrada para la simulación. Construimos nuestra hipótesis nula de tal modo que:

$$H_o : EMA_{0,5} = EMA_{0,25}, \quad (2.1)$$

$$H_a : EMA_{0,5} \neq EMA_{0,25}. \quad (2.2)$$

Para disminuir los grados de libertad del problema, se realizó la diferencia diaria del estadístico a probar para cada temporada. Esto resultó en tres series de diferencias, una para cada temporada. Ya que cada serie contenía un número de diferencias de aproximadamente 60 valores, se consideró a la muestra lo suficientemente grande para realizar inferencias estadísticas sobre esta. Nuestra hipótesis nula anterior se modificó para tomar en cuenta las diferencias, quedando de la siguiente manera:

$$H_o : \overline{(EMA_{0,5} - EMA_{0,25})} = 0, \quad (2.3)$$

$$H_a : \overline{(EMA_{0,5} - EMA_{0,25})} \neq 0. \quad (2.4)$$

Para estimar el valor que tendrá la media de las diferencias de los errores, se utilizó la aproximación tomada en Willmott et al. (1985). Esta consiste en hacer uso de una prueba no paramétrica de remuestreo con *bootstrap* para estimar los intervalos de confianza del estadístico de interés, en este caso la media. Esto fue necesario ya que la distribución que presentan los errores es desconocida. Para poder aplicar este método es necesario que las dos muestras sean independientes entre sí. Ya que cada muestra viene de simulaciones diferentes, se asumió que existe independencia entre ellas. Para evitar que los datos presentaran correlación espacial entre ellos mismos (ya que estamos tratando con puntos sobre un campo geográfico) se aplicó el método de manera individual a cada punto. Se asumió también que los datos no presentan correlación temporal entre ellos al tomar las diferencias de los errores en vez de los errores crudos.

Los intervalos de confianza utilizando el método de *bootstrap* se realizaron tomando 10,000 remuestreos con reemplazo para cada serie. Lo anterior se realizó de manera automatizada con la función *boot* del software de procesamiento estadístico R. Este método dió como resultado un histograma de la distribución empírica de la media para cada serie, como puede ser observado en la Figura (2.7). Se realizó una supervisión manual de cada histograma para descartar aquellos que no cumplieran con una distribución aproximadamente normal. Los intervalos de confianza del 95 % fueron calculados a partir de los percentiles del 95 % de estos histogramas.

Para realizar un primer análisis de sensibilidad se observó si los intervalos de confianza de la media de cada serie incluyen el 0. Si la respuesta es positiva entonces (asumiendo que  $H_o$  es verdadero), existe una gran probabilidad de que los datos se acoplen a los resultado observado.

#### 2.4.2. Diagramas de bosque

Se realizó un análisis más completo de la sensibilidad mostrada por el modelo utilizando un diagrama de bosque construido con los intervalos de confianza obtenidos en la sección anterior. Lo anterior sigue el método propuesto en Cumming (2013), donde se hace énfasis en evitar el uso de pruebas de significancia a favor de ver el tamaño y comportamiento de los intervalos de confianza.

Los diagramas de bosque se realizaron para cada una de las tres temporadas con dos errores diferentes: el EMA y el ECM tanto de la temperatura como de la magnitud de la velocidad del viento. Un ejemplo de estos diagramas de bosque se puede apreciar en la Figura 3.25.



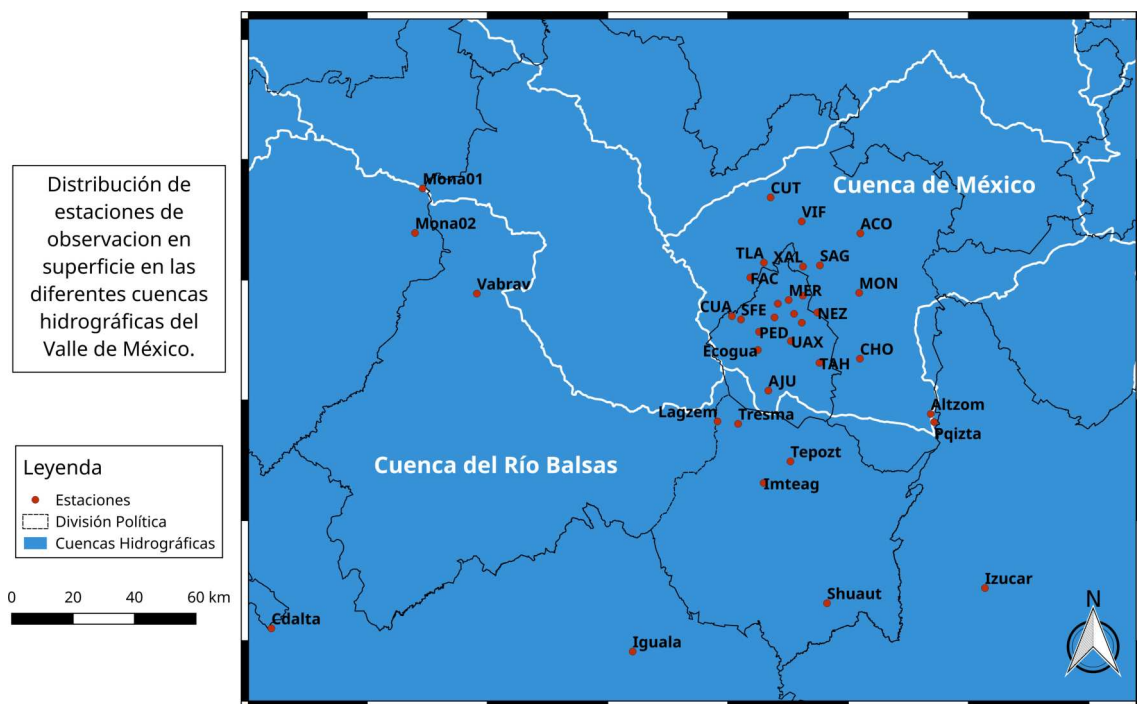


Figura 2.6: Distribución de las estaciones en la Cuenca de México y en la Cuenca del río Balsas.




Figura 2.7: Histograma de la distribución empírica resultante al usar el método de remuestreo de *bootstrap* para la media  $t^*$  de las diferencias del EMA para la estación CUA en la temporada húmeda.



## Capítulo 3

# Resultados y Discusión

Se muestran los resultados de aplicar el esquema de verificación y el análisis de sensibilidad a los 6 meses de simulación. Primero se procede a describir los resultados de calidad de acuerdo a las medidas de verificación, para posteriormente describir los resultados del análisis de sensibilidad.

### 3.1. Verificación de pronóstico

#### 3.1.1. Precipitación

Las tablas 3.1 y 3.2 muestran las tablas de contingencia para la precipitación de acuerdo a las agrupaciones de estaciones descritas en el capítulo anterior. Para esta variable se muestran únicamente los datos para la temporada de lluvias. No hay la misma cantidad de pronósticos para las dos resoluciones debido a que existían faltas en la base de datos de GFS para la resolución de 0.5, pero ya que estas faltas fueron menores al diez por ciento del total de días simulados, se considero que el efecto de estos días adicionales no agregaría un error significativo a los resultados de verificación.

Podemos apreciar que en ambas cuencas, el caso dominante es aquel en donde el pronóstico de no lluvia corresponde con la observación de no lluvia. En contraste, el valor más pequeño corresponde al pronóstico de lluvia con observación de lluvia.

La tabla (3.3) muestra los resultados de aplicar los métodos descritos en el capítulo anterior a las tablas de contingencia, igualmente para el periodo de lluvias.

Para analizar la distribución espacial a lo largo del dominio para la temporada húmeda, se realizaron 4 mapas para las métricas que se consideraron más importantes: la Figura 3.1 muestra la PC, la Figura 3.2 el PA, la Figura 3.3 el RFA y la Figura 3.4 el sesgo. Ya que únicamente las estaciones EMA del SMN cuentan con pluviometro, se omiten los puntos correspondientes a estaciones REDMET en estos mapas.

Tabla 3.1: Tabla de contingencia para la cuenca de México, temporada de lluvias.

Resolución	0.5		0.25	
	obs			
pron	si	no	si	no
si	144	458	165	448
no	613	4047	663	4178

Tabla 3.2: Tabla de contingencia para la cuenca del río Balsas, temporada de lluvias.

Resolución	0.5		0.25	
pron \ obs	si	no	si	no
	si	754	1331	687
no	2137	12375	2198	11814

Tabla 3.3: Resultados de la verificación para las tablas de contingencia, temporada de lluvias.

	Cuenca México		Cuenca Balsas	
Res	0.5	0.25	0.5	0.25
PC	0.80	0.80	0.78	0.79
PA	0.12	0.13	0.16	0.18
S	0.80	0.74	0.70	0.72
PD	0.19	0.20	0.24	0.26
PFD	0.05	0.06	0.08	0.10
RFA	0.76	0.73	0.66	0.64
PHH	0.10	0.12	0.16	0.18
PDE	0.08	0.08	0.09	0.13

El mapa de PC muestra valores bastante elevados de éste para todo el dominio. Esto es consistente con la tabla de contingencia, en donde la mayor parte de los eventos fue de “no precipitación”, algo que el modelo fue muy bueno para pronosticar. El complemento de esta medida se puede ver en el mapa de PA, que muestra un error muy grande para todo el dominio. Esto indica que para observaciones de “precipitación” el modelo no fue capaz de indicar lo mismo. Esto es congruente también con las tablas de contingencia, donde los pares de observación ‘sí’/pronóstico ‘no’ y observación ‘no’/pronóstico ‘sí’ fueron mucho más numerosos que los pares observación ‘sí’ / pronóstico ‘sí’.

El mapa de sesgo indica que las regiones con mayor sesgo son aquellas en donde la topografía es más complicada, como es el caso de las estaciones ubicadas cerca del volcán Popocatepetl, al sureste del dominio. Los puntos ubicados en la parte central del dominio, donde la topografía es más plana, muestran el menor sesgo de todo el dominio.

El mapa de RFA muestra también un error fuerte en todo el dominio, lo que indica que el modelo es muy propenso a indicar que habrá precipitación cuando no hay. Esto también es consistente con las tablas de contingencia observadas.

Así mismo la tabla 3.3 muestra que la PD es muy baja para ambas cuencas. Similarmente el PHH y el PDE muestran valores muy bajos, lo que nos permite concluir que el modelo tiene una calidad de pronóstico muy baja para la precipitación.

Entre las dos resoluciones se observa que hay cambios muy pequeños al pasar de 0.5 a 0.25. Lo anterior sugiere que el error es debido a la elección de parametrizaciones y resolución de modelación, mostrando posiblemente una sensibilidad muy baja ante cambio en las C.I. y de F., aunque cabe destacar que también es posible que estas condiciones no esten cambiando notablemente al pasar de una resolución a otra.

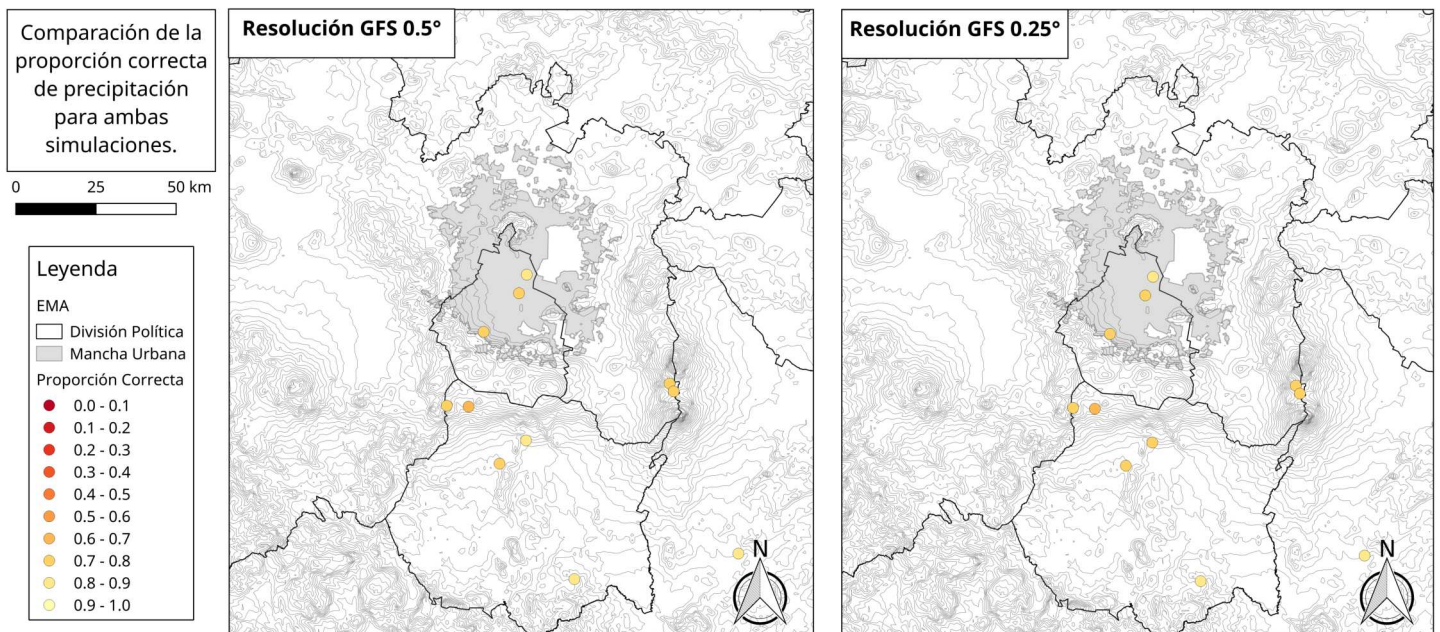


Figura 3.1: Mapas de Proporción Correcta (PC) para la temporada húmeda.

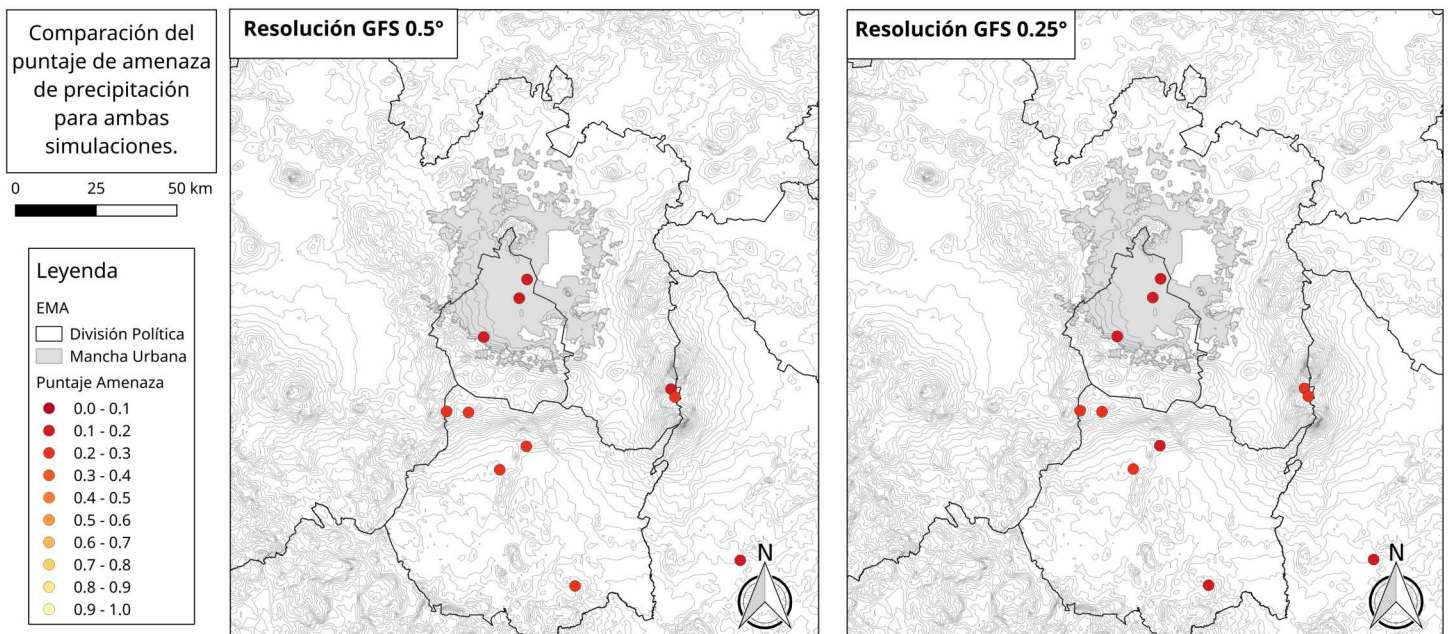


Figura 3.2: Mapas de Puntaje de Amenaza (PA) para la temporada húmeda.



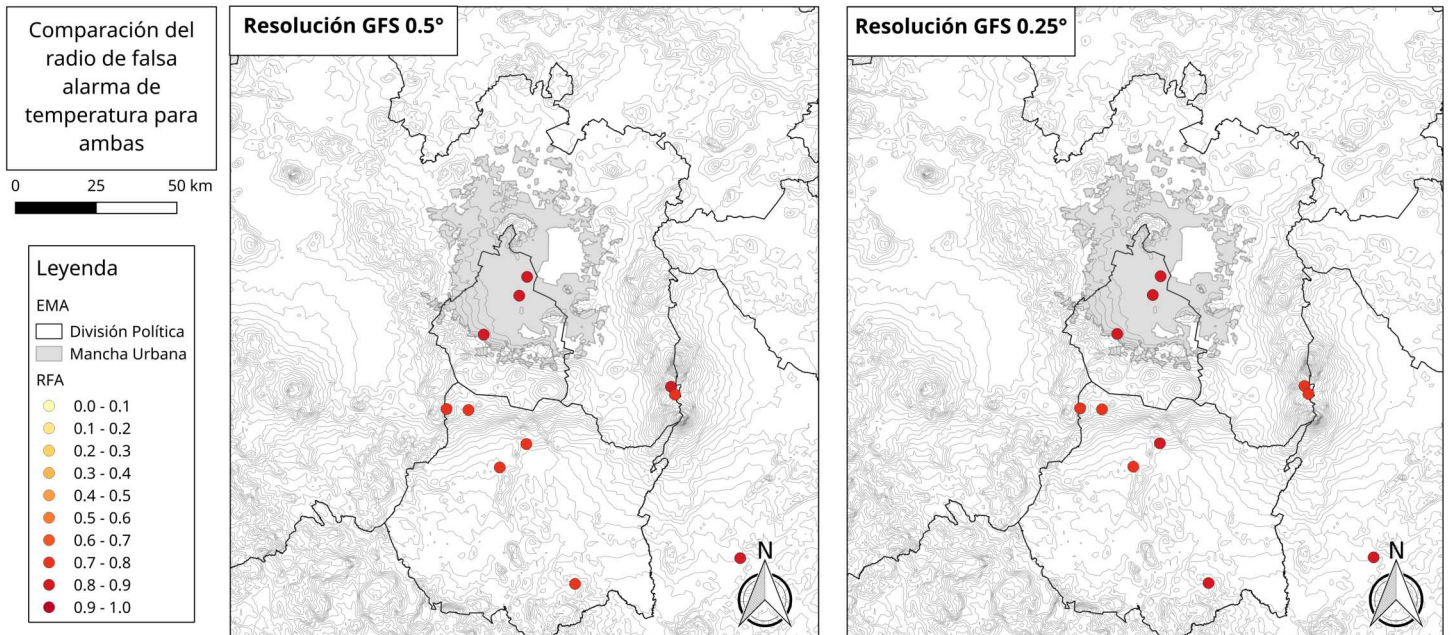


Figura 3.3: Mapas de Razón de Falsa Alarma (RFA) para la temporada húmeda.

