

UNIVERSIDAD NACIONAL AGRARIA

LA MOLINA

FACULTAD DE CIENCIAS



**“VALIDACIÓN DEL MODELO WEATHER RESEARCH AND
FORECASTING (WRF) AL SIMULAR TEMPERATURAS EN ZONAS
ALTOANDINAS DE PUNO Y AREQUIPA”**

Presentada por:

Victor Miguel Ñavincopa Muñoz

Tesis para optar el Título Profesional de:

INGENIERO AMBIENTAL

Lima – Perú

2018

DEDICATORIA

A mi madre...

AGRADECIMIENTOS

A MI FAMILIA, por el soporte emocional que ellos significan.

A mi asesor de tesis, el profesor Jerónimo García V., que gracias a su orientación y dedicación supo dirigir sabiamente el desarrollo de este trabajo de investigación.

A mi co-asesor, el doctor Odón Sánchez C. y su equipo en la Dirección General de Investigación ambiental (DGIA) del SENAMHI, por el apoyo en la parte experimental de la tesis, y por su disposición siempre en resolver cualquier duda.

A la doctora Elizabeth Silvestre E., a quién le pertenece la idea original de este trabajo. Un agradecimiento especial también a su grupo de investigación por promover este trabajo y confiar en mí para ejecutarlo.

Un especial agradecimiento a los doctores Jimmy Dudhia y Wei Wang, científicos de la Corporación Universitaria para la Investigación Atmosférica (UCAR) de los Estados Unidos. Cruciales colaboraciones.

Y en general a todas esas personas que con algunas palabras de motivación o con alguna enseñanza, sugerencia, etc., contribuyeron para el desarrollo de este estudio.

"Si he logrado ver más lejos, fue porque estuve en hombros de gigantes"

Isaac Newton

ÍNDICE GENERAL

RESUMEN	i
ABSTRACT	ii
I. INTRODUCCIÓN	1
II. REVISIÓN DE LITERATURA	3
2.1. ANTECEDENTES	3
2.2. MODELOS DE PREDICCIÓN NUMÉRICA (NWP).....	4
2.2.1. LAS ECUACIONES GOBERNANTES	5
2.2.2. LOS PROCESOS FÍSICOS	6
2.2.3. EL SISTEMA DE MODELAMIENTO	7
2.3. DATOS DE ANÁLISIS	9
2.4. MODELOS ATMOSFÉRICOS DE MESOESCALA.....	9
2.5. CONDICIONES INICIALES Y DE FRONTERA	10
2.6. EL MODELO WEATHER RESEARCH AND FORECASTING (WRF)	12
2.6.1. SISTEMA DE MODELAMIENTO DEL MODELO WRF.....	13
2.6.2. COMPONENTES DEL MODELO WRF	14
2.6.3. GRILLA HORIZONTAL DEL MODELO WRF	16
2.6.4. GRILLA VERTICAL Y COORDENADAS VERTICALES DEL MODELO WRF	17
2.7. VALIDACIÓN DE MODELOS DE PREDICCIÓN NUMÉRICA	18
2.7.1. MEDIDAS DE PRECISIÓN	19
2.7.2. PRUEBAS ESTADÍSTICAS PARA VALIDACIÓN DE RESULTADOS ...	25
III. MATERIALES Y MÉTODOS	26
3.1. EQUIPOS Y/O MATERIALES	26
3.2. METODOLOGÍA.....	27
3.2.1. VALIDACIÓN DEL PRONÓSTICO DE TEMPERATURAS	28
3.2.2. VALIDACIÓN DE LA SIMULACIÓN DE TEMPERATURAS	46
IV. RESULTADOS Y DISCUSIÓN	57
4.1. VALIDACIÓN DEL PRONÓSTICO DE TEMPERATURAS	57
4.1.1. ANÁLISIS DE LAS MEDIDAS DE PRECISIÓN EN CADA PUNTO DE VALIDACIÓN	57

4.1.2. ANÁLISIS COMPARANDO LOS CUATRO PUNTOS DE VALIDACIÓN	76
4.2. VALIDACIÓN DE LA SIMULACIÓN DE TEMPERATURAS	79
4.2.1. ANÁLISIS DE LAS MEDIDAS DE PRECISIÓN EN CADA PUNTO DE VALIDACIÓN	79
4.2.2. ANÁLISIS COMPARANDO LOS CUATRO PUNTOS DE VALIDACIÓN	91
V. CONCLUSIONES.....	94
VI. RECOMENDACIONES.....	95
VII. REFERENCIAS BIBLIOGRÁFICAS	96
VIII. ANEXOS	101

ÍNDICE DE FIGURAS

Figura 2.1. La atmósfera dividida en celdas tridimensionales	8
Figura 2.2. Diferentes caminos de simulación en el modelo WRF-ARW	13
Figura 2.3. Los componentes del modelo WRF y sus principales programas.....	14
Figura 2.4. Grilla horizontal tipo Arakawa-C del modelo WRF-ARW	16
Figura 2.5. Grilla horizontal con anidamiento de proporción 3:1	17
Figura 2.6. Coordenadas verticales del modelo WRF-ARW	18
Figura 2.7. Grilla vertical del modelo WRF-ARW	18
Figura 3.1. Los dos principales procedimientos de la metodología	28
Figura 3.2. Diagrama de flujo para el pronóstico de temperaturas.....	29
Figura 3.3. Dimensiones del dominio padre y de los anidamientos	31
Figura 3.4. Diagrama de flujo elegido en el estudio. Adaptación de la figura 2.2	34
Figura 3.5. Fuerza en el grado de correlación	46
Figura 3.6. Diagrama de flujo para la simulación de temperaturas	47
Figura 4.1. Comparación de temperaturas observadas y pronosticadas en la estación Chivay.....	59
Figura 4.2. Diagramas de dispersión y regresión lineal de los pronósticos - Estación Chivay.....	60
Figura 4.3. Comparación de temperaturas observadas y pronosticadas en la estación La Angostura	64
Figura 4.4. Diagrama de dispersión y regresión lineal de los pronósticos - Estación La Angostura	65
Figura 4.5. Comparación de temperaturas observadas y pronosticadas en la estación Lagunillas	69
Figura 4.6. Diagrama de dispersión y regresión lineal de los pronósticos - Estación Lagunillas	70
Figura 4.7. Comparación de temperaturas observadas y pronosticadas en la estación Pampahuta.....	74
Figura 4.8. Diagrama de dispersión y regresión lineal de los pronósticos - Estación Pampahuta.....	75
Figura 4.9. Variación del RMSE promedio para cada punto de validación	78
Figura 4.10. Variación del Índice de Willmott promedio para cada punto de validación...	78