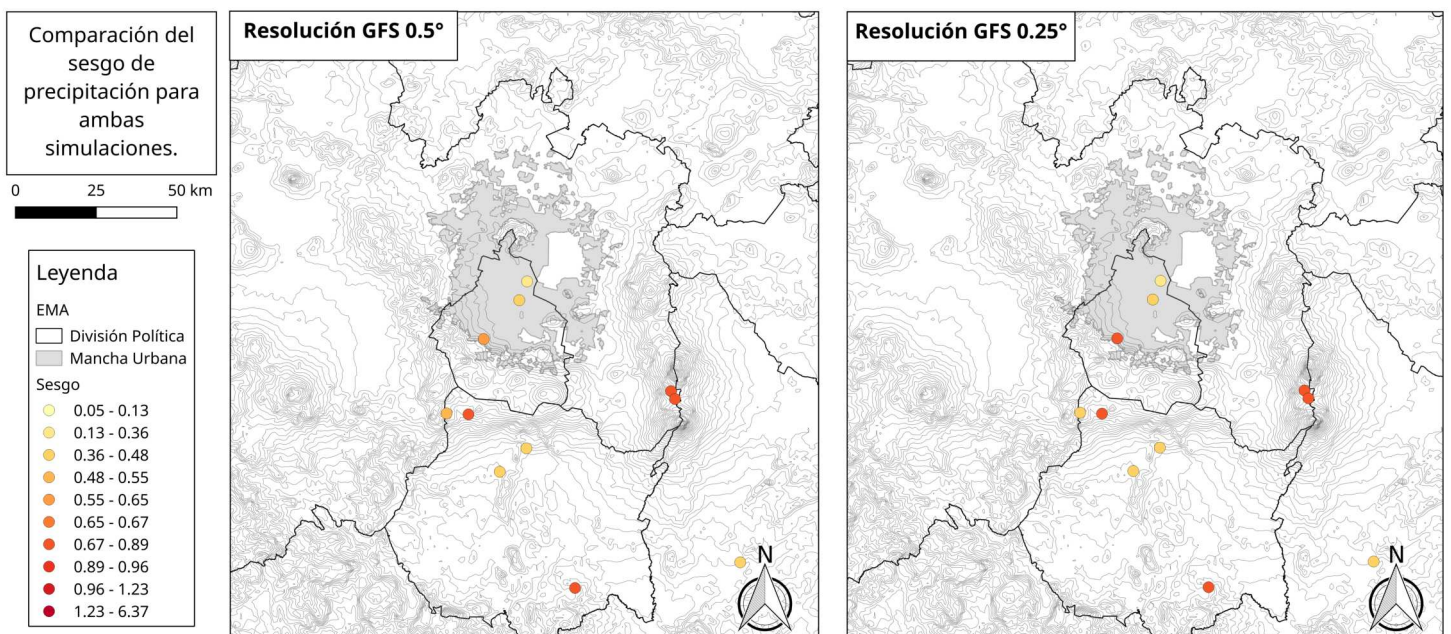


Figura 3.4: Mapas de Sesgo para la temporada húmeda.

### 3.1.2. Temperatura

Los diagramas de Taylor calculados para la temperatura se muestran en las Figuras 3.5 a 3.7. En estos se muestran los resultados de verificación para las estaciones contenidas en la Cuenca de México y en la Cuenca del Río Balsas. Mientras más cercano estén los puntos a el punto verde con correlación de 1 y desviación estándar de 1, mejor será el pronóstico.

Los resultados para las tres temporadas son muy similares, con los puntos mostrando un coeficiente de correlación que va del 0.8 al 0.9, el cual es un valor bastante elevado. En particular para la temporada de secas frías este coeficiente llega a valores cercanos a 0.95, sobre todo para las estaciones de la Cuenca de México. Esto nos dice que cuando las temperaturas observadas son relativamente altas, las temperaturas del modelo son altas también, y viceversa para las temperaturas bajas.

Por otro lado, si analizamos la posición radial de los puntos para ver la distribución de la desviación estándar a lo largo de las estaciones podemos ver algunas diferencias entre estas. En la temporada de lluvias los puntos caen principalmente en valores más grandes de desviación estándar, indicando que el pronóstico constantemente sobreestima la amplitud de las observaciones. Esta situación se invierte en las temporadas secas, donde los puntos principalmente caen en valores más pequeños de desviación estándar, indicando que los pronósticos comúnmente subestiman las observaciones.

Cabe destacar que al comparar entre simulaciones con diferentes condiciones iniciales, no se observan cambios importantes. Casi siempre los puntos rojos se encuentran muy cercanos a los azules, con pocas instancias en donde se pueda apreciar un cambio entre los dos colores. La poca diferencia entre estos puntos podría indicar que la sensibilidad del modelo ante diferentes resoluciones de C.I. y de F. no es muy fuerte para el Valle de México, algo que será explorado más a fondo en la siguiente sección.

Estos dos resultados (correlación alta con fuerte sesgo) nos dicen que la simulación muestra una buena calidad para representar el aumento o disminución de las temperaturas a lo largo del día, pero no es bueno para estimar adecuadamente la magnitud de estos valores. Este fenómeno ocurre tanto para las estaciones del Valle de México como para aquellas localizadas en zonas con topografía más compleja. Tomando esto en cuenta podemos inferir que el problema es generalizado para el modelo con la configuración usada.

Un resultado que apoya esta observación está dado por los círculos de error cuadrático medio centrado constante (dibujados en verde en los diagramas). En la temporada de lluvias vemos que este error tiene valores relativamente altos, que van del 0.4 al 0.6, mientras que para las temporadas secas va del 0.3 al 0.6. Esto nos dice que en general el modelo muestra un poco más de calidad para pronósticos de las temporadas secas que de la temporada de lluvia, aunque para ambas temporadas el error mostrado es relativamente alto para todas las estaciones.

Los mapas de las Figuras 3.8 a 3.10 muestran la distribución espacial de los errores a lo largo del dominio, con colores menos rojizos mostrando el menor error, y colores más rojos mostrando mayor error. Se observa que los menores errores medios cuadráticos se concentran en la parte noreste de la Ciudad de México, incluyendo algunas estaciones del Estado de México. En contraste, las estaciones en el noroeste/centro de la ciudad muestran fuertes valores de EMC, junto con las estaciones fuera del Valle de México.

El mapa de errores medios absolutos de la Figura 3.9 muestra una historia similar al de los EMC, aunque en este caso los puntos con menos errores son todos aquellos localizados en la zona norte/centro de la Ciudad de México, estando los errores más grandes en las



afueras de la ZMVM. La magnitud de los errores para esta región es del rango de 1 a 2 grados centígrados para todas las temporadas.

El análisis del EMA nos dice que la simulación es buena para aproximar las magnitudes de las temperaturas en el Valle de México, pero el EMC nos dice que no es adecuada para simular los valores extremos, sobre todo en la región noroeste del Valle.

El análisis del mapa del error medio, Figura 3.10, muestra que en la región norte/central del valle las temperaturas son constantemente subestimadas por el modelo. Esto va de acuerdo a los diagramas de Taylor, que indicaban que para las temporadas secas la mayor parte de los puntos subestimaba la variabilidad de las observaciones.

Para analizar más a fondo los errores de los puntos del norte y centrales, se escogieron dos estaciones para observar los diagramas cuantil-cuantil y las series de tiempo: la estación de la Escuela Nacional de Ciencias Biológicas 02 (Código encb02) y la estación Acolman (Código ACO). Las series de tiempo se pueden ver en la Figura 3.11 para ACO y en la Figura 3.12 para Encb02; y los diagramas cuantil en la Figura 3.13 para ACO y en la Figura 3.14 para Encb02. Los códigos de tres letras *SEC*, *HUM*, *SEF* hacen referencia a la temporada seca cálida, seca fría y húmeda, respectivamente. La estación ACO se encuentra al norte del Valle de México, en la región donde el EMC presentaba menores valores. En cambio, la estación Encb02 se encuentra en el norte/centro, la región con elevados valores de EMC.

La serie de tiempo del punto ACO muestra que los pronósticos están muy bien correlacionados con las observaciones, manteniendo el mismo ciclo diurno. Sin embargo, para las temporadas secas se puede ver que los pronósticos tienen magnitudes más pequeñas que las observaciones, y en la temporada húmeda los pronósticos son constantemente de mayor magnitud que las observaciones. Esto va de acuerdo con lo visto en el digrama de Taylor analizado al inicio de esta sección. La situación es la misma para ambas resoluciones, sugiriendo que en esta región la sensibilidad de la simulación ante C.I. y de F. es muy baja.

Los diagramas cuantil-cuantil del punto ACO muestran también este comportamiento. En los meses de secas el pronóstico subestima constantemente las temperaturas, mientras que en la temporada húmeda se subestiman las bajas temperaturas y se sobreestiman los extremos cálidos. La temporada húmeda muestra el mejor desempeño del pronóstico en temperaturas cercanas a los 20 grados centígrados. Entre resoluciones hay cambios pequeños, sin notar una mejoría aparente entre los pronósticos. Los valores de nitidez, representados por qué tan *desparramado* está el histograma en los diagramas, parecen ser constantes también, con una pequeña tendencia del pronóstico de 0.25 de ser un poco más concentrado hacia valores centrales.

La situación cambia al analizar la serie de tiempo del punto Encb02 al mostrar pronósticos que subestiman siempre la observación. Esto es consistente con lo observado en la distribución del EM, que mostraba fuertes valores negativos en esta región. Al comparar las dos resoluciones no se aprecia un cambio fuerte, lo que sugiere que para esta región la sensibilidad del modelo ante CI también es baja.

Al observar los diagramas cuantil-cuantil para este punto se observa también una subestimación de los valores de temperatura. Esta es constante a lo largo del año, siendo un poco menos marcada en los extremos derechos de la temporada de lluvias. Entre resoluciones la situación es la misma, sin que se aprecie un cambio fuerte entre estos. La nitidez del modelo tiende a centrarse en valores de temperaturas relativamente bajas, de 10 a 15 grados centígrados para ambas resoluciones.




Figura 3.5: Diagrama de Taylor para la variable temperatura, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).

Para este punto (Encb02) la correlación entre las dos series es muy buena, pero el modelo no parece ser capaz de representar los procesos de superficie que ocasionan una subida en la temperatura. Ya que esta región es de las más urbanizadas en el Valle de México podemos pensar que la isla de calor urbana sea causante de las altas temperaturas en esta zona. Este es un fenómeno estudiado en anterioridad por Jauregui (1997).

El que no hubiera un cambio fuerte entre las resoluciones para modelar este fenómeno sugiere que el problema está en la representación de uso de suelo y de parametrizaciones de superficie usadas para la simulación. Este es un problema común al usar bases de datos de uso de suelo no actualizadas, como ha sido estudiado por López-Espinoza et al. (2012).

### 3.1.3. Magnitud de la velocidad del viento

Al igual que con la temperatura, los diagramas de Taylor calculados para la magnitud de la velocidad del viento se muestran en las Figuras 3.15 a 3.17. En este caso basta con hacer una observación rápida de los tres diagramas para observar que el modelo muestra un error muy grande para simular tanto la correlación como la variabilidad de las observaciones.

En la temporada de lluvias los resultados muestran una correlación con rango de 0 a 0.4, valor considerado como bajo. Esto indica que la simulación no representa adecuadamente los aumentos y disminuciones de la magnitud del viento a lo largo del día. Los puntos caen tanto en valores mayores y menores a la desviación estándar de la muestra, en donde las estaciones CuBal parecen subestimar la variabilidad de los datos y las estaciones CuMeX la sobre estiman. Lo anterior sugiere que el error podría estar asociado a la distribución espacial de los accidentes orográficos del dominio.




Figura 3.6: Diagrama de Taylor para la variable temperatura, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).




Figura 3.7: Diagrama de Taylor para la variable temperatura, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).

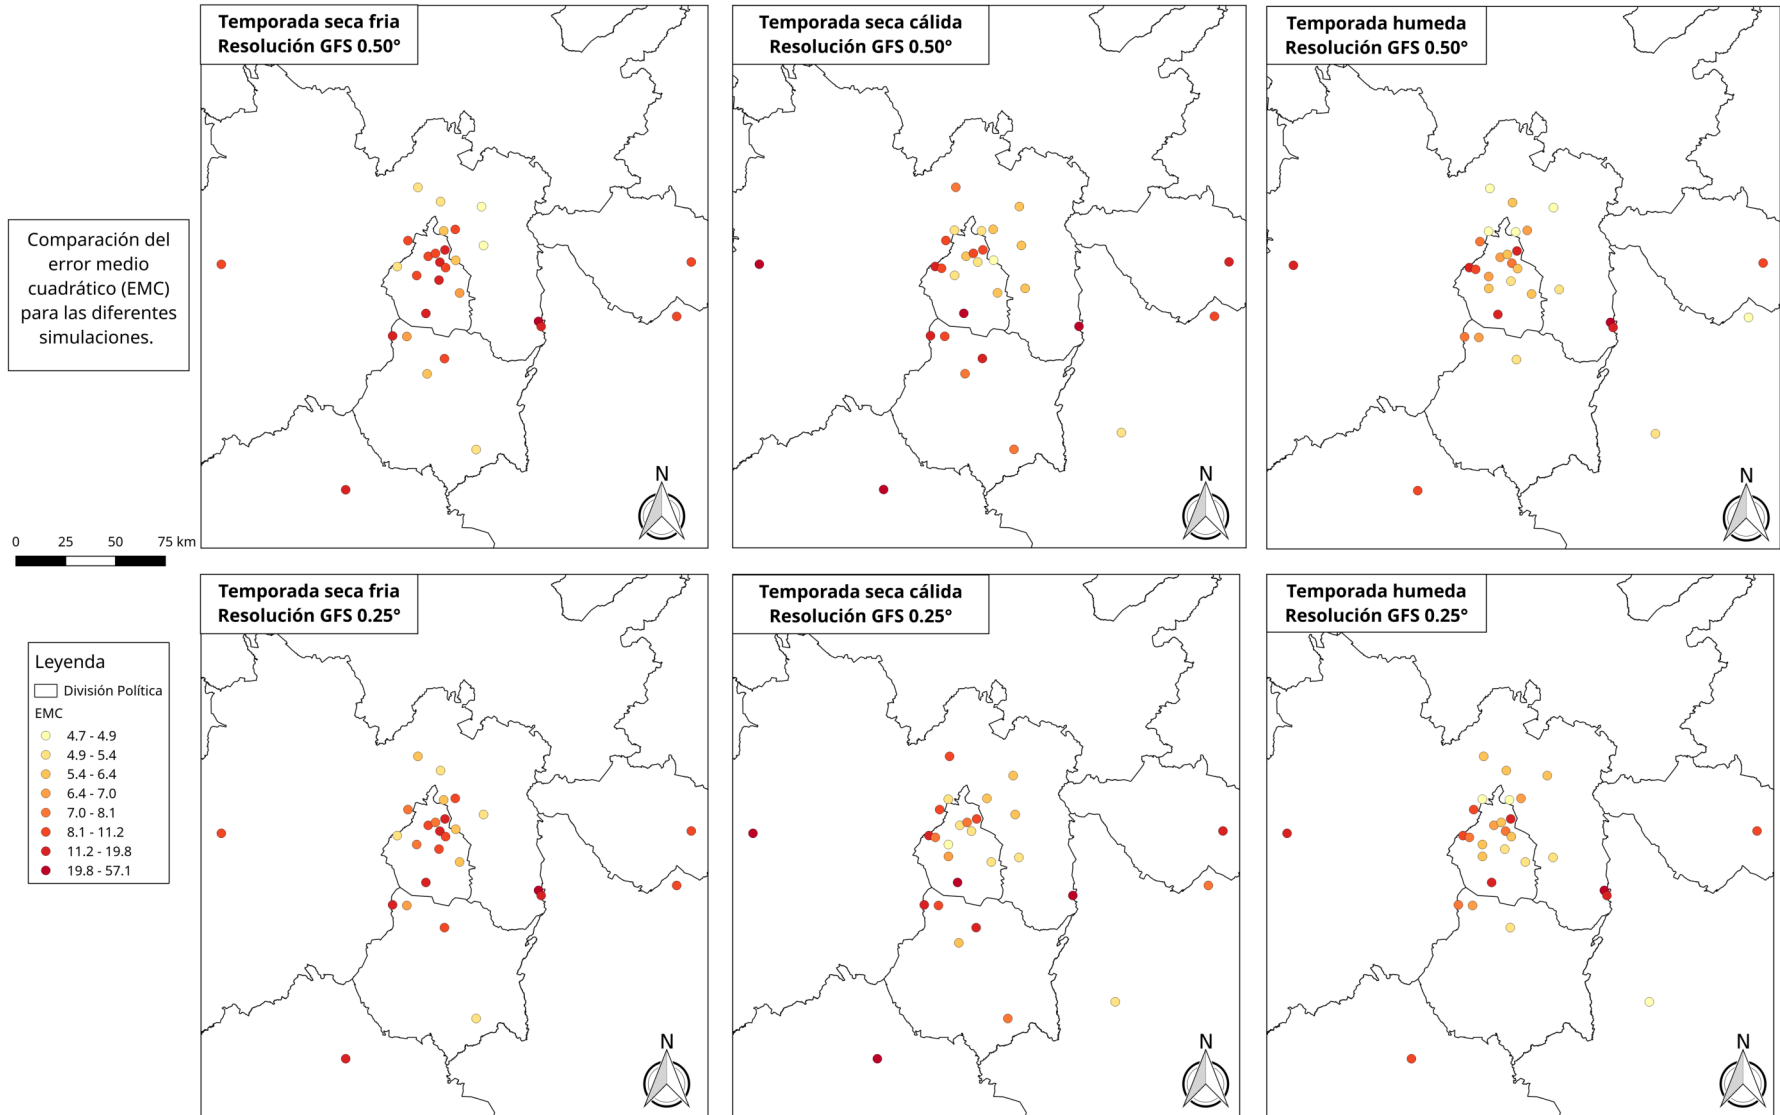


Figura 3.8: Comparación del error cuadrático medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación.

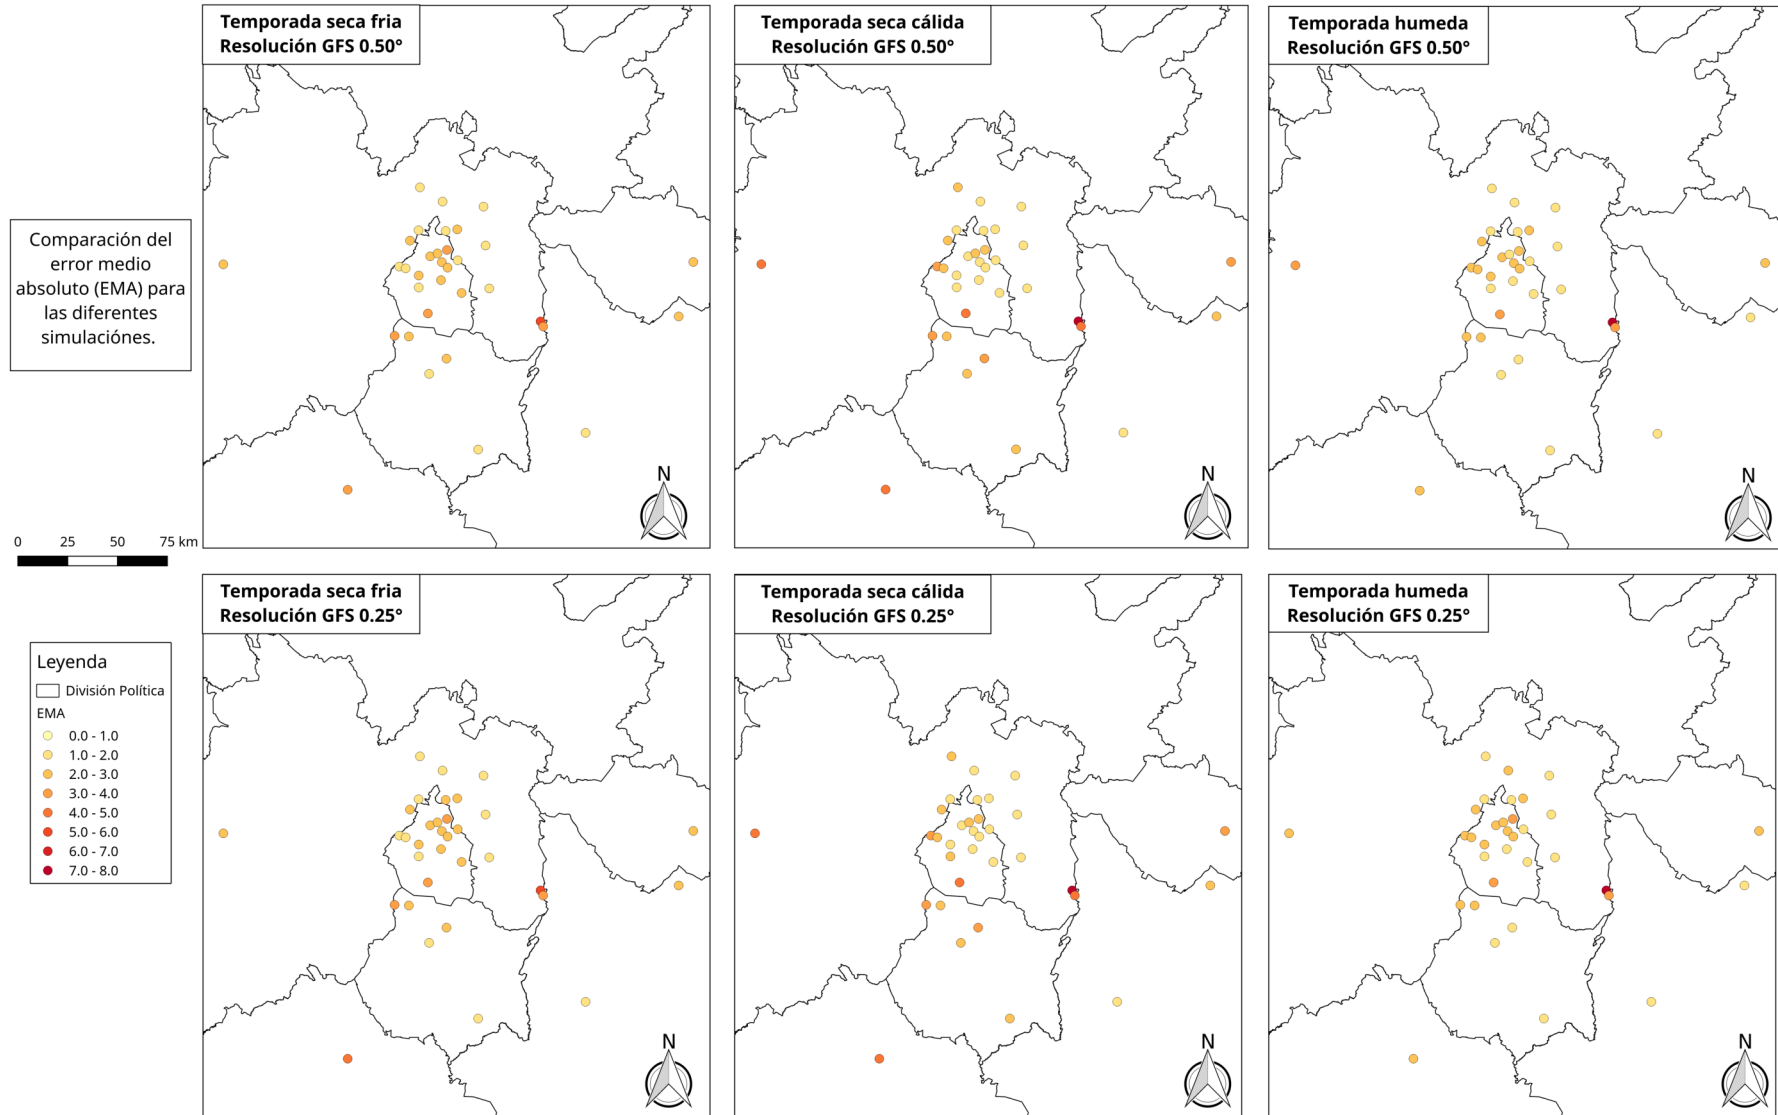


Figura 3.9: Comparación del error medio absoluto para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación.

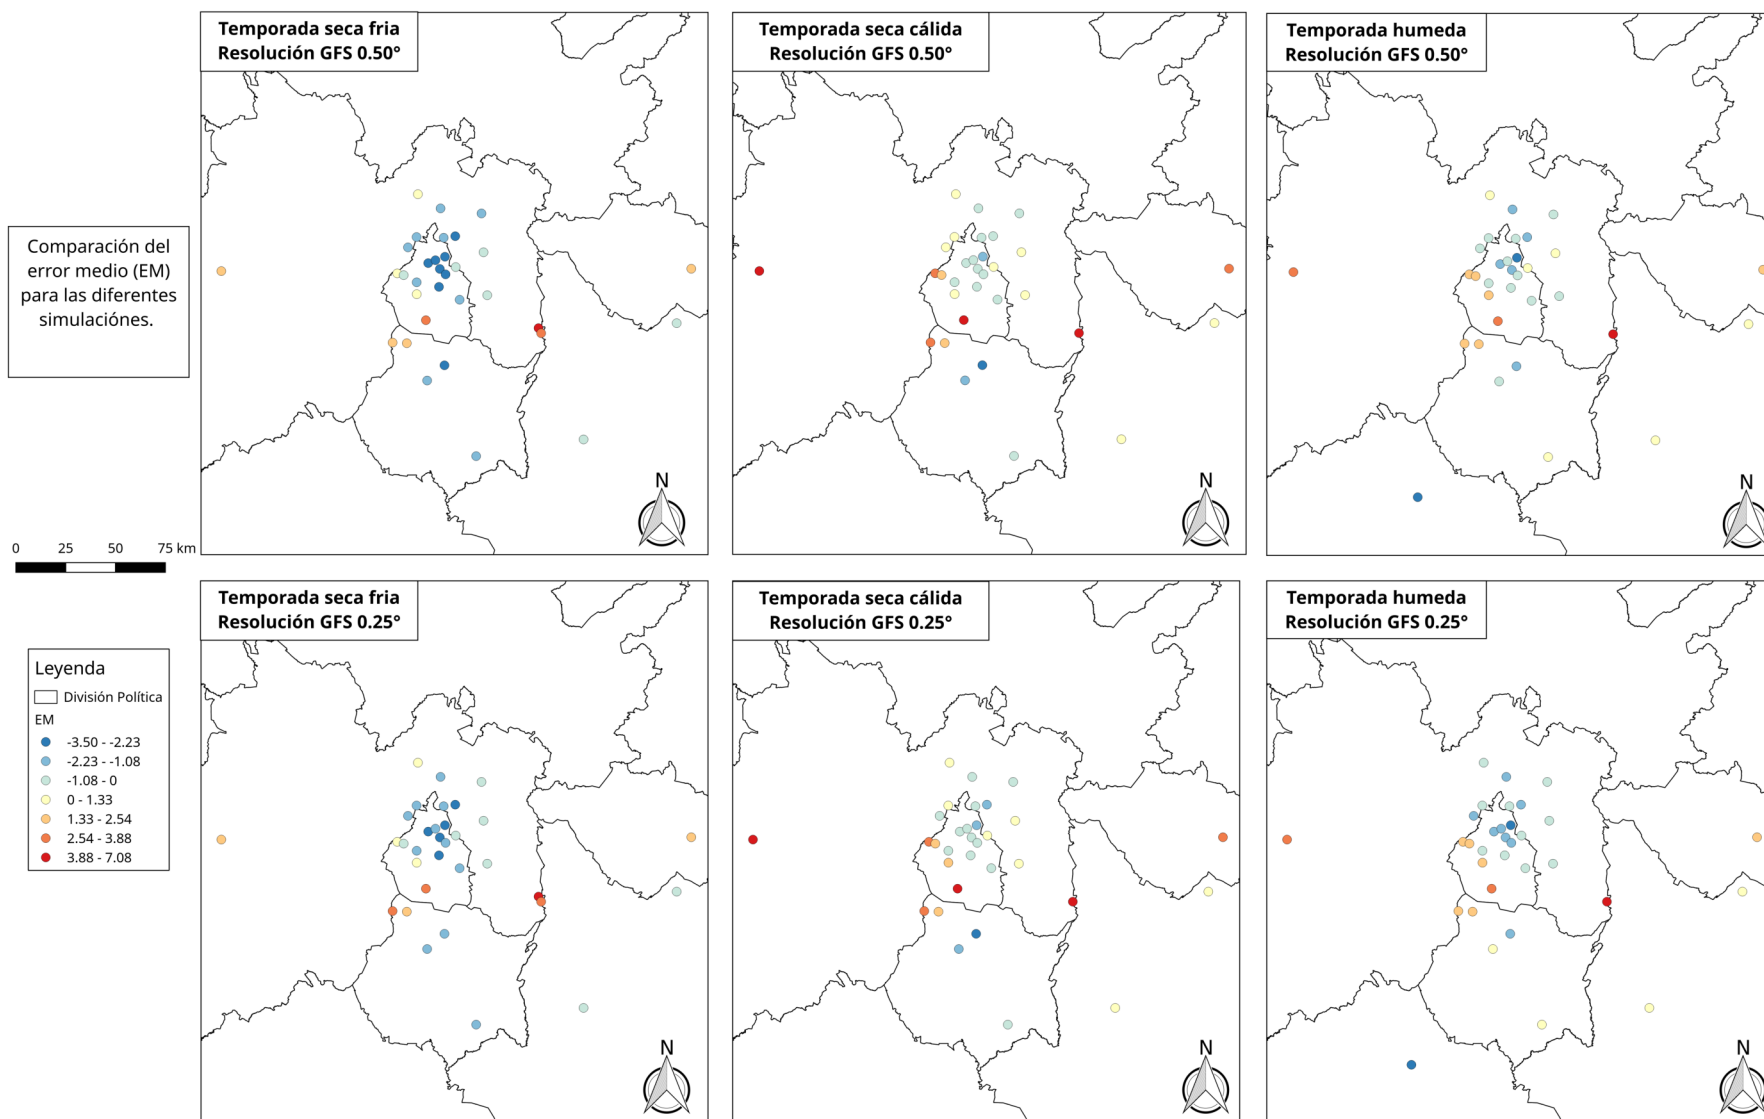


Figura 3.10: Comparación del error medio para la variable temperatura a lo largo de las temporadas analizadas para el dominio de simulación.



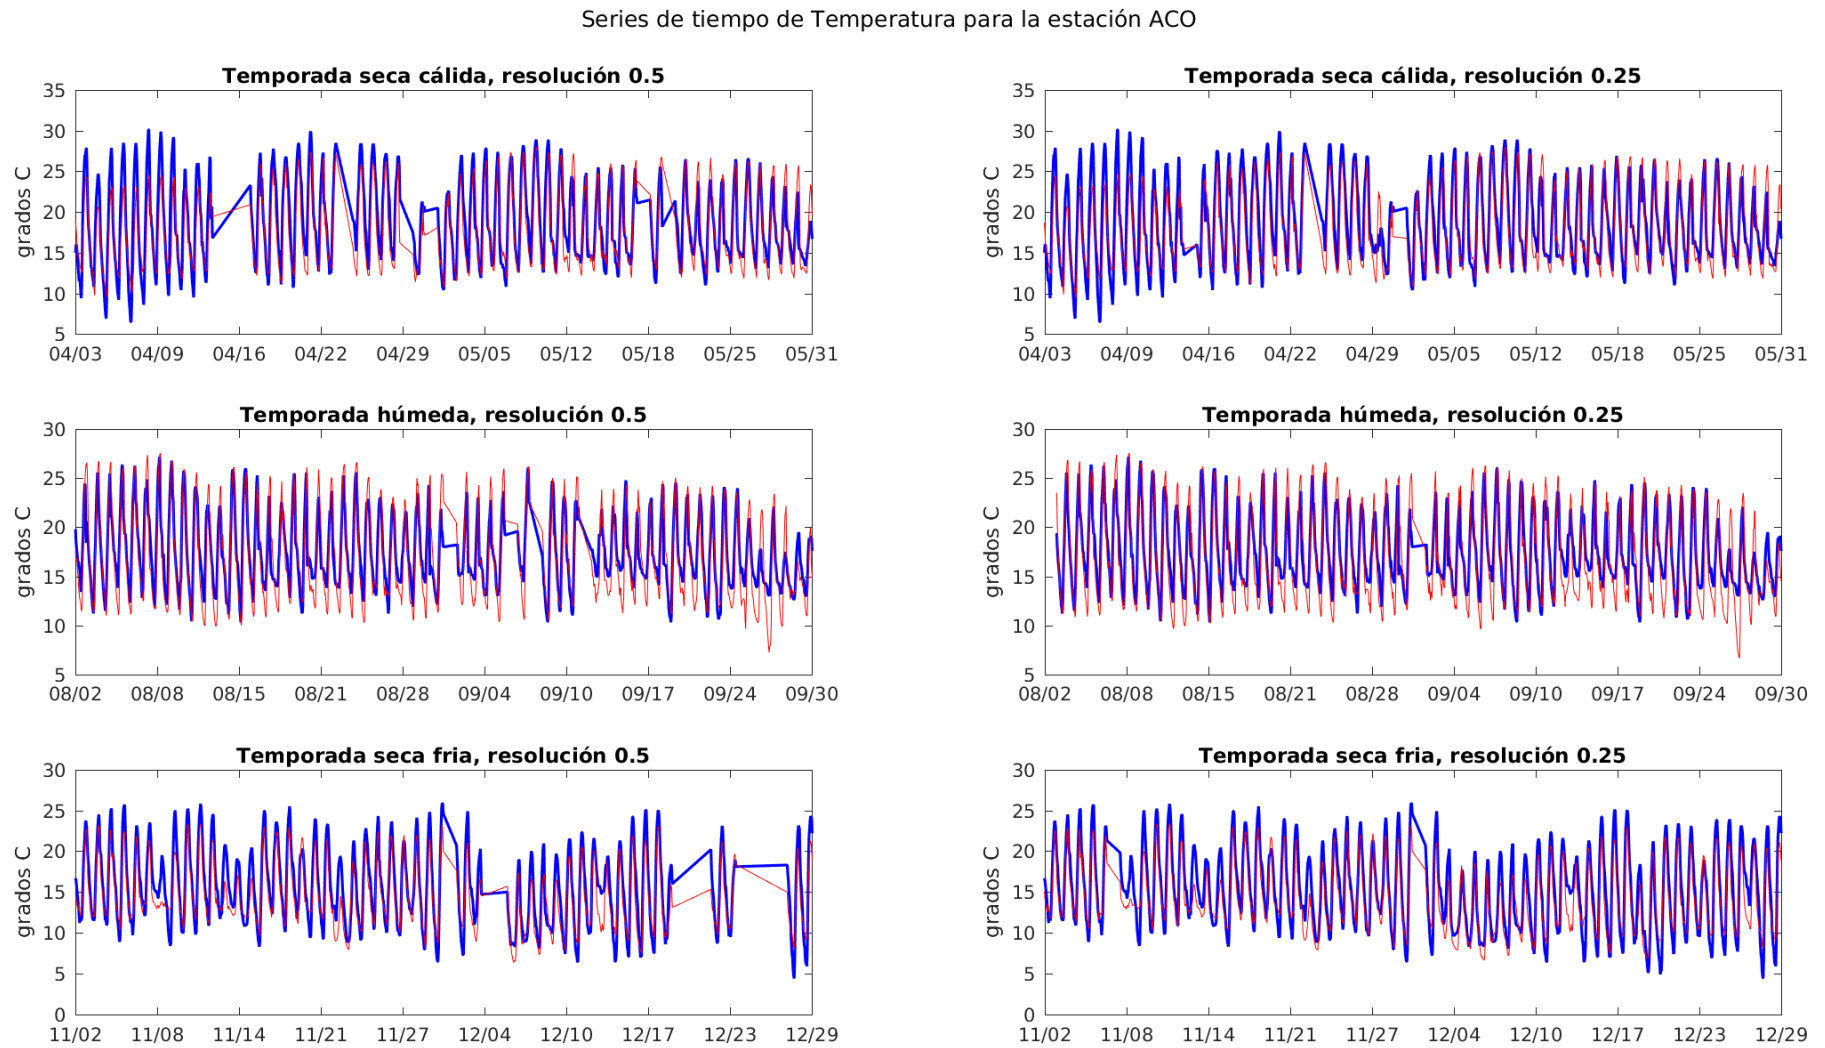


Figura 3.11: Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Acolman.

Series de tiempo de Temperatura para la estación encb02

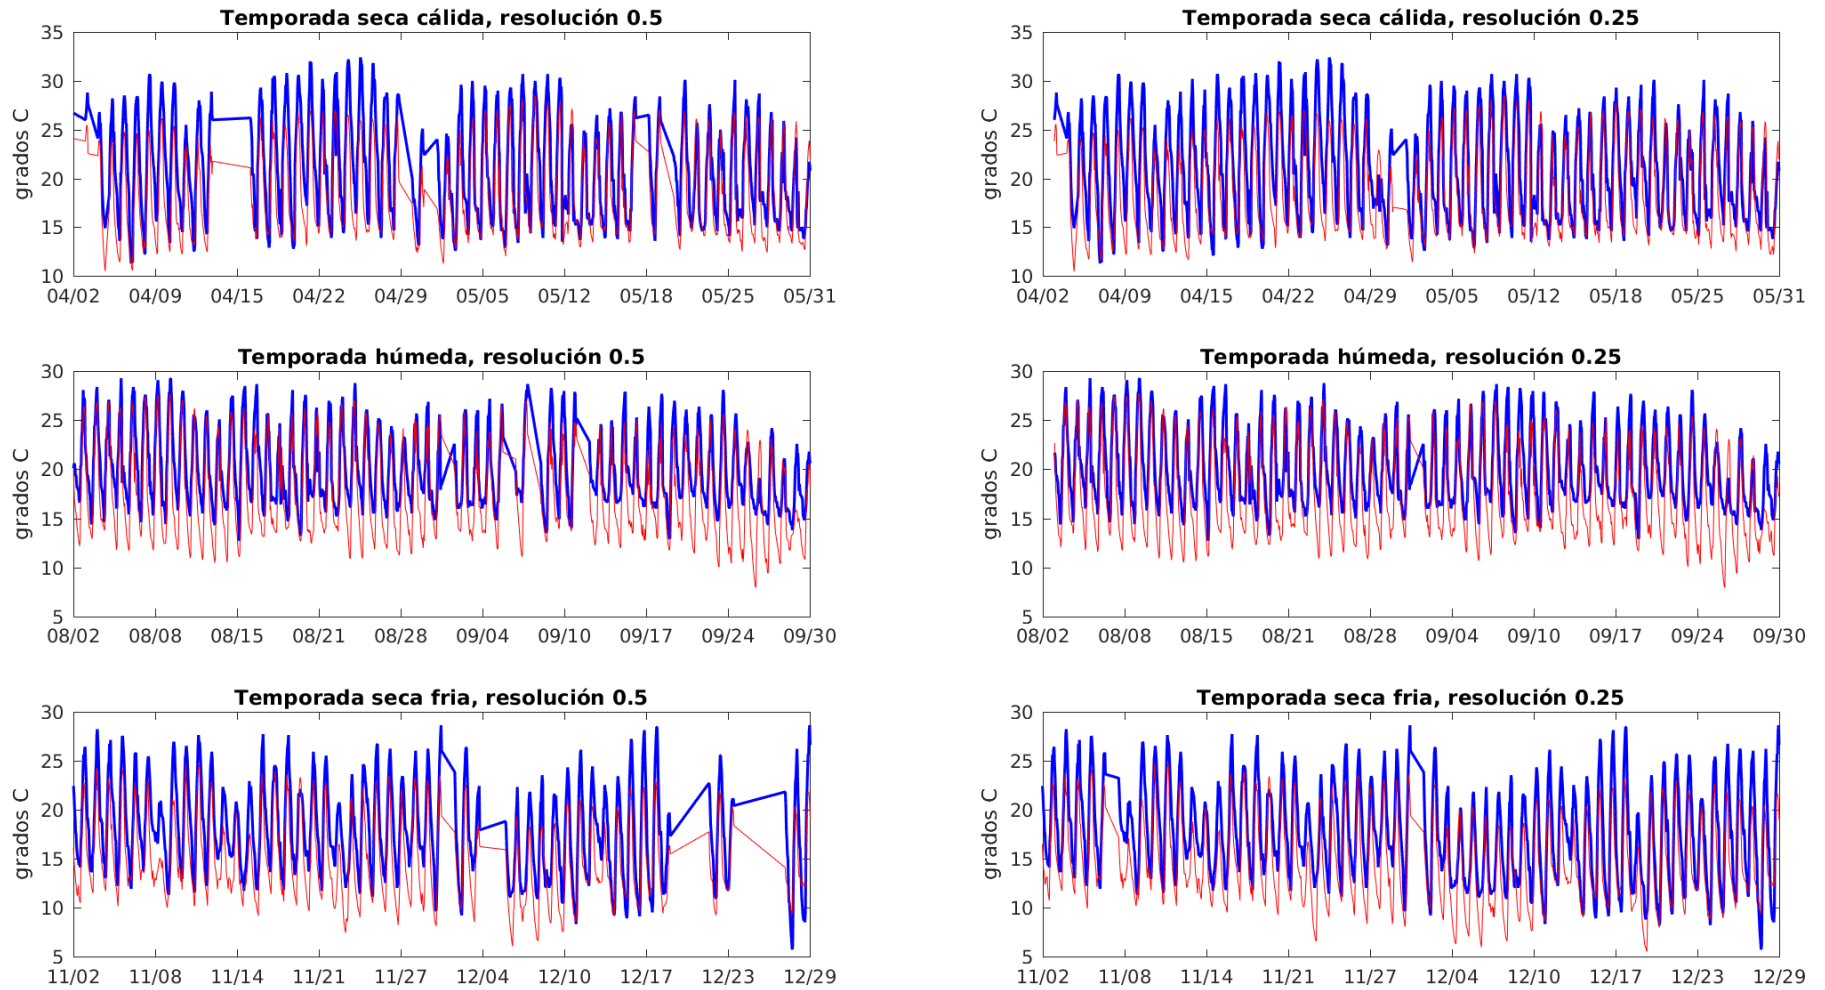


Figura 3.12: Serie de tiempo de temperatura mostrando las observaciones en azul y el pronóstico en rojo para la estación Escuela Nacional de Ciencias Biológicas 2.