Figura 4.11. Comparación de temperaturas observadas y simuladas en la estación Chivay.	81
Figura 4.12. Comparación de temperaturas observadas y simuladas en la estación La Angostura.	84
Figura 4.13. Comparación de temperaturas observadas y simuladas en la estación Lagunillas	87
Figura 4.13. Comparación de temperaturas observadas y simuladas en la estación Lagunillas	87
Figura 4.14. Comparación de temperaturas observadas y simuladas en la estación Pampahuta	90
Figura 4.15. Variación del RMSE promedio en los cuatro puntos de validación	92

ÍNDICE DE TABLAS

Tabla 2.1. Funciones de los programas del preprocesador WPS.....	15
Tabla 2.2. Funciones de los programas del procesador WRF-ARW.....	15
Tabla 3.1. Características de los datos de entrada	29
Tabla 3.2. Total de archivos descargados como fuente de entrada al modelo WRF.....	30
Tabla 3.3. Opciones generales elegidas para realizar los pronósticos.....	32
Tabla 3.4. Opciones de física elegidas para los pronósticos	33
Tabla 3.5. Hora de inicio y fin para cada pronóstico	35
Tabla 3.6. Características del ordenador utilizado para los pronósticos	36
Tabla 3.7. Total de horas obtenidas en los pronósticos	38
Tabla 3.8. Estaciones meteorológicas para la validación del modelo	40
Tabla 3.9. Total de <i>scripts</i> creados para cada ejecución del modelo	42
Tabla 3.10. Características de los datos de entrada para realizar las simulaciones.....	48
Tabla 3.11. Total de archivos descargados para realizar las simulaciones.....	48
Tabla 3.12. Configuración general elegida para las simulaciones	50
Tabla 3.13. Opciones de física elegidas para realizar las simulaciones	50
Tabla 3.14. Hora de inicio y fin de las simulaciones	51
Tabla 3.15. Características del ordenador utilizado para las simulaciones	52
Tabla 3.16. Total de horas simuladas obtenidas en cada simulacion	54
Tabla 3.17. Total de scripts creados para cada simulación	56
Tabla 4.1. Resumen de las medidas de precisión calculadas para cada pronóstico. Estación Chivay	58
Tabla 4.2. Resumen de las medidas de precisión calculadas para cada pronóstico. Estación La Angostura.....	63
Tabla 4.3. Resumen de las medidas de precisión calculadas para cada pronóstico. Estación Lagunillas.....	68
Tabla 4.4. Resumen de las medidas de precisión calculadas para cada pronóstico. Estación Pampahuta.....	73
Tabla 4.5. Promedios mensuales de las medidas de precisión obtenidos en cada punto de validación	76
Tabla 4.6. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación Chivay	80

Tabla 4.7. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación La Angostura	83
Tabla 4.8. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación Lagunillas	86
Tabla 4.9. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación Pampahuta	89
Tabla 4.10. Resumen de las medidas de precisión obtenidas en los cuatro puntos de validación.....	92

ÍNDICE DE ANEXOS

ANEXO 1: Configuración elegida en el preprocesador (WPS)	101
ANEXO 2: Configuración elegida en el procesador (WRF-ARW)	102
ANEXO 3: Configuración elegida en el postprocesador (ARWpost).....	104
ANEXO 4: Script utilizado para extraer los datos del modelo WRF	105

RESUMEN

Los modelos de predicción numérica regionales son de amplio uso hoy en día ya que pueden simular el comportamiento de la atmósfera a un nivel de mesoescala enfocándose en un determinado lugar del mundo, por eso se conocen también como modelos de mesoescala. El modelo *Weather Research and Forecasting* (WRF) es un modelo de mesoescala comunitario de última generación desarrollado en EE.UU. Al ser un modelo comunitario, el código fuente del modelo puede ser descargado desde internet de forma gratuita, lo que permite tener una tecnología sofisticada al alcance de cualquier usuario; sin embargo el manejo de este tipo de modelos requiere de un adiestramiento adecuado. Para el uso de un modelo de mesoescala sobre una determinada zona primero se tiene que verificar si el modelo tiene un buen comportamiento sobre esa zona, sobre todo si se pretende usar un modelo en zonas de alta variabilidad topográfica. La verificación de un buen comportamiento de un modelo sobre una zona específica se conoce como *validación del modelo*. De ese modo, el objetivo principal del presente estudio fue validar el modelo WRF en zonas altoandinas de Puno y Arequipa, de modo que luego el modelo pueda ser utilizado en estas zonas para el pronóstico de temperaturas, sobre todo cuando en estas zonas ocurren temperaturas extremas frías. Se realizaron pronósticos hasta con 120 horas de anticipación con una resolución temporal de salida del pronóstico horaria y se eligieron los meses de mayo y julio, ya que en estos meses suelen ocurrir las temperaturas extremas frías más perjudiciales en la región de Puno y Arequipa. Para evaluar estadísticamente los pronósticos, se utilizó el análisis de medidas de precisión realizado en (Willmott, C. 1982). Para la validación, se eligieron cuatro estaciones meteorológicas: Chivay y La Angostura ubicadas en la región de Arequipa, y las estaciones Lagunillas y Pampahuta uicadas en Puno. Los resultados de la validación mostraron que el modelo WRF logra simular significativamente el comportamiento diurno de las temperaturas en Chivay y Lagunillas, mientras que en La Angostura y Pampahuta la significancia de los pronósticos es menor. Una vez comprobado el buen comportamiento del modelo en estas zonas, se tendrán que realizar estudios adicionales para elegir las parametrizaciones adecuadas en el modelo para que los errores de pronósticos sean los mínimos posibles.

Palabras clave: Modelos de predicción numérica del tiempo, modelo WRF, validación, pronóstico, heladas.

ABSTRACT

Nowadays *regional numerical weather prediction models* have a wide utility because they can simulate the behavior of the atmosphere focusing over a determined place of the world at a mesoscale level, that is why they are also known as mesoscale models. The model Weather Research and Forecasting (WRF) is a mesoscale community state-of-the-art model developed in United States. Being WRF a community model, WRF is an open-source-code model downloadable from internet freely, allowing everyone to make use of this sophisticated technology, although the use of this kind of models requires a specialized training. First of all the use of mesoscale models over a determined zone requires to prove that the model has an appropriate behavior over that zone, especially on places which have a high topographic variability. The research to prove a good performance of the model is known as validation of the model. Thus, the goal in the present study is to validate the WRF model in highlands of Puno and Arequipa, Peru, so later the use of the WRF model can be used to do temperatures forecasts, above all when in these places extreme cold temperatures occur. The validation of the WRF model consisted at executing several 120-hour lead temperature forecasts through two months. Because of in May and July use to happen intense harmful frosts on these zones, these months were chosen to do the forecasts. The accuracy measures analysis given by (Willmott, C. 1982) was chosen so the statistic evaluation can be made. Also, for the validation it was chosen four station points: Chivay and La Angostura in Arequipa, Lagunillas and Pampahuta in Puno. The results showed that the WRF model achieves to simulate significantly the hourly behavior of temperatures at Chivay and Lagunillas unlike La Angostura and Pampahuta where the significance was less. Once proved a good behavior of the model, the next step is to make further researchers to figure out the adequate model parameterizations so the forecasts errors be as minimum as possible.