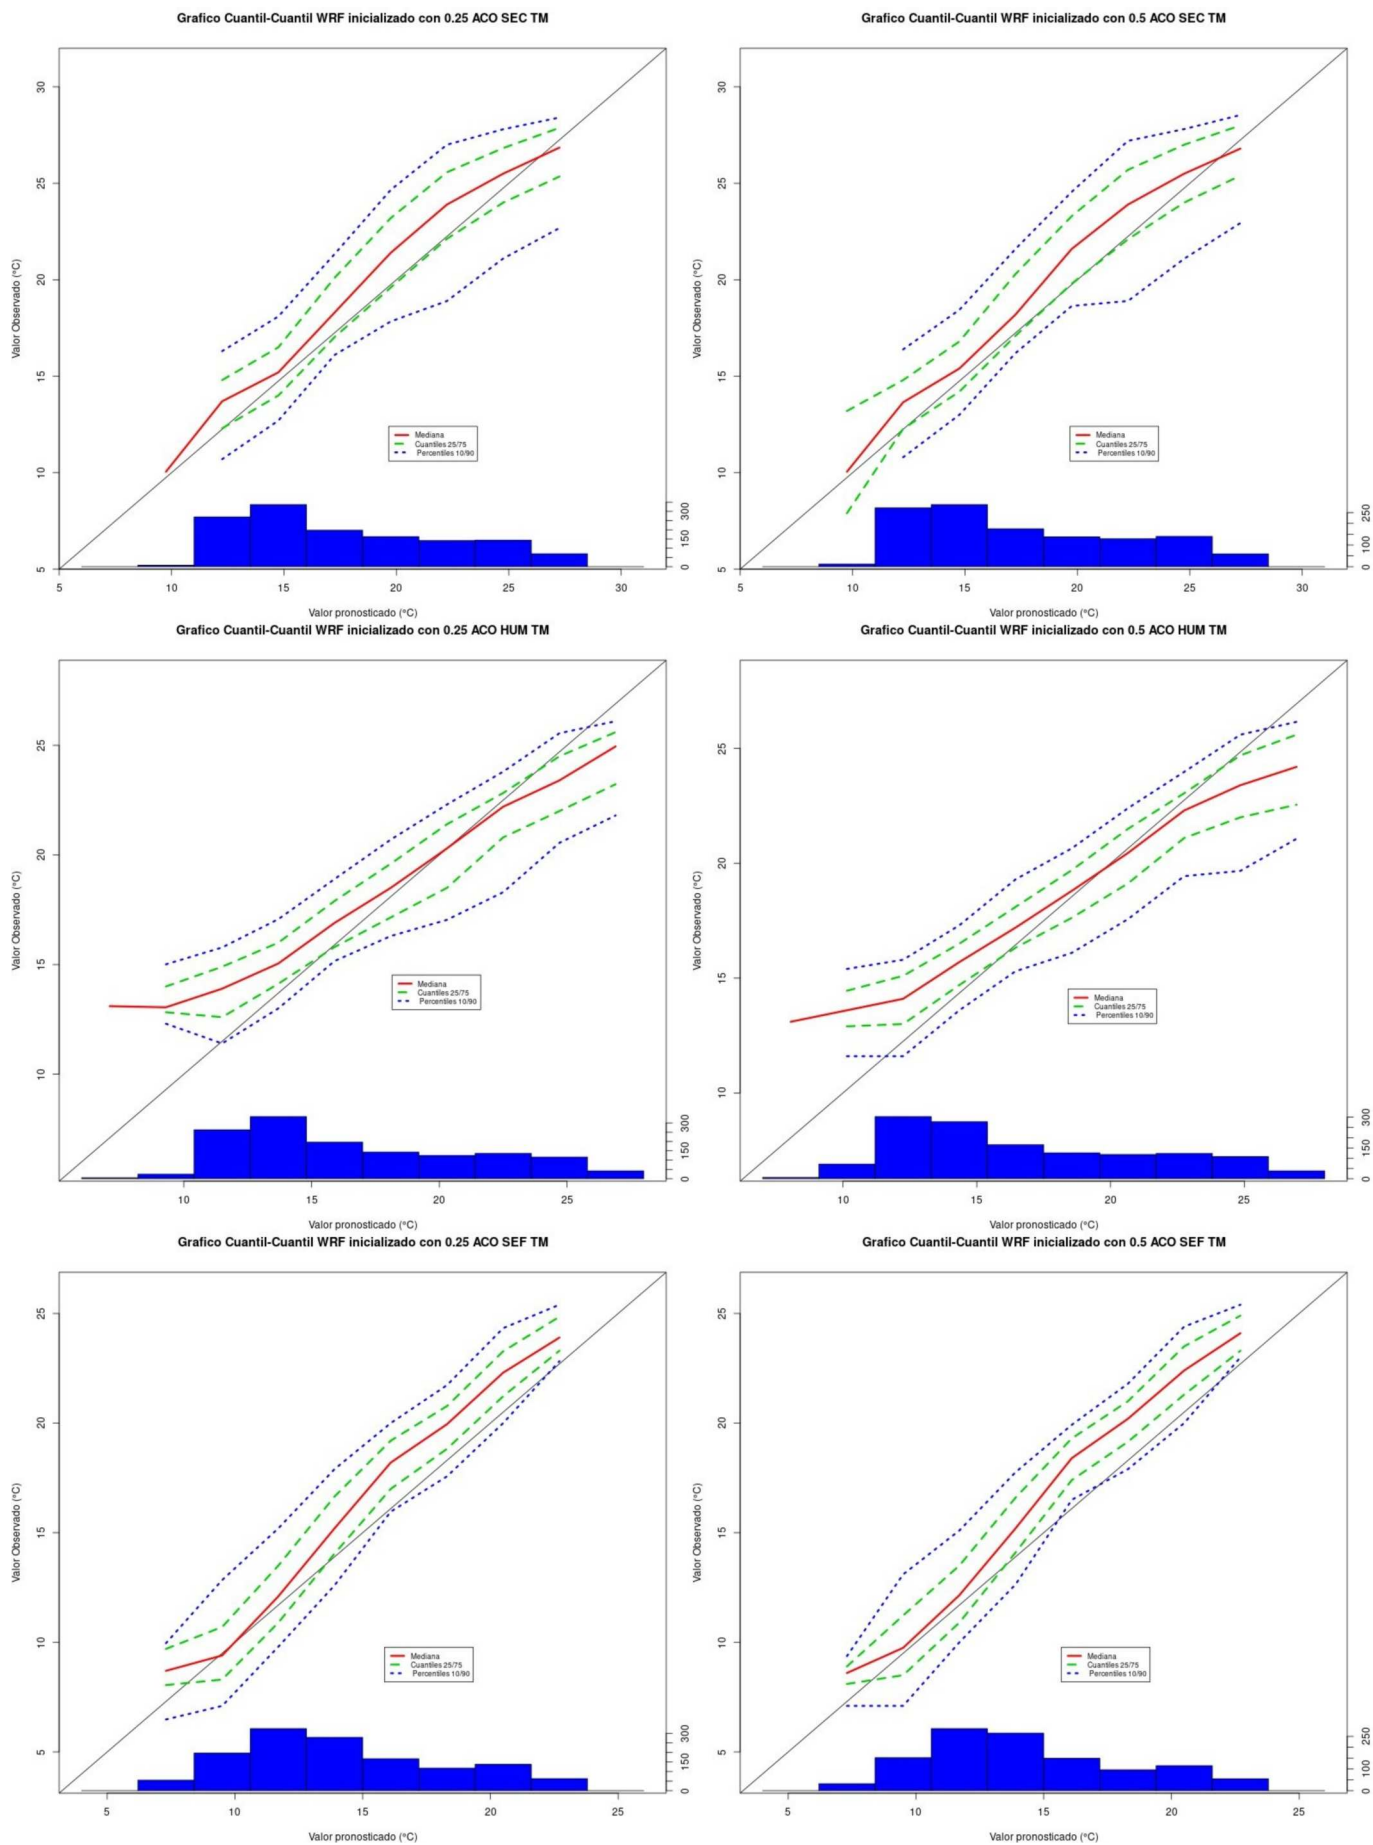


Figura 3.13: Diagrama cuantil-cuantil para la temperatura en la estación Acolman.

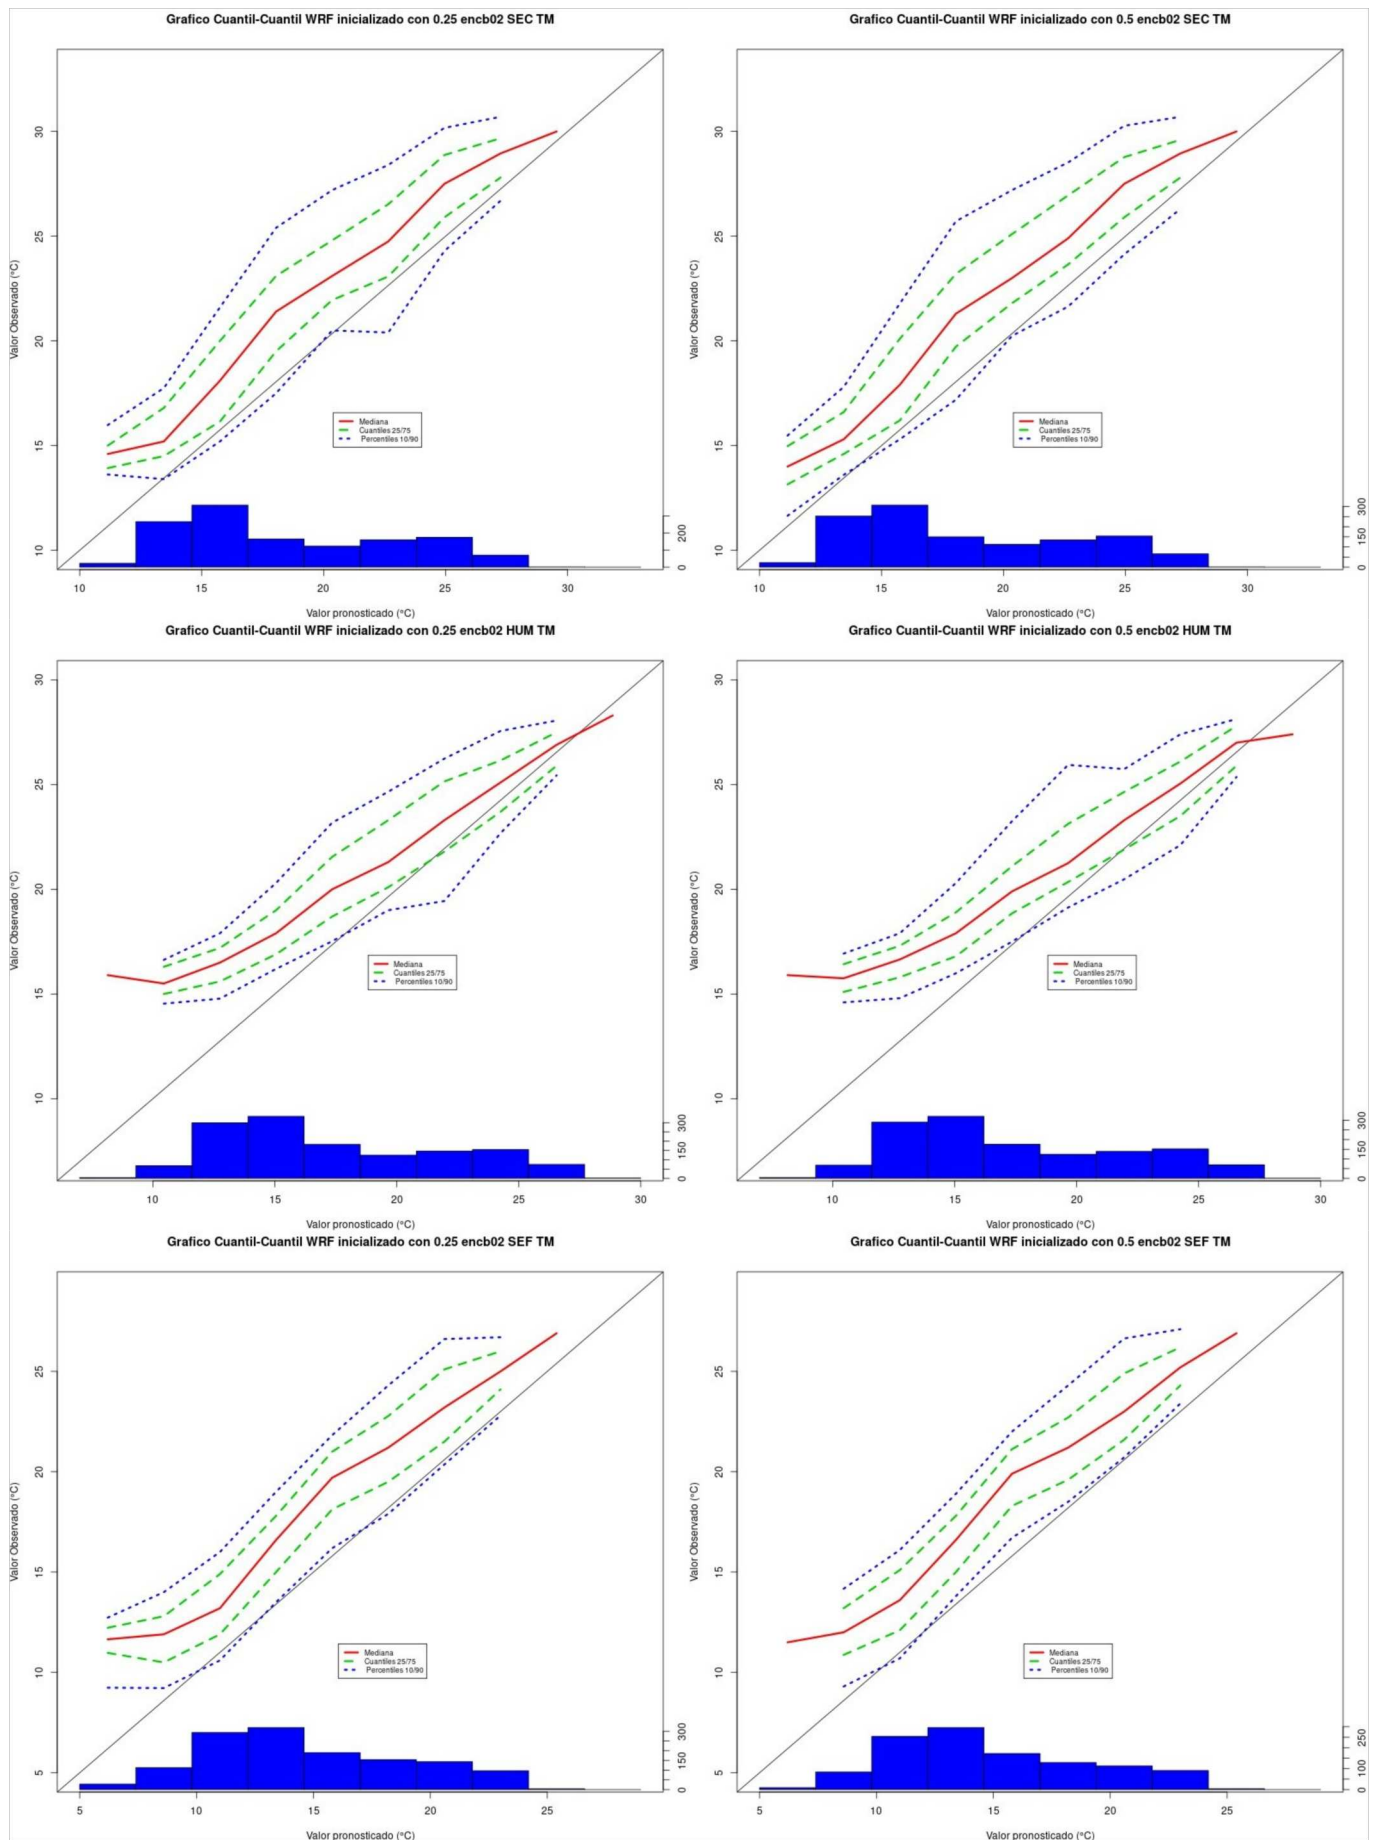


Figura 3.14: Diagrama cuantil-cuantil para la temperatura en la estación Encb02.

La temporada de secas cálidas muestra una distribución de puntos similar a la temporada de lluvias, con la diferencia de que el rango del coeficiente de correlación va de 0.2 a 0.4, mostrando una pequeña mejora con respecto de la temporada de lluvias. Las estaciones CuBal también subestiman la variabilidad, mientras que las CuMex las sobre estiman.

La temporada de secas frías es la que muestra una mayor diferencia en el diagrama de Taylor. En esta las estaciones están esparcidas en una región mayor de correlaciones y desviaciones estandar. El coeficiente de correlación va de valores ligeramente negativos hasta 0.7, el cual es el rango más amplio de las tres temporadas. Al igual que las otras dos temporadas, las estaciones CuBal caen por debajo de la desviación estándar de la muestra, mientras que las CuMex caen por encima. El que las tres temporadas muestren este patrón espacial de sub y sobre estimación sugiere que este error es indiferente ante variaciones estacionales del patrón de vientos, y se asocia a fenómenos locales de mesoescala, como pueden ser brisas de valle montaña (Jazcilevich et al., 2005).

En cuanto a la sensibilidad del modelo podemos observar una diferencia más grande que para la temperatura entre las dos resoluciones. En general los puntos de resolución de 0.25 se acercan más a el pronóstico perfecto, aunque en términos de error cuadrático medio centrado, caen casi sobre el mismo círculo de error constante. La mayor diferencia se puede observar para la temporada de secas frías sobre todo para las estaciones CuMex.

Los mapas de la distribución del error cuadrático medio muestran una concentración de errores de grandes magnitudes en la región norte/centro del Valle. Los errores tienden a ser menores en las regiones del norte, sobre todo en aquellas fuera de la mancha urbana. Los puntos ubicados en zonas de fuerte topografía, como altzom o AJU muestran también errores con magnitudes grandes. En términos de temporadas, la temporada de secas frías es la que muestra mayor concentración de error en la zona centro/norte. Entre resoluciones se aprecia una disminución de error muy ligera al pasar de 0.5 a 0.25 grados.

La distribución del error medio absoluto es muy similar a la del error cuadrático medio. Los errores de mayor magnitud se concentran en la región norte/centro del Valle (mancha urbana) así como en regiones de topografía complicada. Los puntos del noreste muestran las magnitudes de error más bajas, los cuales corresponden a puntos de topografía plana y fuera de la mancha urbana principal. La estación con el error más grande es la de secas frías. Entre ambas resoluciones no se observan cambios importantes.

El mapa de distribución de error medio indica una subestimación en regiones planas y una sobreestimación en regiones de topografía importante. Tanto puntos del norte/centro como del noreste muestran errores medios negativos (subestimación), con la magnitud más negativa en el norte/centro. Los puntos que están cerca de topografía compleja, como AJU, altzom o tresma muestran valores positivos grandes de error (sobreestimación). El error es más marcado en la temporada de secas frías, y menor en la de secas cálidas. La comparación entre resoluciones no muestra una diferencia importante entre los errores.

Para estudiar más profundamente el fenómeno de sobreestimar en las montañas y subestimar en el valle, se eligieron dos puntos para analizar series de tiempo y diagramas cuantil-cuantil. El primer punto es el de la estación AJU, representando un punto en topografía complicada. La serie de tiempo de AJU se puede observar en la Figura 3.21 y el diagrama cuantil-cuantil en la Figura 3.23. El segundo punto es el de la estación UAX, representando una región plana. La serie de tiempo de UAX se puede observar en la Figura 3.22 y el diagrama cuantil-cuantil en la Figura 3.24.

La serie de tiempo para el punto AJU confirma lo antes observado con el error medio

y el diagrama de Taylor, viendo que hay una constante sobreestimación de los valores de la magnitud del viento. Esta situación parece ser la misma para las dos resoluciones, algo que también muestra el diagrama cuantil-cuantil. Entre estaciones se observa que la temporada seca fría es donde la correlación entre series es mejor, aunque aún se presenta la sobreestimación.

Por otro lado, la serie de tiempo para el punto UAX muestra un mejor acoplamiento entre las series, pero con varias regiones de subestimación de la magnitud. El diagrama cuantil-cuantil nos ayuda a observar que en las regiones a la izquierda de la cola del histograma existe subestimación de los valores, y dado que esta región es donde se encuentra la mayor parte de los conteos, el error medio global resultante es negativo. Al ver el cambio entre resoluciones se observa que la cola del histograma tiende a concentrarse un poco hacia valores más pequeños. También se puede apreciar que la mayor calidad del pronóstico se alcanzó en la temporada de secas frías, y la peor en la temporada húmeda.

Dada la situación topográfica de las dos estaciones estudiadas, se cree que el error presentado por estas dos estaciones puede estar asociado al fenómeno de brisa de vallemontaña, donde se esperaría que la estación que esta en sotavento (UAX) tuviera magnitudes más grandes al llegar la corriente de gravedad. Ya que este fenómeno no es resuelto por el modelo con ninguna de las dos resoluciones, tendrían que hacerse simulaciones de mayor resolución para analizar fenómenos de ésta escala. La escala horizontal típica de estos fenómenos es del orden de 5 km.

En general la simulación del viento parece ser bastante inadecuada para la región del Valle de México. Los diagramas de Taylor muestran una muy baja correlación con fuertes problemas para replicar la variabilidad del viento. Los mapas de distribución de error también muestran fuertes errores en el centro del Valle y en las regiones con topografía complicada. La temporada con más errores globalmente fue la de secas frías, la cual es la temporada en donde se presentan la mayor parte de los eventos de frentes fríos que afectan a la región. Ya que estos frentes se asocian a cambios en la dirección y magnitud del viento, es posible que el modelo no sea capaz de resolver este fenómeno con la configuración usada para el pronóstico.

## 3.2. Sensibilidad ante condiciones iniciales y de frontera

### 3.2.1. Temperatura

Los diagramas de bosque que representan los intervalos de confianza calculados mediante el *bootstrap* para la diferencia de medias de los errores se muestran en las Figuras 3.25 a 3.27 para el error medio absoluto. Cada color representa una de tres posibles situaciones, que la estación esté en la mancha urbana con topografía plana, que la estación esté fuera de la mancha urbana con topografía plana o que la estación se encuentre en una montaña. Cuando la media se encuentra del lado derecho del cero existe una mejoría en la calidad del pronóstico debido al cambio de C.I. y de F. a 0.25, mientras que si se encuentra del lado izquierdo la calidad del pronóstico empeoró al emplear C.I. y de F. de 0.25.

El diagrama de la temporada húmeda (Figura 3.25) muestra que existe poca sensibilidad del modelo a C.I. y de F. para esta temporada. Esto se concluye porque casi todas las estaciones tienen al 0 dentro de sus intervalos de confianza, con la excepción de 4 estaciones en las montañas: AJU, altzom, tresma y pqizta. La mayor parte de las estaciones de montaña muestra pérdida de calidad, aunque como se mencionó solo 4 de estas muestran




Figura 3.15: Diagrama de Taylor para la variable magnitud del viento, temporada de lluvias. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).




Figura 3.16: Diagrama de Taylor para la variable magnitud del viento, temporada seca cálida. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).




Figura 3.17: Diagrama de Taylor para la variable magnitud del viento, temporada seca fría. Se muestran las estaciones de la Cuenca de México (CuMeX) y la Cuenca del Río Balsas (CuBal).

un cambio lo suficientemente grande como para ser estadísticamente significativo. Los puntos urbanos en cambio se muestran más centrados hacia el 0, donde sólo las estaciones TLA, XAL y SAG mostraron una desmejora estadísticamente significativa. Esto es notable ya que estos tres puntos se encuentran muy cercanos a la ladera del cerro de Guadalupe, al norte del Valle de México.

Para la temporada seca cálida (Figura 3.26), es posible observar una sensibilidad muy grande del modelo en los puntos de montaña, ya que quince de los veintidós puntos de montaña (rojos) muestran un cambio estadísticamente significativo. De estos diez muestran desmejoría y cinco una mejora en calidad. Las estaciones de montaña que mostraron desmejoría son aquellas que se encuentran en las montañas que rodean al Valle. Lo anterior no ocurre para los puntos urbanos y no urbanos, ya que ninguno de estos muestra un cambio estadísticamente significativo. La tendencia de los intervalos de confianza para los puntos urbanos es de concentrarse del lado derecho del diagrama, sugiriendo una ligera ganancia de calidad para el modelo. Los puntos no urbanos en cambio se mantuvieron muy centrados, indicando una sensibilidad casi nula del modelo para las regiones fuera de la mancha urbana.

La tercer temporada analizada, secas frías, muestra en el diagrama de bosque (Figura 3.27) una sensibilidad moderada en los puntos de montaña con 12 de 21 puntos mostrando una diferencia estadísticamente significativa entre diferentes C.I. y de F. En este caso no hay un claro indicador de ganancia o pérdida de calidad, ya que casi el mismo número de puntos caen a la derecha y a la izquierda del cero (siete a la izquierda y cinco a la derecha). Los puntos urbanos muestran también una sensibilidad media ante el cambio de C.I., aunque en este caso es mucho más claro que la tendencia es a mejorar la calidad de los pronósticos. Los puntos no urbanos no muestran gran sensibilidad, aunque tienen una pequeña tendencia a moverse hacia la derecha del diagrama.



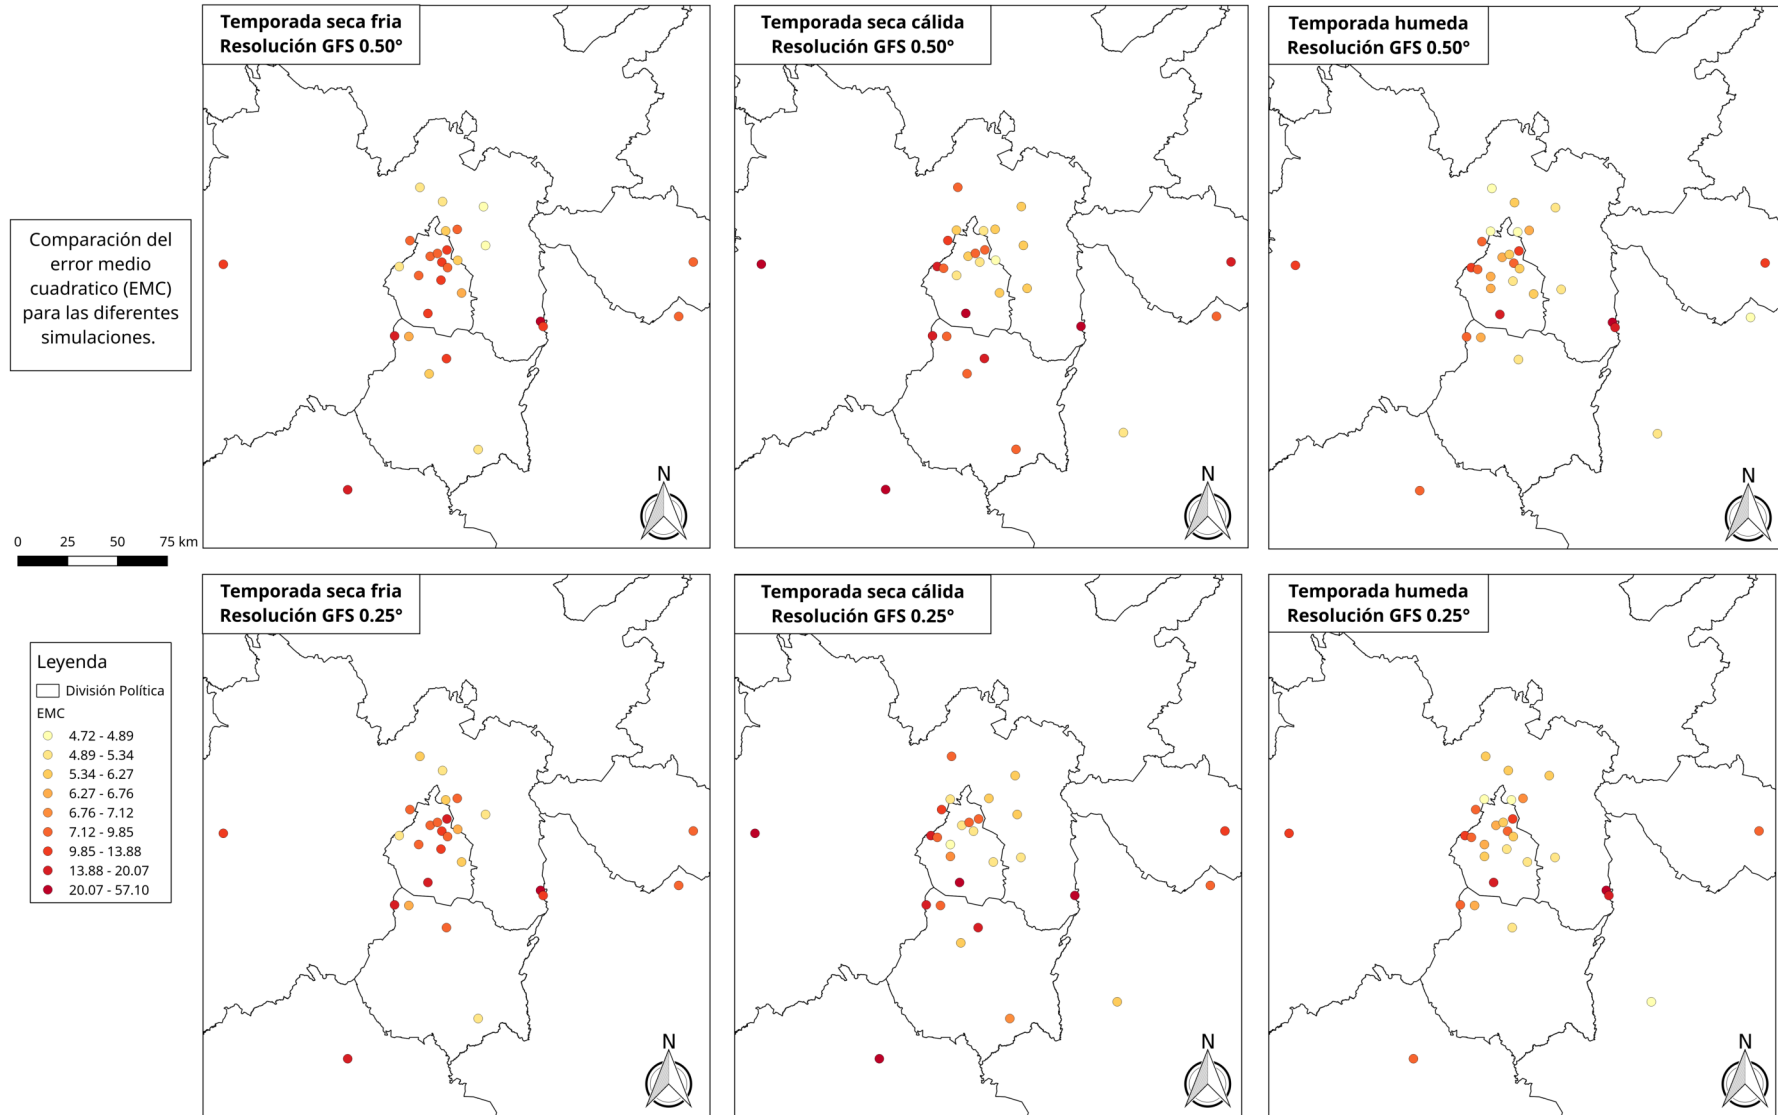


Figura 3.18: Comparación del error cuadrático medio para la variable magnitud del viento a lo largo de las temporadas analizadas para el dominio de simulación.

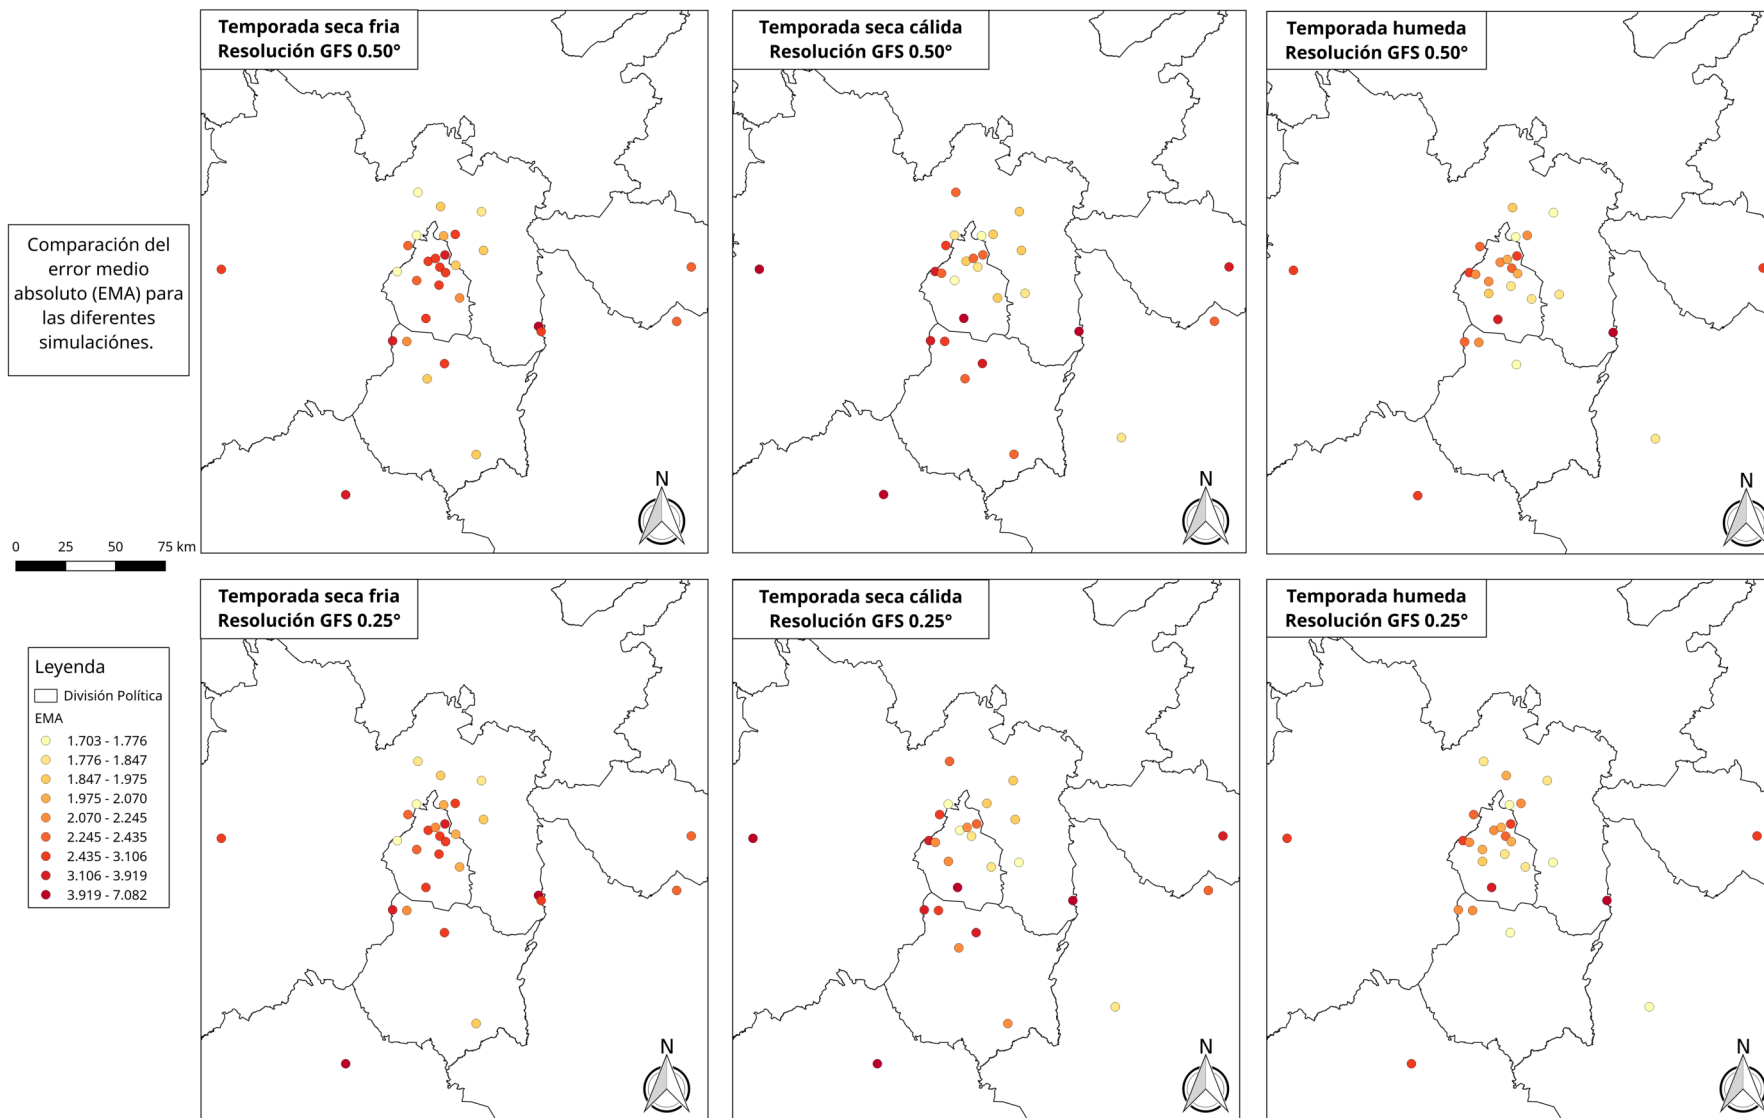


Figura 3.19: Comparación del error medio absoluto para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación.