Key words: Numerical weather prediction models, WRF model, validation, forecast, frosts.

I. INTRODUCCIÓN

Año tras año en zonas altoandinas del Perú vienen ocurriendo intensas heladas con temperaturas tan bajas que afectan la calidad de vida de los habitantes de estas zonas. Las temperaturas, en época de invierno, pueden alcanzar valores muy por debajo de cero grados centígrados, los cuales, cada año, afectan las principales actividades económicas de estas zonas, tales como la agricultura y la ganadería. Esta afectación es aún más severa cuando estos eventos son inesperados, como por ejemplo las heladas que se producen en otoño y primavera (Atlas de heladas en el Perú. 2010, p.13). La ocurrencia de heladas con mayor intensidad se está dando actualmente en el Perú dentro de un contexto de Cambio Climático Global, donde el Perú es altamente vulnerable a este proceso por ser uno de los diez países más megadiversos del mundo (MINAM, 2012). De ese modo, tomando en cuenta que el *cambio climático* actual puede ser una de las razones de la alteración normal del comportamiento de estos eventos extremos fríos, es de interés ambiental también encontrar las herramientas tecnológicas adecuadas de hoy en día para luego prever la posibilidad de ocurrencia de heladas, y alertar y adecuar los métodos de defensa (Atlas de Heladas en el Perú. 2010, p.9).

El esfuerzo por predecir el comportamiento de la atmósfera en el siglo XX trajo consigo la concepción de modelos matemáticos que reproducían el comportamiento de la atmósfera con cierta precisión. Gracias a un mejor entendimiento del comportamiento de la atmósfera y de una mejor forma de representar ese comportamiento en los modelos, hoy en día estos modelos existen de tal modo que pueden pronosticar el tiempo con varios días de anticipación y con una precisión admirable, una clara muestra de la impresión que puede causar el conocimiento científico. Sin embargo, el uso de *modelos de predicción numérica del tiempo* implica realizar estudios previos que luego garanticen una precisión adecuada de los pronósticos. Uno de esos estudios es la validación de estos modelos, cuya finalidad principal es determinar si el comportamiento del modelo es representativo en la zona donde se pretende realizar los pronósticos. Hoy en día, el modelo de predicción numérica *Weather*

Reasearch and Forecasting (WRF) cuenta con una de las tecnologías más sofisticadas en el mundo, y que además, está al alcance de cualquier usuario de forma gratuita desde internet.

Tener en cuenta que los modelos numéricos no solo se usan para predecir eventos meteorológicos futuros, sino también para estudiar eventos meteorológicos pasados. De ese modo, el objetivo general del presente estudio es evaluar estadísticamente el comportamiento del modelo WRF en zonas altoandinas de Puno y Arequipa al simular temperaturas a dos metros de la superficie, de modo que luego el pronóstico de temperaturas extremas frías en estas zonas sea factible. Para cumplir el objetivo general se establecieron dos objetivos específicos:

- Validar el modelo WRF al realizar pronósticos de temperaturas con 120 horas de anticipación en zonas altoandinas de Puno y Arequipa,
- Validar el modelo WRF al realizar simulaciones de temperaturas con *datos de análisis* como condiciones de frontera en zonas altoandinas de Puno y Arequipa.

El primer objetivo se planteó con el fin de determinar si los pronósticos hasta con 120 horas de anticipación son analíticamente representativos, de modo que luego se pueda usar el modelo para el pronóstico de temperaturas menores o iguales a 120 horas de anticipación. El segundo objetivo se planteó para verificar si el modelo logra un buen comportamiento en la simulación de temperaturas más allá de la predictibilidad estimada en modelos de mesoescala usando datos de análisis como condiciones de frontera, de modo que se reafirme un buen comportamiento del modelo y se compruebe la calidad de estos datos de análisis.

II. REVISIÓN DE LITERATURA

2.1. ANTECEDENTES

Cada año, principalmente en los meses de invierno, ocurren heladas en el Perú. Las heladas suelen ocurrir en zonas altoandinas donde los factores meteorológicos, así como las características físicas propias de la zona permiten el desarrollo de estos eventos extremos fríos llegando las temperaturas mínimas a presentar valores muy por debajo de 0°C.

En los últimos años, las heladas vienen teniendo un comportamiento variable, apareciendo de forma temprana o en forma tardía. Dependiendo de la estación del año, las heladas pueden llegar a ser muy adversas. Según la ocurrencia de estas, pueden afectar considerables áreas de cultivos, sacrificar cientos de cabezas de ganado y peor aún, afectar la calidad de vida de mucha gente. Las heladas más devastadoras, considerando la afectación a los cultivos, se producen en otoño y primavera (Atlas de Heladas en el Perú, 2010, p.13). Según (Grupo Perú COP 20, 2013), el comportamiento variable de las heladas y friajes en el Perú pueden ser efectos del actual *Cambio Climático* que se viene dando en diferentes zonas del mundo.

En relación a estos eventos extremos fríos, el Gobierno de turno viene aplicando, desde el 2012, planes de prevención para afrontar estos eventos, por lo que el año 2014 se aprobó el “Plan Multisectorial para la atención de Heladas y Friajes 2014”; cuyo objetivo es articular esfuerzos multisectoriales para la preparación, respuesta y rehabilitación frente a la temporada de heladas y friajes en el Perú (CENEPRED, 2014).

En el plan Multisectorial propuesto para el 2014, liderado por el Ejecutivo, se señala que dentro de la Región de Arequipa se encuentran siete distritos considerados como zonas críticas susceptibles de sufrir heladas, mientras que en Puno existen 74 distritos. En ese contexto se crea el proyecto *Sistemas de Alerta Temprana para Eventos Extremos Fríos*, (FRIO-SAT) liderado por el grupo de investigación ambiental INCLIMA, cuyo objetivo del

proyecto no solo fue establecer un sistema de alerta temprana en el Perú, sino también incentivar la generación de conocimiento científico a través de trabajos de investigación como el presente.

2.2. MODELOS DE PREDICCIÓN NUMÉRICA (NWP)

Un *modelo de predicción numérica* es una representación matemática codificada a lenguaje de ordenador de los procesos dinámicos, físicos, químicos y radiativos de la atmósfera (Jacobson, M., 2005, p.6). (Coiffier, J. 2012, p.xi) menciona que los modelos no solo son un sistema de ecuaciones que gobiernan el comportamiento continuo de la atmósfera, sino también hay que incluir en la definición la forma en que estas ecuaciones son resueltas en el modelo. Las soluciones a esas ecuaciones son plasmadas en algoritmos, por lo que los *modelos numéricos atmosféricos* están organizados en programas de computadora. Al estar organizados en programas informáticos y seguir los procedimientos de la ingeniería de *software*, un modelo se expresa computacionalmente como un *software* (Brookshear, J. 2012, p.2), aunque conceptualmente un modelo atmosférico no sea un *software*.

Con el avance y el desarrollo de estos modelos numéricos y el avance también de la potencia de las computadoras, los *modelos de predicción numérica* tienen en la actualidad diversas aplicaciones. En (Warner. T. T., 2011, cap.1) se menciona que estos modelos pueden ser utilizados en agricultura para estimar periodos de siembra, de cosechas e irrigaciones; determinar lugares donde fijar determinados cultivos; en la aviación para estimar turbulencias, nubosidad, formación de hielo, etc.; en el sector energético para predecir el tiempo y estimar la demanda de electricidad, calefacción y refrigeración; para estimar los mejores lugares donde se pueda construir fuentes de energías renovables. Una de las principales aplicaciones de estos modelos se da cuando estos son acoplados con otros tipos de modelos tales como modelos de calidad de aire, modelos hidrológicos (para predecir inundaciones) o modelos climáticos (para predecir eventos climáticos como el Fenómeno de El Niño).

Los *modelos de predicción numérica* se pueden clasificar en modelos globales que cubren toda la superficie de la tierra y en modelos de mesoescala o también llamados modelos regionales. Estos últimos, por enfocarse en un área específica de la tierra para realizar sus simulaciones, son también llamados modelos de área limitada (Coiffier, J. 2011, p.263). Los

modelos globales se encargan de predecir procesos atmosféricos a escala planetaria tales como ciclones, anticiclones, etc.; en cambio los modelos de mesoescala tienen una suficiente resolución vertical y horizontal para simular procesos atmosféricos tales como turbulencia, convección de nubes, tornados, tormentas, estados del mar, etc.

Para entender cómo funciona un modelo numérico hay que saber que cada modelo numérico se divide en dos partes: la dinámica y la física del modelo (Dudhia, J. 2014). La parte dinámica del modelo está conformada por las ecuaciones primitivas que gobiernan la dinámica de la atmósfera, y la parte física está conformada por los procesos físicos a nivel local que no pueden resolverse directamente y que por eso tienen que ser representados dentro del modelo de forma simplificada (parametrizaciones).

2.2.1. LAS ECUACIONES GOBERNANTES

El sistema de ecuaciones que gobiernan la dinámica de la atmósfera es la base para el desarrollo de los *modelos de predicción numérica* (Warner, T. 2011, p.6). Estas ecuaciones son las siguientes:

$$\frac{\partial u}{\partial t} = -u \frac{\partial u}{\partial x} - v \frac{\partial u}{\partial y} - w \frac{\partial u}{\partial z} + \frac{uv \tan \phi}{a} - \frac{uw}{a} - \frac{1}{\rho} \frac{\partial p}{\partial x} - 2\Omega(w \cos \phi - v \sin \phi) + Fr_x \quad (1)$$

$$\frac{\partial v}{\partial t} = -u \frac{\partial v}{\partial x} - v \frac{\partial v}{\partial y} - w \frac{\partial v}{\partial z} + \frac{u^2 \tan \phi}{a} - \frac{uw}{a} - \frac{1}{\rho} \frac{\partial p}{\partial y} - 2\Omega u \sin \phi + Fr_y \quad (2)$$

$$\frac{\partial w}{\partial t} = -u \frac{\partial w}{\partial x} - v \frac{\partial w}{\partial y} - w \frac{\partial w}{\partial z} - \frac{u^2 + v^2}{a} - \frac{1}{\rho} \frac{\partial p}{\partial z} - 2\Omega u \cos \phi - g + Fr_z \quad (3)$$

$$\frac{\partial T}{\partial t} = -u \frac{\partial T}{\partial x} - v \frac{\partial T}{\partial y} - w \frac{\partial T}{\partial z} + (\gamma - \gamma_d)w + \frac{1}{c_p} \frac{dH}{dt} \quad (4)$$

$$\frac{\partial \rho}{\partial t} = -u \frac{\partial \rho}{\partial x} - v \frac{\partial \rho}{\partial y} - w \frac{\partial \rho}{\partial z} - \rho \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} + \frac{\partial w}{\partial z} \right) \quad (5)$$

$$\frac{\partial q_v}{\partial t} = -u \frac{\partial q_v}{\partial x} - v \frac{\partial q_v}{\partial y} - w \frac{\partial q_v}{\partial z} - Q_v \quad (6)$$

$$p = \rho RT \quad (7)$$

Las tres primeras ecuaciones, (1) a (3), son ecuaciones de momentum para una Tierra esférica, los cuales representan a la segunda ley del movimiento de Newton. La ecuación (4) representa la ecuación termodinámica de la conservación de la energía. La ecuación de continuidad para la masa total está representada en la ecuación (5). La ecuación (6) es análoga a la ecuación (5), solo que esta aplicada para vapor de agua. Y por último la ecuación que representa la ley de los gases ideales (7). Las variables meteorológicas tienen su significado *standard*. Las variables independientes u , v y w son las componentes de velocidad cartesiana, p es la presión, ρ es la densidad, T es la temperatura, q_v es la humedad específica, Ω es la frecuencia rotacional de la Tierra, ϕ es la latitud, a es el radio de la tierra, γ es el gradiente de temperatura, γ_d es el gradiente adiabático seco, c_p es el calor específico del aire a presión constante, g es la aceleración de la gravedad, H representa la pérdida o ganancia de calor, Q_v es la pérdida o ganancia de vapor de agua a través de cambios físicos, y Fr es un término de fricción genérica en cada dirección de coordenada.

Este sistema de ecuaciones recibe el nombre de *ecuaciones gobernantes de la dinámica de la atmosfera* o también *ecuaciones primitivas*; todos los modelos de predicción numérica ya sea operacionales o de investigación están basados sobre alguna versión de estas ecuaciones (Warner, T. 2011, p.7). La exacta formulación y resolución de estas ecuaciones puede afectar la precisión de los pronósticos y simulaciones.

Ya que estas ecuaciones no pueden ser resueltas analíticamente, ellas deben ser convertidas a una forma en que puedan ser resueltas. Para resolver estas ecuaciones normalmente se usan métodos numéricos (Warner, T. 2011, p.6).

2.2.2. LOS PROCESOS FÍSICOS

La parte física de los modelos está conformada por esos procesos físicos que ocurren en la atmósfera y que son muy complejos como para ser incluidos de forma exacta en los modelos. Estos procesos físicos son por ejemplo los procesos radiativos, los procesos de microfísica de nubes, los movimientos turbulentos en la capa límite planetaria (PBL), etc. Debido a su compleja naturaleza, los procesos físicos son representados en los modelos de forma simplificada. A estas simplificaciones de los procesos físicos se les conoce como

parametrizaciones. Estas parametrizaciones relacionan algorítmicamente o estadísticamente los efectos de los procesos físicos (Warner, T. 2011, p.119).