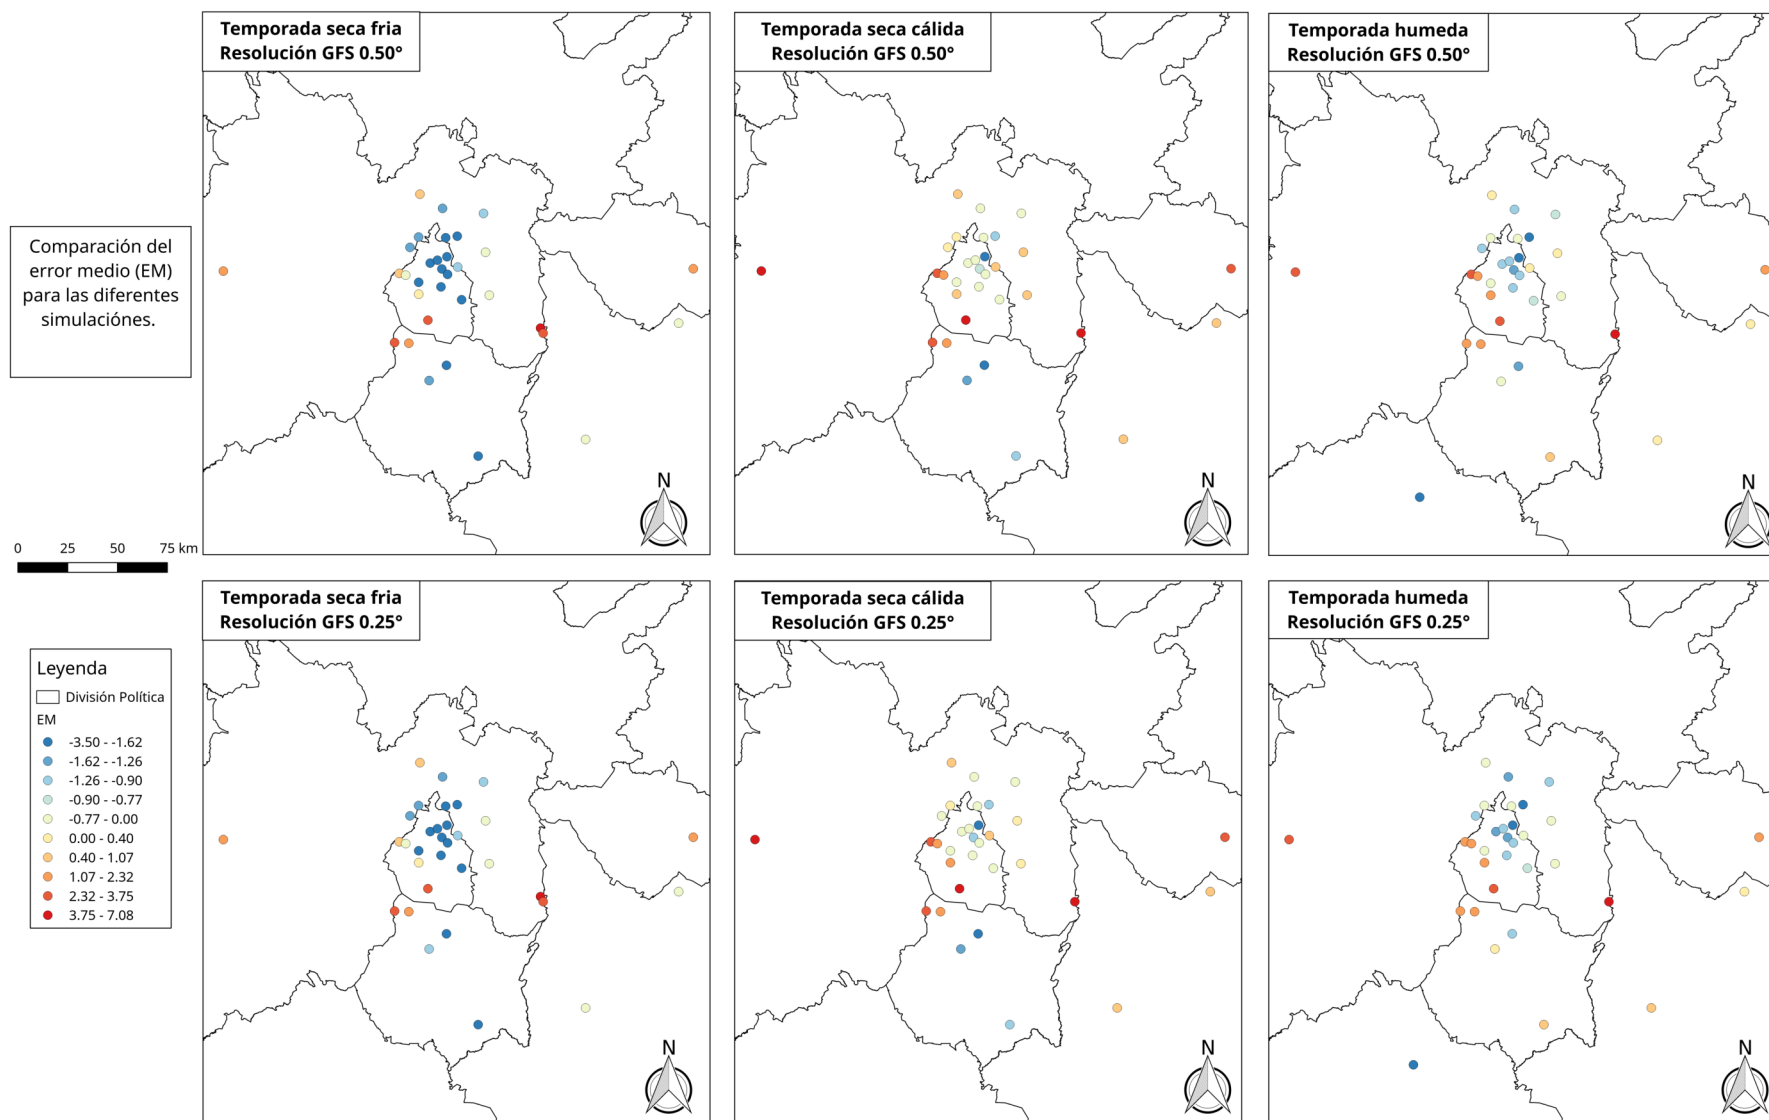


Figura 3.20: Comparación del error medio para la variable magnitud del viento a lo largo de las temporadas para el dominio de simulación.

Series de tiempo de Temperatura para la estación AJU

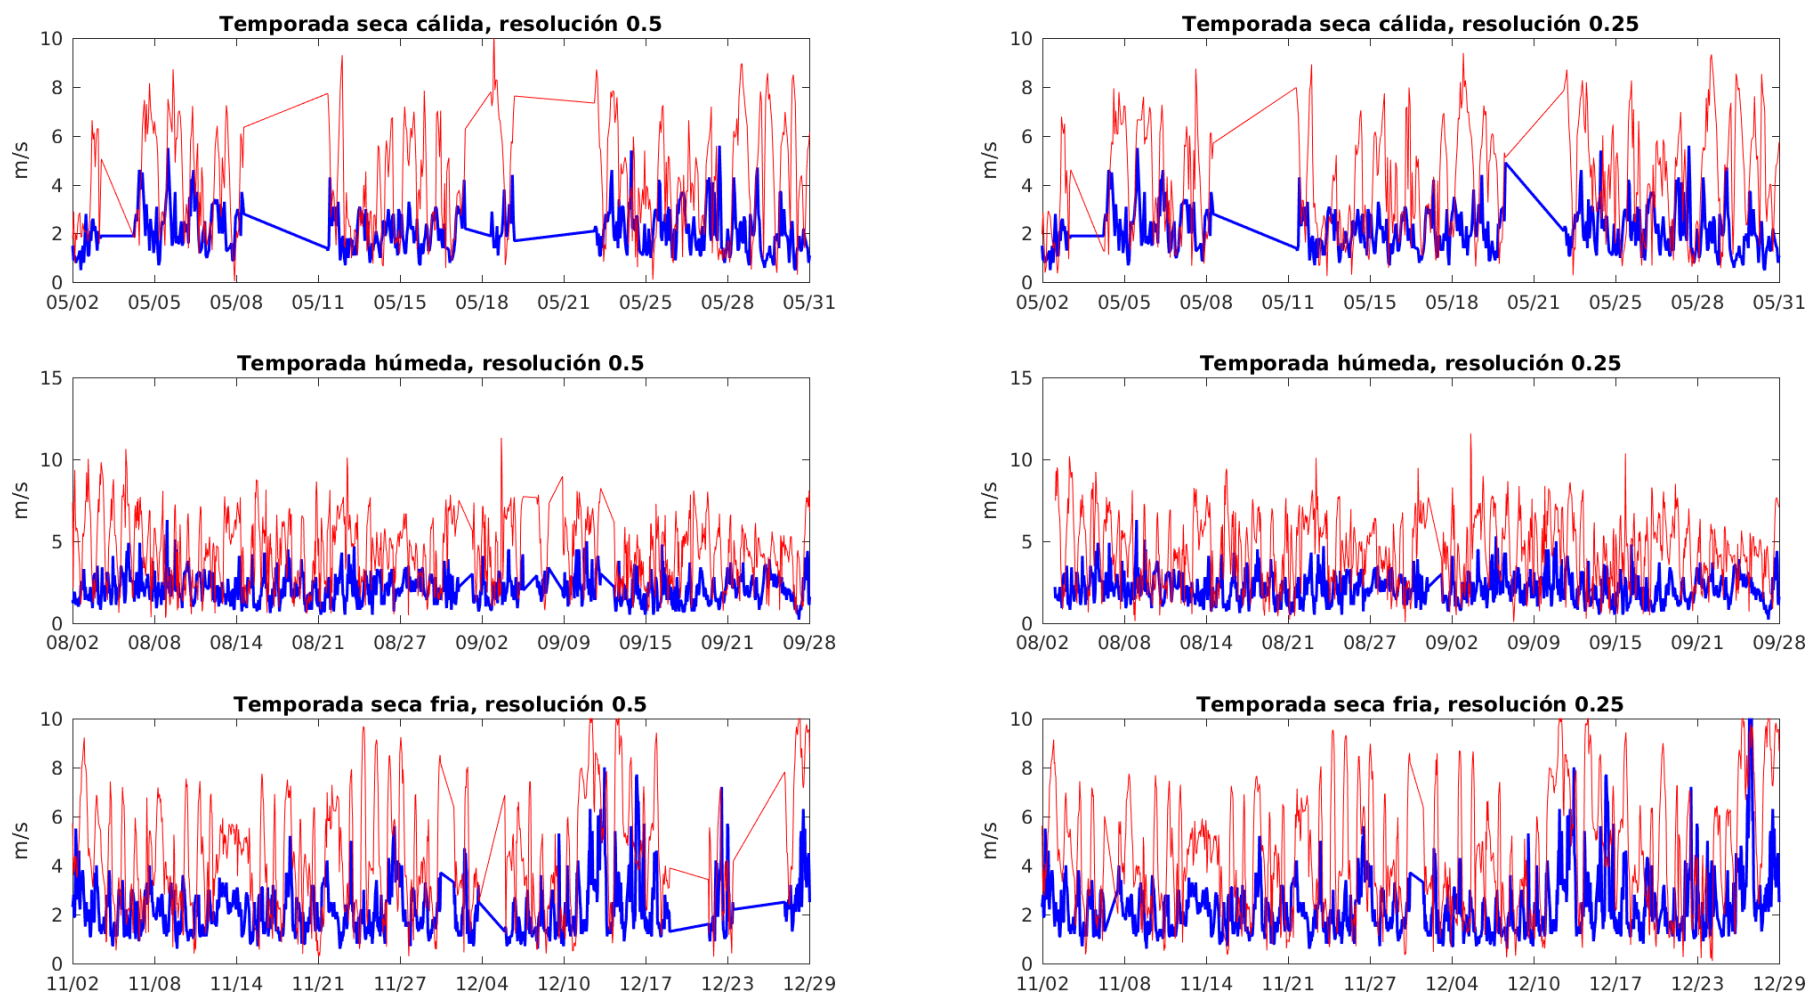


Figura 3.21: Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación Ajusco.

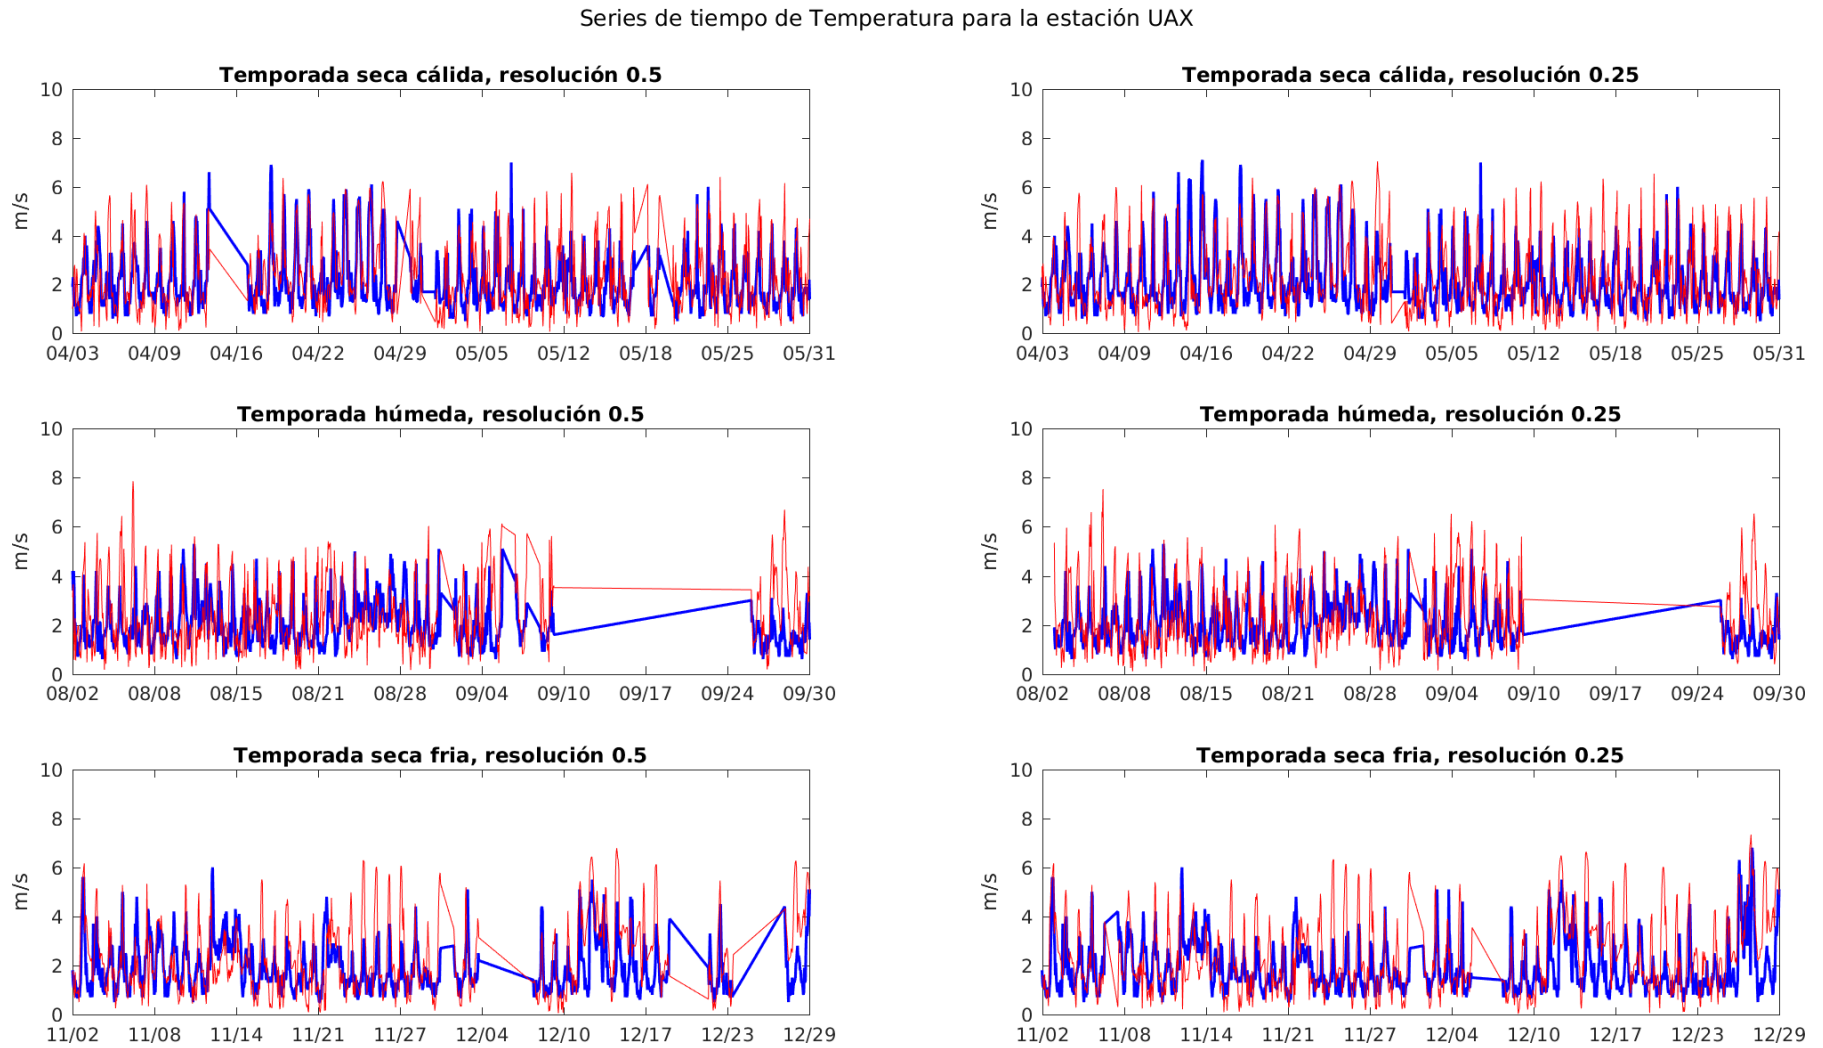


Figura 3.22: Serie de tiempo de viento mostrando las observaciones en azul y el pronóstico en rojo para la estación UAM Xochimilco.