En (Warner, T. 2011, p.119) se menciona claramente tres razones de porqué estos procesos físicos son parametrizados:

- Las pequeñas escalas involucradas en las simulaciones conlleva a un gran consumo computacional para representar los procesos directamente.
- La complejidad de los procesos físicos conlleva también a un gran consumo computacional para representar los procesos directamente.
- Existe un conocimiento insuficiente acerca del comportamiento de estos procesos físicos para explícitamente representarlos matemáticamente.

La representación de los procesos físicos en los modelos interactúa también con la dinámica del modelo. Incluso aunque los procesos físicos son parametrizados realizando grandes simplificaciones de los mismos, su adecuada representación en un modelo también es esencial para la predicción de todas las variables meteorológicas (Warner, T. 2011, p.119). Las parametrizaciones de los procesos físicos hoy en día es un campo de intensa investigación (Kalnay, E. 2003, p. 129)

2.2.3. EL SISTEMA DE MODELAMIENTO

En el caso de la mayoría de modelos de predicción numérica, el sistema de modelamiento consiste en dividir el espacio en celdas tridimensionales, tal como se muestra en la figura 2.1. A ese conjunto de celdas tridimensionales se le llamará *grilla* en el presente estudio.

El proceso de simulación en un modelo consiste en resolver las ecuaciones gobernantes de la dinámica de la atmósfera en puntos determinados de cada celda de simulación (Warner, T. 2011, p.20), figura 2.1, al mismo tiempo que las parametrizaciones también son resueltas en cada celda (NOAA, et al. MetEd. 2008). De esa forma la atmósfera evoluciona en el tiempo en cada celda calculándose los valores de las variables meteorológicas en puntos específicos de cada celda para cada cierto tiempo. A ese proceso de resolver las ecuaciones

en determinados puntos de cada una de estas celdas tridimensionales ya no para variables continuas sino ahora para variables discretas y en cada cierto tiempo, se denomina *discretización* (Coiffer, J. 2011, p.1).

Como se tiene que resolver las ecuaciones en cada punto de celda de la *grilla* tridimensional y para varios tiempos, se requieren de ordenadores muy potentes para realizar todos esos cálculos, sobre todo en el uso de modelos globales.

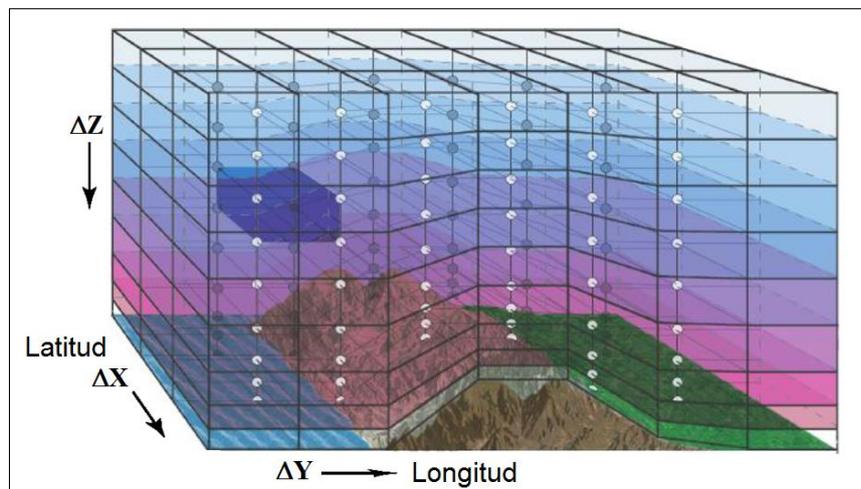


Figura 2.1. La atmósfera dividida en celdas tridimensionales

FUENTE: Neelin, J. David, 2011.

Algunos modelos globales como el *Global Forecasting Systems* (GFS) usan un cierto número de ondas para representar la atmósfera y no un grillado tridimensional. A ese tipo de modelos se les conocen como *modelos espectrales*.

La mayoría de modelos globales como el GFS utilizan una suposición que simplifica la resolución de las ecuaciones a niveles globales. La suposición es la de considerar a la atmósfera como un fluido hidrostático. Esa suposición es una de las grandes diferencias entre modelos globales y los actuales modelos de mesoescala, ya que estos últimos generalmente utilizan una suposición no hidrostática. La suposición hidrostática funciona muy bien a escala global, sin embargo cuando se quiere analizar procesos atmosféricos de meso o micro escala como tormentas o convección de nubes, esa suposición ya no trabaja muy bien (Kalnay, E. 2003, p.25).

2.3. DATOS DE ANÁLISIS

Muchos servicios meteorológicos en el mundo recolectan observaciones de variables meteorológicas en diversos puntos alrededor del mundo provenientes de estaciones meteorológicas, de satélites, de aviones, de barcos, etc. Sin embargo, estas observaciones, en un inicio, están distribuidas en el planeta, tanto en espacio como en tiempo, de forma desigual. Para subsanar este problema de desigualdad, los servicios meteorológicos juntan estas observaciones, las evalúan analíticamente para comprobar su exactitud, y las ordenan en una *grilla* tridimensional (Warner, T. 2011, p.199), de modo que estas observaciones estén distribuidas regularmente tanto en espacio y tiempo en esa misma grilla. A ese proceso de evaluar *analíticamente* las observaciones para diferentes estados de la atmósfera se conoce como *Asimilación de Datos*, y a los datos provenientes de este proceso se les como *datos de análisis*. Una vez que los *datos de análisis* estén ordenados en *grillas* tridimensionales recién pueden ser utilizados en *modelos de predicción numérica*. Estos *datos de análisis* son los que, por lo general, se utilizan como *condiciones iniciales* (CI) en los modelos para realizar pronósticos y/o simulaciones.

En diversos servicios meteorológicos alrededor del mundo se pueden encontrar *datos de análisis* para diversas horas del día. Estos *datos de análisis* al estar libremente disponibles en internet, pueden ser utilizados en los modelos para realizar una gran variedad de trabajos de investigación, tales como realizar simulaciones de eventos meteorológicos pasados, para realizar estudios climáticos, estudios de calidad de aire, etc.,

2.4. MODELOS ATMOSFÉRICOS DE MESOESCALA

Los *modelos atmosféricos de mesoescala* son esos modelos que tienen un sistema de modelamiento construido para resolver los procesos físicos que ocurren a nivel de mesoescala en una determinada región del planeta (aunque en algunos casos se pueden utilizar para hacer simulaciones globales). Estos modelos, al enfocarse en una región del planeta son conocidos también como *modelos regionales*.