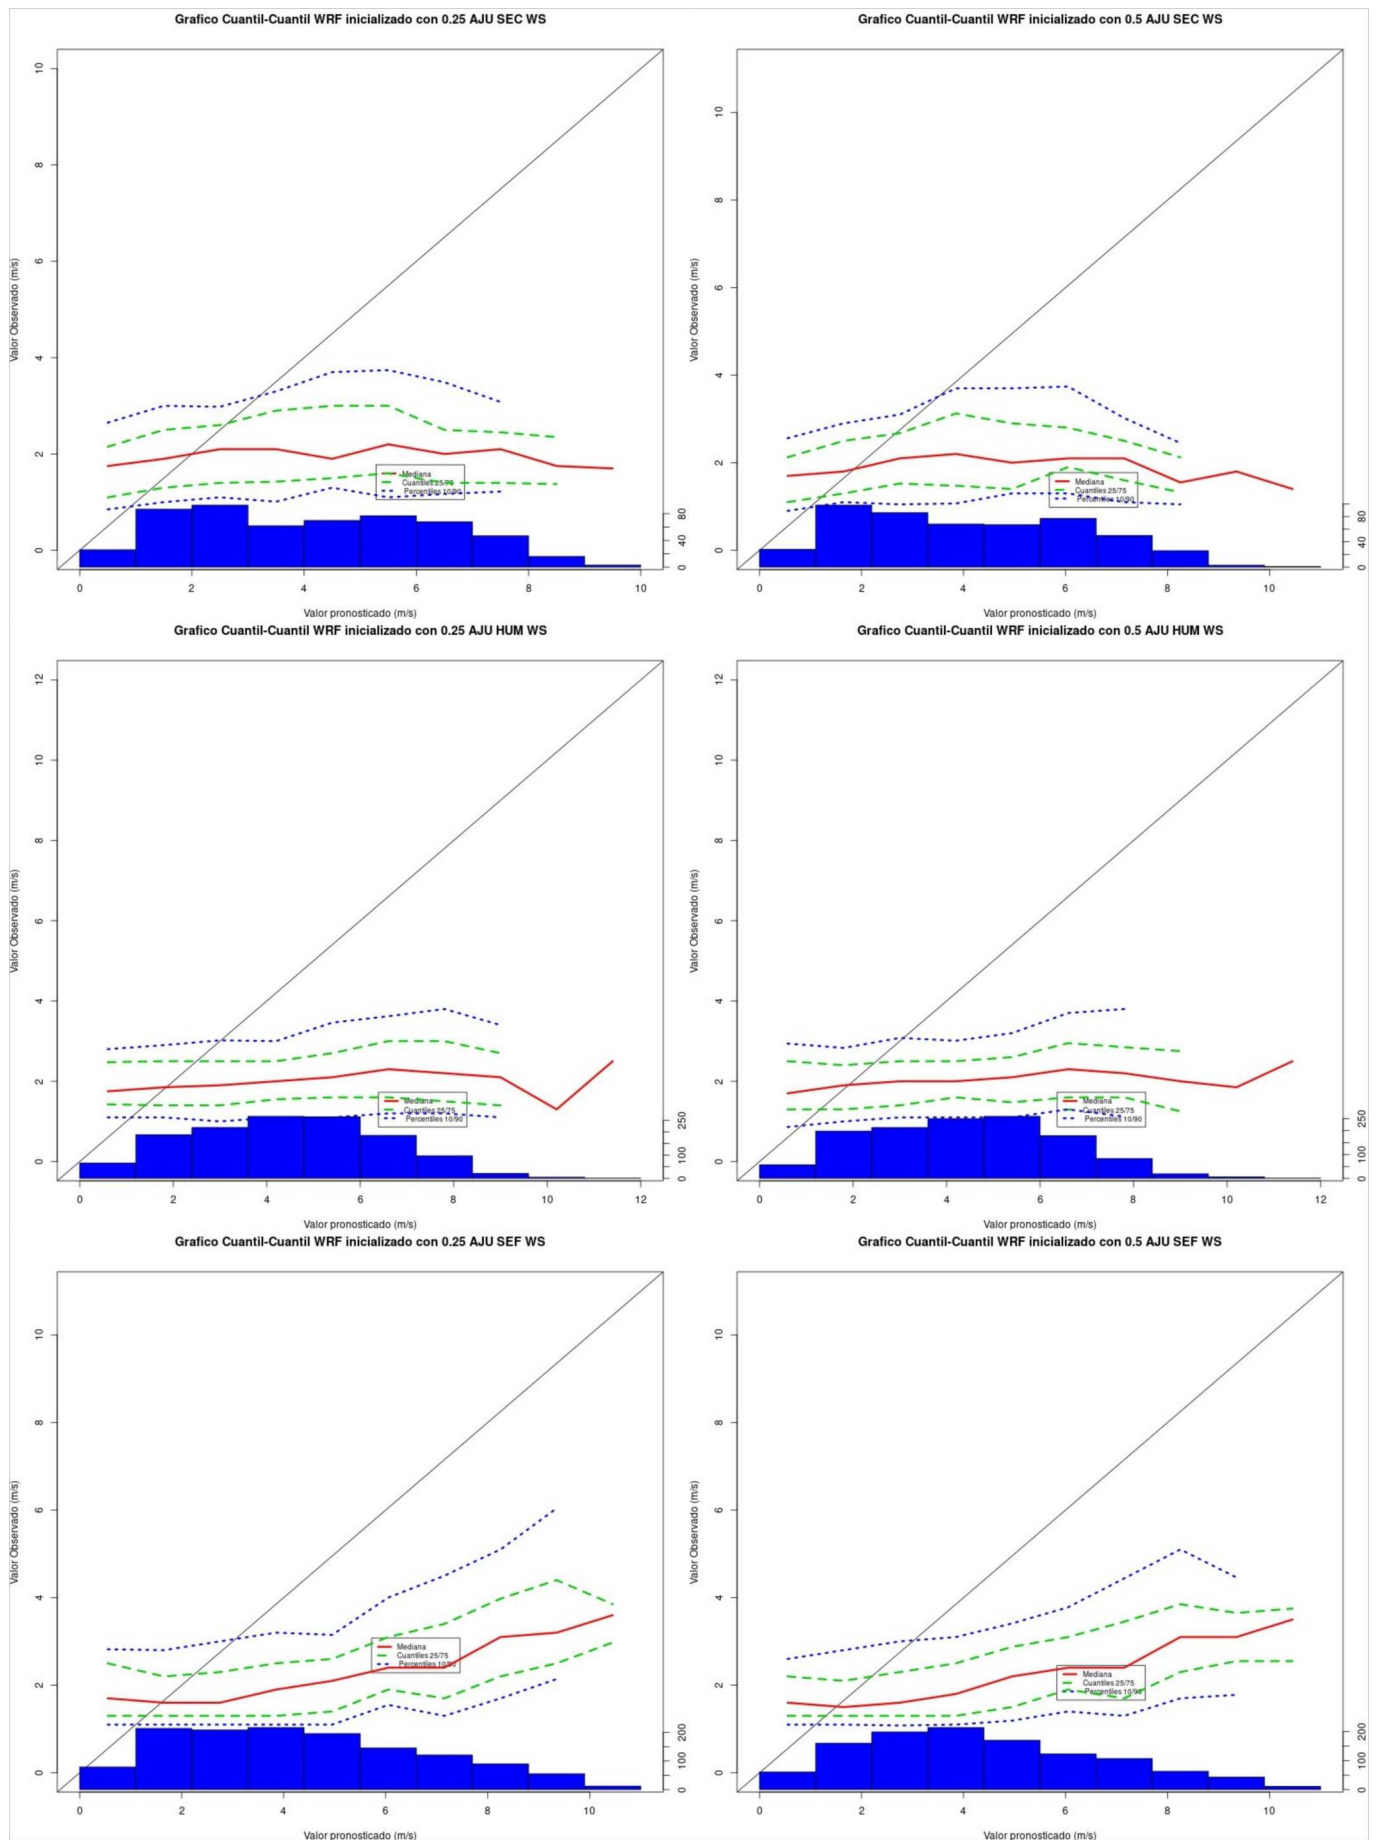


Figura 3.23: Diagrama cuantil-cuantil para la magnitud del viento en la estación Ajustco.

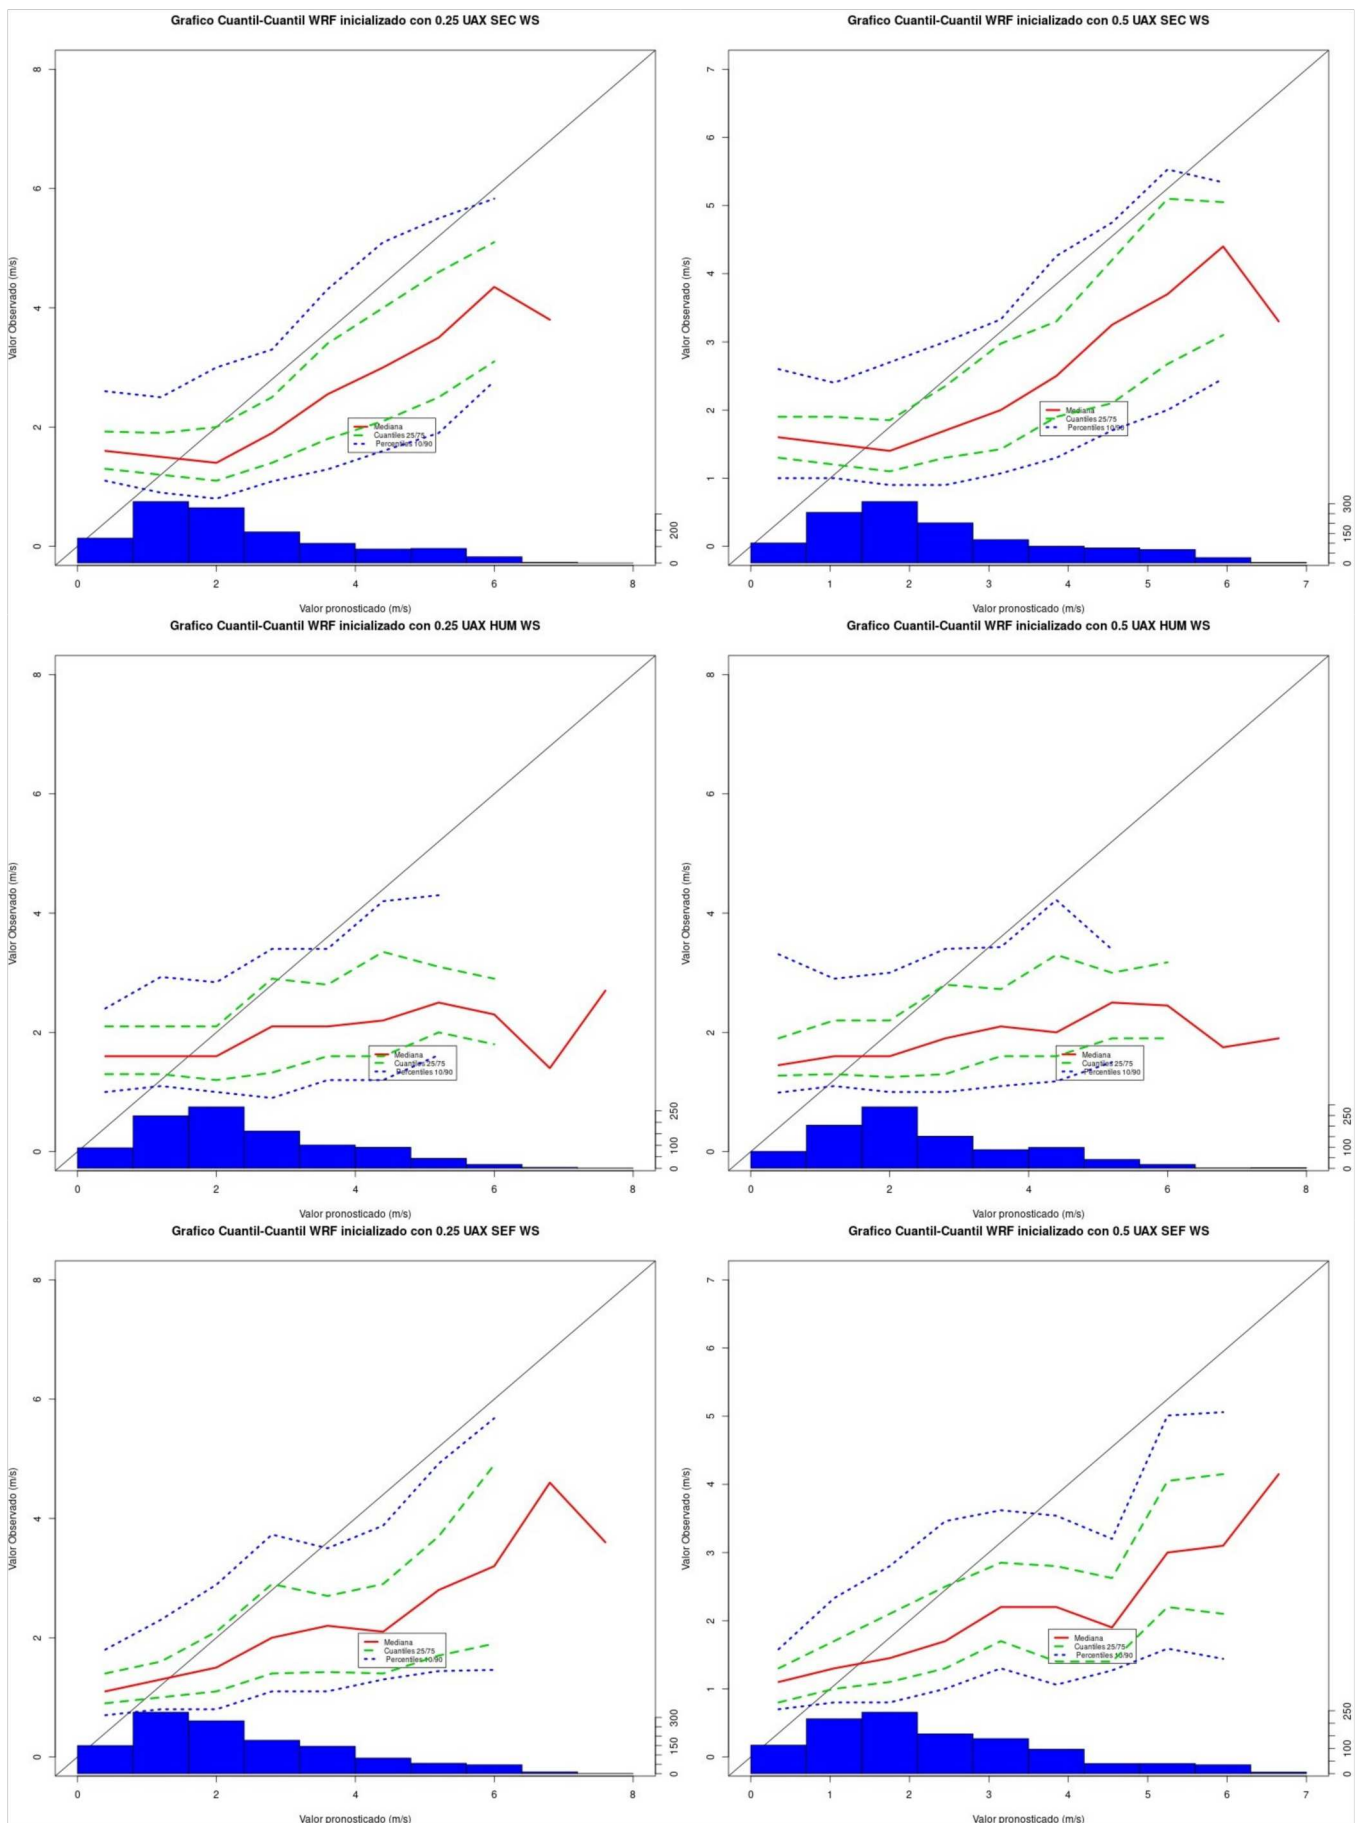


Figura 3.24: Diagrama cuantil-cuantil para la magnitud del viento en la estación de la UAM Xochimilco (UAX).

Globalmente se observa que la sensibilidad es muy baja para la temporada húmeda, relativamente alta para la temporada de secas cálidas e intermedia para la de secas frías. Para explicar esta variabilidad anual se propone explicar estos cambios en sensibilidad de acuerdo a los diferentes eventos meteorológicos que ocurren en el valle con cada temporada.

En la temporada húmeda existe una dominancia de eventos locales convectivos que dan lugar a precipitación, modificando la temperatura en el proceso. Los bajos valores de sensibilidad sugieren que la principal fuente de error para esta temporada no está asociado con las C.I. y de F., pudiendo ser que tengan una mayor relación con la parametrización de cúmulos y microfísica elegidos.

En la temporada seca fría existe un fuerte forzamiento sinóptico ocasionado por el paso de frentes fríos originados en latitudes medias. Está temporada mostró una sensibilidad mediana, algo que podemos explicar con el paso de los frentes fríos, los cuales son perturbaciones del campo de densidad horizontal que se generan fuera del dominio y se propagan a lo largo de este. La información necesaria para que un frente frío entre al dominio se encuentra en las C.F., por lo que se espera que al mejorar la resolución de las C.F., mejore la representación de los frentes fríos en el dominio, explicando el aumento en sensibilidad observado. Por otro lado, el que la sensibilidad no sea tan grande sugiere también que otros procesos, como la modelación de la isla de calor urbana, están involucrados también en la simulación, impidiendo una ganancia significativa de calidad para el modelo.

Por último la temporada seca cálida no está tan influenciada por forzamientos sinópticos o locales convectivos como las otras temporadas, y es donde la sensibilidad ante C.F. es mayor. En este caso se puede pensar que en esta temporada es donde las C.F. son más importantes para la simulación.

Otro aspecto de interés es que los puntos de montaña mostraron siempre una mayor sensibilidad al cambio de C.I. y de F. que los puntos en topografía plana. Esto puede ser explicado si pensamos en la distribución espacial esperada de la temperatura para el Valle de México. Para la parte plana no se espera un gradiente horizontal de temperaturas muy elevado, mientras que en las zonas montañosas se espera que el gradiente horizontal de temperatura sea grande. Al aumentar la resolución espacial de las C.I. y de F. puede ocurrir que no tengamos cambios muy grandes en temperatura que al usar las C.I. y de F. de menor resolución en la parte plana, aunque si existan diferencias grandes en las temperaturas de las zonas montañosas. Esto resulta en una mejor aproximación inicial en el campo de temperaturas para las zonas montañosas junto con una aproximación similar a la ya existente en las zonas planas, aumentando la sensibilidad de la zona montañosa ante C.I. y de F. de mayor resolución.

### 3.2.2. Viento

Los diagramas de bosque que representan intervalos de confianza para las diferencias de medias para la magnitud del viento se presentan en las Figuras 3.28 a 3.30. Al igual que con la temperatura, valores a la izquierda del cero representan una mejoría en la calidad del pronóstico debido al cambio de C.I. y de F. a 0.25, mientras que valores del lado izquierdo representan que la calidad del pronóstico empeoró al emplear C.I. y de F. de 0.25.

El análisis de la Figura 3.28 muestra una sensibilidad muy baja del modelo ante C.I. y de F. para la temporada húmeda. La mayor parte de los puntos se encuentran centrados alrededor del cero, con solo cuatro puntos de montaña mostrando cambios significativos (AJU, cdalta, huaman y lama02), así como dos urbanos (UAX, UIZ). No es claro si hay




Figura 3.25: Diagrama de bosque de temperatura para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.






Figura 3.26: Diagrama de bosque de temperatura para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.






Figura 3.27: Diagrama de bosque de temperatura para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.

una ganancia o pérdida global de calidad, ya que se observa la misma cantidad de puntos de ambos lados de la línea vertical (dieciocho de cada lado). Se puede apreciar que los intervalos de confianza para todos los puntos abarcan un intervalo más grande que para la temporada seca fría, indicando que la variabilidad de la diferencia del error es más grande en esta temporada.

Para la temporada seca cálida, el diagrama de la Figura 3.29 muestra una sensibilidad baja con variabilidad mayor de la diferencia de errores. Similar a la temporada húmeda, los intervalos de confianza no muestran diferencias significativas más que para dos estaciones (mona01, NEZ). En este caso los puntos de montaña parecen alinearse más a la izquierda, mientras que los puntos urbanos tienden a estar más a la derecha. Esto indica ligeras pérdidas de calidad en los puntos de montaña y ligeras ganancias de la misma para los puntos urbanos. Es notable que el rango para los intervalos de confianza crece notablemente, indicando mucha variabilidad en la diferencia de errores para estos puntos.