Los primeros modelos de mesoescala fueron desarrollados en la década de los 70's en Estados Unidos, el Reino Unido y Australia (Dudhia, J., 2014). En un inicio estos modelos

empezaron con la condición hidrostática y modelando a bajas resoluciones espaciales (Dudhia, J., 2014). Sin embargo, con el avance en el desarrollo de estos modelos y el avance en el poder de las computadoras, estos modelos se han hecho más sofisticados, donde ahora incluyen el criterio no hidrostático en sus sistemas de modelamiento, operando a altas resoluciones espaciales y representando mejor los procesos físicos (parametrizaciones).

Existen modelos de mesoescala que realizan pronósticos operacionales como el modelo operacional de los Estados Unidos (NAM) o el modelo operacional del Reino Unido (*Met Office Unified Model*) que requieren de un adiestramiento especializado y de potentes computadoras. Sin embargo, existe otros modelos de mesoescala llamados modelos comunitarios (Dudhia, J., 2014). Estos modelos adquieren el nombre “comunitario” principalmente porque están a libre disposición desde internet y porque al mismo tiempo los usuarios de estos modelos alrededor del mundo contribuyen en el desarrollo y mejoramiento de estos modelos. Algunos de los modelos comunitarios más conocidos en el mundo son el MM5, el RAMS y el WRF. Estos modelos comunitarios no requieren, según sea el caso, de potentes ordenadores y pueden ser corridos incluso en ordenadores personales. Debido a su libre acceso, estos modelos comunitarios son muy usados en países donde no se cuenta con el adiestramiento adecuado para desarrollar *modelos de predicción numérica*.

Si bien los diferentes modelos de mesoescala utilizan las mismas ecuaciones que gobiernan la dinámica de la atmósfera, los diferentes modelos de mesoescala que existen hoy en día se diferencian principalmente en los métodos que utilizan para resolver las ecuaciones que gobiernan la dinámica de la atmósfera y en la forma como representan a los procesos físicos.

2.5. CONDICIONES INICIALES Y DE FRONTERA

Para poner en funcionamiento un modelo de predicción numérica, este necesita obligatoriamente de unas condiciones de iniciales (CI), unas condiciones iniciales que ingresen a las ecuaciones que gobiernan la dinámica de la atmósfera explicadas en la sección 2.2.1. Estas CI no solo contienen el valor de las variables meteorológicas que predominan en ese instante de la atmósfera necesario para poner en marcha el pronóstico, sino también contienen los factores meteorológicos propios de la zona, tales como altitud, albedo, tipo de suelo, cobertura vegetal, etc. Las CI actúan en el instante inicial que dará comienzo al modelamiento (en la hora inicial del modelamiento).

A diferencia de los modelos globales que actúan sobre todo el globo y que solo necesitan de condiciones iniciales, la mayoría de modelos de mesoescala actúan sobre un limitado espacio tridimensional del globo. Debido a este limitado espacio, los modelos de mesoescala no solo necesitan de unas *condiciones iniciales* (CI) para arrancar el modelamiento, sino que además, cada hora de pronóstico establecida en un modelo de mesoescala necesitará de los valores iniciales en los contornos de este espacio tridimensional. Estos valores iniciales en los límites laterales para cada hora de pronóstico de este espacio tridimensional se conocen como *condiciones de frontera* (CF) o *condiciones de contorno*. Cuando se trata de utilizar un modelo de mesoescala para predecir el tiempo, necesariamente las CI tienen que ser *datos de análisis* y las CF deben ser datos de pronóstico. Tener presente que los modelos de mesoescala utilizarán estos datos de pronóstico solo en el contorno de este espacio tridimensional y no dentro de este espacio; el propio modelo de mesoescala con su mecanismo de modelamiento simulará resolver los procesos físicos de mesoescala dentro de este espacio y generará los pronósticos dentro de este espacio tridimensional para cada tiempo de pronóstico establecido. Los datos de pronóstico que deben ingresar a un modelo de mesoescala para establecer las CF generalmente provienen de modelos globales y son, por lo general, de menor resolución espacial que las resoluciones espaciales que comúnmente se pueden lograr en modelos de mesoescala.

Las CI siempre deben ser *datos de análisis* porque estos datos tienen la característica de ser más precisos que los *datos de pronóstico*, y como lo menciona (Kalnay, E. 2003, p.1), la precisión de los pronósticos está determinada por la precisión de las CI y por la representación realística de la atmósfera que se incorpora en los modelos. En modelos de mesoescala las CI y CF son de igual importancia, y son un factor clave para obtener pronósticos de alto grado de precisión.

Como las CI y las CF son obtenidos generalmente desde modelos globales, estos dos tipos de modelos (tanto global como de mesoescala) se complementan entre sí. A esa técnica de modelamiento por el cual se utiliza un modelo de mesoescala para pasar los datos de menor resolución (provenientes de modelos globales) a una mayor resolución, se denomina *downscaling dinámico* (Warner, T. 2011, p.433).

2.6. EL MODELO WEATHER RESEARCH AND FORECASTING (WRF)

El modelo de mesoescala *Weather Research and Forecasting* (WRF) es un modelo de predicción numérica comunitario de última generación desarrollado no solo para realizar pronósticos, sino también para hacer investigación y/o docencia (Guía de Usuario WRF. 2014). El modelo fue desarrollado en Estados Unidos a finales de los 90's al combinar esfuerzos de muchos científicos de agencias gubernamentales de los Estados Unidos, tales como la *National Center for environmental Prediction* (NCEP), la *National Center for Atmospheric Research* (NCAR), la *Naval Research Laboratory* (NRL), la *Federal Aviation Administration* (FAA); y de universidades como la Universidad de Oklahoma.

El modelo WRF posee una plataforma computacional eficiente y flexible ofreciendo una variedad de opciones para realizar simulaciones con el modelo. Actualmente el modelo es oficialmente manejado por la *National Center for Atmospheric Research* (NCAR) y por la *University Corporation for Atmospheric Research* (UCAR). Estas instituciones están constantemente actualizando el modelo, y además, reciben recomendaciones de todos los usuarios alrededor del mundo para mejorar paulatinamente la tecnología del modelo. El modelo es de código abierto de modo que puede ser descargado libremente. A la fecha la última versión del modelo es la versión 3.7, publicada en abril del 2015. Hasta el momento el modelo solo ha sido probado satisfactoriamente en sistemas operativos (OS's) basados en UNIX como Darwin o AIX, o en OS's cuyo *kernel* sea LINUX. Más información del *software*, *hardware* y otras utilidades necesarias para disponer del modelo en un ordenador se puede encontrar en la Guía de Usuario del modelo, publicado libremente en internet.

El modelo cuenta con dos núcleos dinámicos de operación, el *Advance Reaserch WRF* (WRF-ARW) y el *WRF Non-hydrostatic Mesoscale Model* (WRF-NMM). El primer núcleo fue desarrollado y es mantenido actualmente por la *NCAR Mesoscale and Microscale Meteorology Division* (NCAR-MMM), y el segundo núcleo fue desarrollado por la NOAA/NCEP y la *Developmental Testbed Center* (DTC). El núcleo dinámico ARW, es un núcleo que ofrece más opciones en su configuración, que lo hace más versátil para ser utilizado alrededor del mundo (Dudhia J., 2014). El núcleo dinámico WRF-NMM es más rápido y más eficiente y por eso tiene más fines operacionales, en cambio el núcleo WRF-ARW es más versátil y fácil de manejar, por eso el núcleo WRF-ARW es actualmente el

más utilizado alrededor del mundo. Los dos núcleos vienen integrados en el mismo paquete informático.

2.6.1. SISTEMA DE MODELAMIENTO DEL MODELO WRF

El sistema de modelamiento del modelo WRF-ARW consta de tres principales componentes que tienen que ser operados cuidadosamente. Estos componentes se describen en la sección 2.6.2. Una de las ventajas del modelo WRF es que tiene su propio sistema de *asimilación de datos* (WRFDA) que permite mejorar la calidad de las condiciones iniciales. Otra ventaja del modelo es que se pueden hacer *simulaciones ideales* para verificar la correcta instalación del modelo en los ordenadores. Asimismo, como la muestra la figura 2.2, se puede usar el modelo utilizando diferentes caminos de simulación. Esa variedad de caminos de simulación hace al modelo versátil para su uso en diferentes aplicaciones.

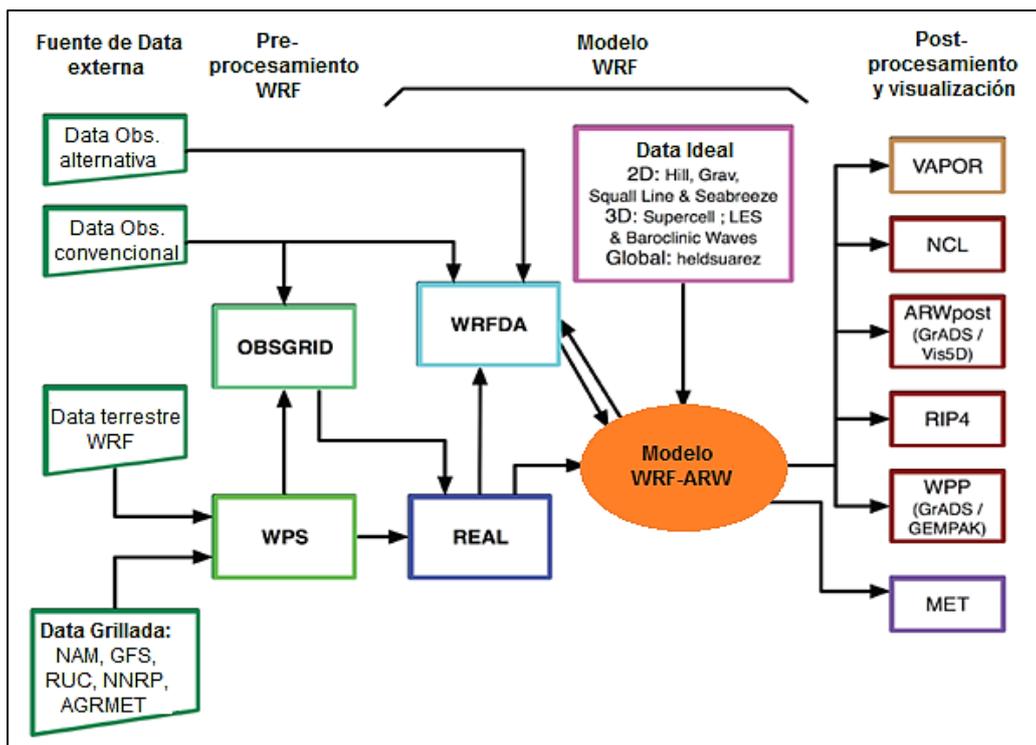


Figura 2.2. Diferentes caminos de simulación en el modelo WRF

FUENTE: Guía de usuario del modelo WRF-ARW (2014)

El sistema de modelamiento del modelo permite también simular eventos meteorológicos del pasado gracias a la disposición que se tiene de *datos de análisis* de eventos atmosféricos pasados y que son generados principalmente por modelos globales. Estos *datos de análisis*

del pasado pueden ser obtenidos en diferentes servicios meteorológicos a través de internet. Estos *datos de análisis* del pasado se utilizan para llevar a cabo diferentes trabajos de investigación en *predicción numérica* tanto del tiempo como del clima.

2.6.2. COMPONENTES DEL MODELO WRF

En la figura 2.3 se resume los tres principales componentes del modelo: el preprocesador (WPS), el procesador y el postprocesador. La figura 2.3 también muestra los principales programas que cada componente lleva integrado para realizar la ejecución del modelo. Cada componente viene en un diferente paquete informático, por lo que se tienen que instalar y configurar de forma independiente. Para visualizar las salidas del modelo se tiene que usar el *software* GRADS, por eso este se incluye como parte de los programas del postprocesador, figura 2.3. Actualmente el *software* NCL viene siendo preferido en lugar del GRADS, ya que prescinde del uso del ARWpost y de GRADS.

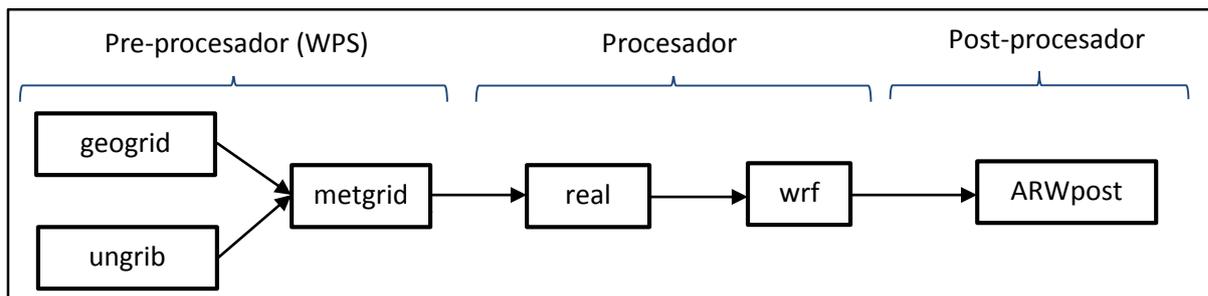


Figura 2.3. Los componentes del modelo WRF y sus principales programas

FUENTE: Elaboración Propia

A. Preprocesador del modelo WRF (WPS)

El preprocesador del modelo tiene como objetivo principal preparar los datos de entrada para el segundo componente del modelo. Para lograr esto cuenta con tres importantes programas: el *geogrid*, el *ungrid* y el *metgrid*. Las principales funciones de estos programas se muestran en la tabla 2.1.