El diagrama de la temporada seca fría (Figura 3.30) muestra también sensibilidad muy baja ante C.I. y de F. del modelo. En este caso el rango de los intervalos es marcadamente menor que para las otras dos temporadas, indicando menor variabilidad en la diferencia de errores. Únicamente dos puntos mostraron un cambio significativo del error, siendo una de montaña (lagzem) y otro urbano (SAG). Los puntos de montaña tienden a estar centrados en el cero o ligeramente en el lado derecho, indicando mejoras muy ligeras en calidad. En cambio, los puntos urbanos y no urbanos se encuentran mayoritariamente a la izquierda, indicando una pérdida pequeña de calidad del pronóstico.

En general, se observó para todas las temporadas que el modelo exhibe una sensibilidad muy baja ante C.I. y de F. para el pronóstico de la magnitud del viento. Las tres temporadas mostraron muy pocos puntos con cambios significativos al emplear C.I. y de F. de mayor resolución, sin poder indicar si hubo ganancia o pérdida global de calidad en el modelo. La diferencia de errores mostró mayor variabilidad para la temporada seca cálida y húmeda, siendo menor en la de secas frías.

En la sección de verificación de pronóstico se mostró que para el dominio de estudio, el modelo WRF era muy inapropiado para simular adecuadamente la magnitud del viento con la configuración elegida. Estos últimos resultados nos indican que el problema no es un problema de condiciones iniciales, ya que los resultados no muestran cambios importantes al aumentar la resolución espacial de las C.I. Lo anterior sugiere que la fuente de error en la simulación está asociada con tres diferentes cuestiones: los procesos de parametrización para la magnitud del viento elegidos, la resolución utilizada para la simulación (la cual conviene recordar que cae en la zona gris de simulación para esta configuración) y la elección de uso de suelo, la cual es muy importante para el viento.




Figura 3.28: Diagrama de bosque de viento para el EMA, temporada húmeda. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.




Figura 3.29: Diagrama de bosque de viento para el EMA, temporada seca cálida. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.




Figura 3.30: Diagrama de bosque de viento para el EMA, temporada seca fría. Los puntos azules corresponden a estaciones dentro de la mancha urbana con topografía plana, los puntos rojos a estaciones con topografía complicada y los puntos verdes a estaciones fuera de la mancha urbana con topografía plana.

## Capítulo 4

# Conclusiones

El objetivo de este trabajo fue cuantificar la respuesta que muestra el modelo de PNT de escala regional *Weather Research & Forecasting* (WRF) (Skamarock et al., 2005) ante condiciones iniciales y de frontera de diferente resolución en la región del Valle de México. Se realizaron aproximadamente 360 simulaciones diarias para un dominio que engloba la región del Valle de México, alimentando una mitad con C.I. y de F. con resolución horizontal de 0.5 grados ( $\sim 50[km]$ ) y la otra con C.I. y de F. de resolución horizontal de 0.25 grados ( $\sim 25[km]$ ). Las simulaciones diarias se realizaron para las tres temporadas presentes en el clima del Valle de México durante 2015: seca fría, seca cálida y de lluvias. Se calcularon diferentes medidas de verificación de pronóstico para evaluar la calidad para todas las simulaciones usando las observaciones de las redes de Estaciones Automáticas (EMA) y REDMET. Se realizó una comparación cualitativa y cuantitativa de las diferencias entre las medidas al usar C.I. y de F. para estimar la sensibilidad que muestra el modelo WRF.

La verificación de pronóstico mostró que para todas las temporadas el modelo WRF era capaz de representar el ciclo diario de la temperatura, pero no era capaz de capturar adecuadamente la magnitud de la variabilidad de esta variable. La distribución espacial de errores mostró también una subestimación de la temperatura en las estaciones contenidas dentro de la mancha urbana, sugiriendo que el modelo no es capaz de representar adecuadamente procesos de superficie como la isla de calor urbana para esta región fuertemente urbanizada del Valle de México. Para la magnitud de la velocidad del viento los resultados de verificación mostraron una calidad muy baja para todas las simulaciones, ya que el modelo no fue capaz de representar adecuadamente la variabilidad o el ciclo diario de esta variable. La distribución espacial del sesgo, en donde las estaciones ubicadas en la ladera de una montaña muestran subestimación del viento, sugiere la existencia de un fenómeno de brisa de valle montaña que no está bien representado por el modelo. La verificación para precipitación mostró también una calidad deficiente para estimar adecuadamente eventos de precipitación, sobrestimando constantemente esta variable.

El análisis de sensibilidad para la temperatura mostró que globalmente ésta no era lo suficientemente grande para generar cambios significativos entre las dos resoluciones. Sin embargo, se observaron cambios relativos de sensibilidad entre las diferentes temporadas, pudiendo asociar cada una de estas con los forzamientos meteorológicos de diferentes escalas que dominan cada temporada. Cuando los procesos locales dominan se observó una baja sensibilidad ante las C.I. y C.F., mientras que cuando forzamientos sinópticos que provienen de las condiciones de frontera son dominantes, la sensibilidad aumentó. Se observó también que los puntos ubicados en montaña mostraron mayor sensibilidad que

aquellos ubicados en terreno plano. Esta diferencia se adjudicó a la mayor capacidad que muestra el modelo GFS para resolver zonas de topografía complicada cuando aumenta su resolución espacial, mientras que en zonas con topografía plana este aumento de resolución posiblemente no generaría cambios importantes en la salida para regiones pequeñas.

Por otra parte, el análisis de sensibilidad para la magnitud de la velocidad del viento mostró que para todas las temporadas la sensibilidad fue muy baja, sin existir cambios significativos al usar las diferentes resoluciones de C.I. y de F. La verificación de pronóstico mostró también que el modelo fue muy deficiente para la simulación de esta variable, por lo que se adjudica esta baja sensibilidad a que la fuente principal de error no está asociada con la inicialización del modelo. Si la base física del modelo no es adecuada para representar los procesos atmosféricos que ocurren en el dominio, no importará entonces qué tan buena sea la calidad de las C.I. y de F. que usemos para la simulación, ya que siempre obtendremos resultados erróneos. Es necesario realizar estudios de sensibilidad ante diferentes parametrizaciones de capa límite y procesos de superficie para el Valle de México para comprender mejor la fuente de error para esta variable.

La sensibilidad que mostró el modelo WRF ante condiciones iniciales y de frontera en el Valle de México fue muy baja. Derivado de lo anterior no se observó una mejoría significativa en la calidad de los pronósticos al usar condiciones iniciales y de frontera de mayor resolución espacial. La distribución temporal y espacial de los errores para las tres variables utilizadas sugieren que la principal fuente de error está relacionada con la manera de representar procesos de subescala en el dominio y con la resolución horizontal utilizada para la simulación. Más estudios sobre la sensibilidad del modelo ante estos procesos para la región del Valle de México deben ser realizados con fin de poder determinar el mejor diseño experimental para elaborar pronósticos operativos de mayor calidad en la región. Una recomendación inicial es evitar la resolución horizontal de simulación dentro de la zona gris (Gerard, 2007), proponiendo como solución el cambio de la resolución de 6,6/18 km (actuales) a 3/15 km o 3/9 km. Se recomienda también implementar un esquema operativo de verificación de pronóstico que corra a la par de la simulación operativa, de tal manera que se pueda juzgar constantemente si la calidad de los pronósticos es adecuada para la aplicación deseada. Esta estrategia podría llevar a un conocimiento más profundo de los procesos meteorológicos que ocurren en el Valle de México.



# Referencias

- Aligo, E. A., Gallus Jr, W. A., y Segal, M. (2007). Summer rainfall forecast spread in an ensemble initialized with different soil moisture analyses. *Weather and forecasting*, 22(2), 299–314.
- Blázquez, J., y Nuñez, M. N. (2009). Sensitivity to convective parameterization in the WRF regional model in southern South America. En *Ninth int. conf. on southern hemisphere meteorology and, oceanography, Melbourne, Australia* (p. 6).
- Brier, G. W., y Allen, R. A. (1951). Verification of weather forecasts. En *Compendium of meteorology* (pp. 841–848). Springer.
- Case, J. L., Crosson, W. L., Kumar, S. V., Lapenta, W. M., y Peters-Lidard, C. D. (2008). Impacts of high-resolution land surface initialization on regional sensible weather forecasts from the WRF model. *Journal of Hydrometeorology*, 9(6), 1249–1266.
- Coles, S., Heffernan, J., y Tawn, J. (1999). Dependence measures for extreme value analyses. *Extremes*, 2(4), 339–365.
- Crétat, J., Pohl, B., Richard, Y., y Drobinski, P. (2012). Uncertainties in simulating regional climate of Southern Africa: sensitivity to physical parameterizations using WRF. *Climate dynamics*, 38(3-4), 613–634.
- Cumming, G. (2013). *Understanding the new statistics: Effect sizes, confidence intervals, and meta-analysis*. Routledge.
- Daley, R. (1991). Atmospheric data analysis, Cambridge atmospheric and space science series. *Cambridge University Press*, 6966, 25.
- Danielson, J. J., y Gesch, D. B. (2011). *Global multi-resolution terrain elevation data 2010 (GMTED2010)* (Inf. Téc.). US Geological Survey.
- Domínguez Mora, R. (2000). Las inundaciones en la Ciudad de México. problemática y alternativas de solución. *Volumen 1*.
- Dudhia, J. (1989). Numerical study of convection observed during the winter monsoon experiment using a mesoscale two-dimensional model. *Journal of the Atmospheric Sciences*, 46(20), 3077–3107.
- Dudhia, J. (1996). A multi-layer soil temperature model for MM5. En *Preprints, the sixth psu/ncar mesoscale model users' workshop* (pp. 22–24).
- Etherton, B., y Santos, P. (2008). Sensitivity of WRF forecasts for South Florida to initial conditions. *Weather and forecasting*, 23(4), 725–740.



- Fast, J. D., De Foy, B., Rosas, F. A., Caetano, E., Carmichael, G., Emmons, L., ... others (2007). A meteorological overview of the MILAGRO field campaigns. *Atmospheric Chemistry and Physics Discussions*, 7(1), 2037–2089.
- Fenn, M. E., De Bauer, L., y Hernández-Tejeda, T. (2002). *Urban air pollution and forests: Resources at risk in the Mexico City air basin* (Vol. 156). Springer Science & Business Media.
- Finley, J. P. (1884). Tornado predictions. *American Meteorological Journal*, 1, 85–88.
- Flaounas, E., Bastin, S., y Janicot, S. (2011). Regional climate modelling of the 2006 West African monsoon: sensitivity to convection and planetary boundary layer parameterisation using WRF. *Climate Dynamics*, 36(5-6), 1083–1105.
- for Environmental Prediction, N. C. (2015). *Global Forecasting System implementations* (Inf. Téc.). Descargado de <http://www.emc.ncep.noaa.gov/GFS/impl.php> (Accesado el: 2016-04-12)
- Gerard, L. (2007). An integrated package for subgrid convection, clouds and precipitation compatible with meso-gamma scales. *Quarterly Journal of the Royal Meteorological Society*, 133(624), 711–730.
- Gustafsson, N., Källén, E., y Thorsteinsson, S. (1998). Sensitivity of forecast errors to initial and lateral boundary conditions. *Tellus A*, 50(2), 167–185.
- Heidke, P. (1926). Berechnung des Erfolges und der Güte der Windstärkevorhersagen im Sturmwarnungsdienst. *Geografiska Annaler*, 301–349.
- Hong, S.-Y., Dudhia, J., y Chen, S.-H. (2004). A revised approach to ice microphysical processes for the bulk parameterization of clouds and precipitation. *Monthly Weather Review*, 132(1), 103–120.
- Hong, S.-Y., Noh, Y., y Dudhia, J. (2006). A new vertical diffusion package with an explicit treatment of entrainment processes. *Monthly Weather Review*, 134(9), 2318–2341.
- Imaz, M. (1989). Historia natural del Valle de México. *Ciencias*(015).
- Jarraud, M. (2008). Guide to meteorological instruments and methods of observation (WMO-no. 8). *World Meteorological Organisation: Geneva, Switzerland*.
- Jauregui, E. (1997). Heat island development in Mexico City. *Atmospheric Environment*, 31(22), 3821–3831.
- Jazcilevich, A. D., García, A. R., y Caetano, E. (2005). Locally induced surface air confluence by complex terrain and its effects on air pollution in the Valley of Mexico. *Atmospheric Environment*, 39(30), 5481–5489.
- Jin, J., Miller, N. L., y Schlegel, N. (2010). Sensitivity study of four land surface schemes in the WRF model. *Advances in Meteorology*, 2010.
- Jolliffe, I. T., y Stephenson, D. B. (2012). *Forecast verification: a practitioner's guide in atmospheric science*. John Wiley & Sons.
- Kain, J. S. (2004). The Kain–Fritsch convective parameterization: An update. *J. Appl. Meteor.*, 43, 170–181.

- Laing, A. E. J. (2011). *Introduction to Tropical Meteorology: A comprehensive online & print textbook*. COMET program, NCAR.
- López-Espinoza, E., Zavala-Hidalgo, J., y Gómez-Ramos, O. (2012). Weather forecast sensitivity to changes in urban land covers using the WRF model for Central Mexico. *Atmósfera*, 25(2), 127–154.
- Lorenz, E. N., y Martin, P. (1995). *The essence of chaos*. AIP.
- Lynch, P. (2006). *The emergence of numerical weather prediction: Richardson's dream*. Cambridge University Press.
- Machenhauer, B. (1977). On the dynamics of gravity oscillations in a shallow water model with applications to normal mode initialization. *Beitr. Phys. Atmos*, 50, 253–271.
- Magaña, V., López, L. C., y Vázquez, G. (2013). El pronóstico de lluvias intensas para la Ciudad de México. *TIP*, 16(1), 18–25.
- Mlawer, E. J., Taubman, S. J., Brown, P. D., Iacono, M. J., y Clough, S. A. (1997). Radiative transfer for inhomogeneous atmospheres: RRTM, a validated correlated-k model for the longwave. *Journal of Geophysical Research: Atmospheres*, 102(D14), 16663–16682.
- Murphy, A. H. (1988). Skill scores based on the mean square error and their relationships to the correlation coefficient. *Monthly weather review*, 116(12), 2417–2424.
- Murphy, A. H. (1993). What is a good forecast? an essay on the nature of goodness in weather forecasting. *Weather and forecasting*, 8(2), 281–293.
- Murphy, A. H., y Winkler, R. L. (1987). A general framework for forecast verification. *Monthly Weather Review*, 115(7), 1330–1338.
- National Centers for Environmental Prediction, N. W. S. N. (2015). *Ncep gfs 0.25 degree global forecast auxiliary grids historical archive* (Inf. Téc.). Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. Descargado de <http://dx.doi.org/10.5065/D6W09402>
- Rabier, F., Klinker, E., Courtier, P., y Hollingsworth, A. (1996). Sensitivity of forecast errors to initial conditions. *Quarterly Journal of the Royal Meteorological Society*, 122(529), 121–150.
- Ruiz, J. J., Saulo, C., y Nogués-Paegle, J. (2010). WRF model sensitivity to choice of parameterization over South America: validation against surface variables. *Monthly Weather Review*, 138(8), 3342–3355.
- Servicio Meteorológico Nacional, M. (s.f.). *Verificación objetiva de modelos numéricos de la atmósfera*. (Inf. Téc.). Descargado de <http://preview.tinyurl.com/verificacionSMN> (Accessado el: 2017-01-15)
- Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Barker, D. M., Wang, W., y Powers, J. G. (2005). *A description of the advanced research WRF version 2* (Inf. Téc.). DTIC Document.
- Smirnova, T., Peckham, S., Benjamin, S., y Brown, J. M. (2009). Implementation and testing of WRF digital filter initialization (DFI) at NOAA/Earth system research laboratory. En *23rd conf. on weather analysis and forecasting/19th conf. on numerical weather prediction*.

Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, 106(D7), 7183–7192.

Warner, T. T. (2010). *Numerical weather and climate prediction*. Cambridge University Press.

Warner, T. T., Peterson, R. A., y Treadon, R. E. (1997). A tutorial on lateral boundary conditions as a basic and potentially serious limitation to regional numerical weather prediction. *Bulletin of the American Meteorological Society*, 78(11), 2599–2617.

Wilks, D. S. (2011). *Statistical methods in the atmospheric sciences* (Vol. 100). Academic press.

Willmott, C. J., Ackleson, S. G., Davis, R. E., Feddema, J. J., Klink, K. M., Legates, D. R., ... Rowe, C. M. (1985). Statistics for the evaluation and comparison of models.

Zhang, Y., Dubey, M., Olsen, S., Zheng, J., y Zhang, R. (2009). Comparisons of WRF/-Chem simulations in Mexico City with ground-based RAMA measurements during the 2006-MILAGRO. *Atmospheric Chemistry and Physics*, 9(11), 3777–3798.

# Anexos



## Anexo A

# namelist.input

```
&time_control
run_days           = 1,
run_hours          = 0,
run_minutes        = 0,
run_seconds        = 0,
start_year         = 2015, 2015,
start_month        = 04, 04,
start_day          = 27, 27,
start_hour         = 00, 00,
start_minute       = 00, 00,
start_second       = 00, 00,
end_year           = 2015, 2015,
end_month          = 04, 04,
end_day            = 29, 29,
end_hour           = 00, 00,
end_minute         = 00, 00, 00,
end_second         = 00, 00, 00,
interval_seconds   = 10800
input_from_file    = .true., .true.,
history_interval   = 60, 60,
frames_per_outfile = 1000, 1000,
restart            = .false.,
restart_interval   = 10000,
io_form_history    = 2
io_form_restart    = 2
io_form_input      = 2
io_form_boundary   = 2
debug_level        = 0
/

&domains
time_step          = 60,
time_step_fract_num = 0,
time_step_fract_den = 1,
max_dom            = 2,
```

```

e_we           = 108,   43,
e_sn           = 70,   37,
e_vert        = 30,   30,
num_metgrid_levels = 27,
num_metgrid_soil_levels = 4,
dx            = 20000, 6666.666,
dy            = 20000, 6666.666,
grid_id       = 1,    2,
parent_id     = 1,    1,
i_parent_start = 1,   48,
j_parent_start = 1,   11,
parent_grid_ratio = 1,  3,
parent_time_step_ratio = 1, 3,
feedback      = 0,
smooth_option = 2
/

&physics
mp_physics    = 3,    3,
ra_lw_physics = 1,    1,
ra_sw_physics = 1,    1,
radt          = 30,   30,
sf_sfclay_physics = 1,  1,
sf_surface_physics = 1,  1,
bl_pbl_physics = 1,   1,
bldt         = 0,    0,
cu_physics    = 1,    1,
cudt         = 5,    5,
isfflx       = 1,
ifsnow       = 0,
icloud       = 1,
surface_input_source = 1,
num_soil_layers = 5,
sf_urban_physics = 0,
mp_zero_out  = 0,
maxiens      = 1,
maxens       = 3,
maxens2      = 3,
maxens3      = 16,
ensdim       = 144,
slope_rad    = 0,
topo_shading = 0,
/

&dynamics
w_damping    = 0,
diff_opt     = 1,
km_opt       = 4,
diff_6th_opt = 0,

```

```

diff_6th_factor      = 0.12 ,
base_temp            = 290.
damp_opt            = 0,
zdamp               = 5000., 5000.,
dampcoef            = 0.01, 0.01,
khdif              = 0, 0,
kvdif              = 0, 0,
non_hydrostatic     = .true., .true.,
moist_adv_opt       = .true., .true.,
scalar_adv_opt      = .true., .true.,
/

&bdy_control
spec_bdy_width      = 5,
spec_zone           = 1,
relax_zone          = 4,
specified           = .true., .false.,
nested              = .false., .true.,
/

&namelist_quilt
nio_tasks_per_group = 0,
nio_groups = 1,
/

```