Tabla 2.1. Funciones de los programas del preprocesador WPS

Programas WPS	Funciones
<i>Geogrid</i>	<ul style="list-style-type: none"> - Define la proyección del mapa terrestre - Establecer el lugar geográfico y las dimensiones de los dominios - Interpola los datos terrestres estáticos horizontalmente (altura de topografía, uso de suelo, tipo de suelo, vegetación, albedo)
<i>Ungrib</i>	<ul style="list-style-type: none"> - Pasa los datos de entrada desde un formato GRIB a un formato intermedio entendido por el modelo. - Extrae los campos meteorológicos necesarios de los datos de entrada
<i>Metgrid</i>	<ul style="list-style-type: none"> - Interpolar horizontalmente los datos meteorológicos de entrada extraídas por el <i>ungrib</i> para los dominios definidos por el <i>geogrid</i>. - Interpolar otros campos meteorológicos a la ubicación “θ” de las celdas de <i>grilla</i> del modelo WRF.

FUENTE: Guía de Usuario del modelo WRF v.3.4

B. Procesador del modelo WRF-ARW

Este es el componente más importante del modelo, es el que se encarga de realizar la integración numérica tanto en las coordenadas horizontales como en las coordenadas verticales del modelo. Este componente está conformado por dos programas: el *real* y el *wrf*. Las funciones de estos programas se muestran en la tabla 2.2.

Tabla 2.2. Funciones de los programas del procesador WRF-ARW

Programas WRF	Funciones
<i>Real</i>	<ul style="list-style-type: none"> - Elige los niveles del modelo en la vertical. - Interpola los datos a los niveles del modelo en la vertical - Crea las condiciones iniciales de los dominios que se eligen. - Crea las condiciones de frontera de la simulación
<i>Wrf</i>	<ul style="list-style-type: none"> - Hacer las integraciones numéricas de la simulación - Usar los cálculos de la parametrizaciones físicas para la simulación.

FUENTE: Guía de Usuario del modelo WRF v.3.4

C. Postprocesador y herramientas de visualización

Es en este componente donde se postprocesa los archivos de salida del procesador del modelo, de modo que estos puedan visualizarse y/o analizarse. Este componente está conformado por el programa ARWpost, que permite convertir los archivos de salida del

simulador WRF a un formato en el que pueda ser leído por otro *software*. El software GRADS permite visualizar los archivos de salida en formato *.ctl* provenientes del ARWpost y también hace uso de *scripts* para extraer datos de este archivo *.ctl* en formato *.txt*.

2.6.3. GRILLA HORIZONTAL DEL MODELO WRF

El tipo de grilla horizontal que utiliza el modelo WRF es del tipo Arakawa C, tal y como se muestra en la figura 2.4. En determinados puntos de esta grilla horizontal se calculan las variables meteorológicas necesarias para la simulación. En la figura 2.4 los componentes v y u corresponden a variables vectoriales, como por ejemplo la dirección de los vientos, los cuales se encuentran determinados en el centro de cada lado de una celda de grilla. Las variables “ θ ” corresponden a variables escalares, tales como temperatura, humedad relativa, etc. Las variables “ θ ” están localizadas en el centro de cada celda de *grilla* y representan el promedio de esa variable en toda esa celda de *grilla* (Coiffer, J. 2011, p.268).

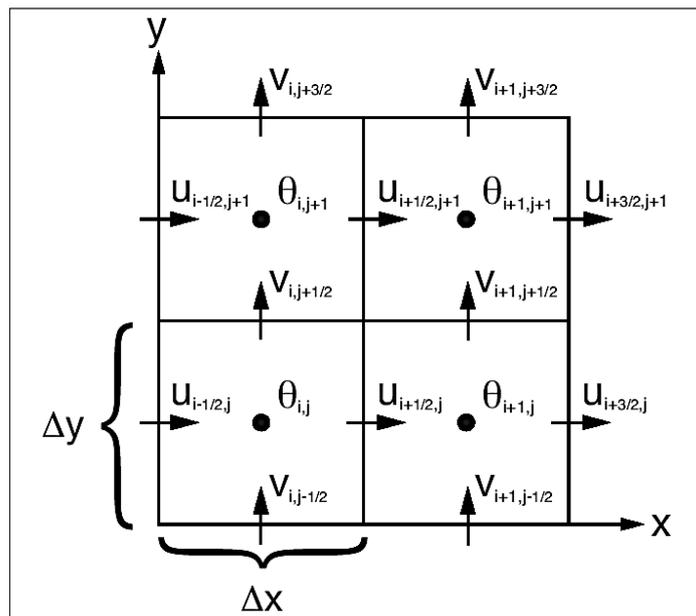


Figura 2.4. Grilla horizontal tipo Arakawa-C del modelo WRF-ARW

FUENTE: Skamarock, W., et al. (2008)

A diferencia de la figura 2.4, en la figura 2.5 se muestra la *grilla* horizontal de un dominio parental con un anidamiento de proporción 3:1. La elección de realizar las simulaciones estableciendo anidamientos permite ejecutar el modelo sin consumir demasiado recurso computacional (Wang, W., 2014).

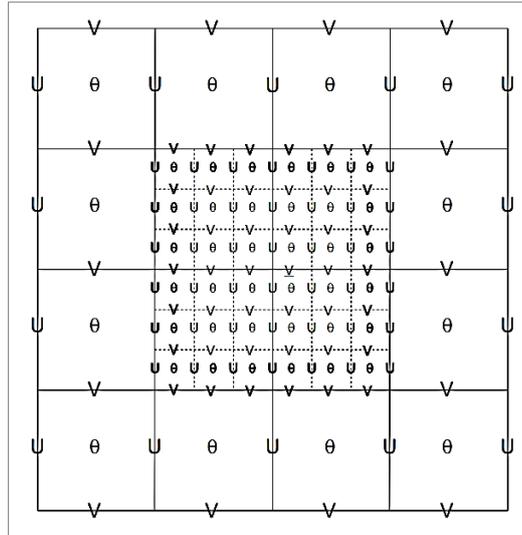


Figura 2.5. Grilla horizontal con anidamiento de proporción 3:1

FUENTE: Skamarock, W., et al. (2008)

2.6.4. GRILLA VERTICAL Y COORDENADAS VERTICALES DEL MODELO WRF

Las coordenadas verticales que usa el modelo se conocen como coordenadas verticales del tipo sigma (σ), un tipo de coordenadas que imita la forma del relieve topográfico para mejorar las simulaciones. Estas coordenadas permiten calcular las variables meteorológicas en puntos determinados de cada celda de simulación según la grilla vertical del modelo (figura 2.7). Las coordenadas verticales se denotan por el valor de η , de la siguiente forma:

$$\eta = \frac{P_h - P_{ht}}{\mu} \quad ; \quad \mu = P_{hs} - P_{ht}$$

Dónde:

η : Coordenada vertical

P_h : Componente hidrostática de la presión

P_{hs} : Componente hidrostática de la presión en la superficie

P_{ht} : Componente hidrostática de la presión a un nivel de altura

Los valores de η varían de uno en la superficie a cero en el nivel más alto del dominio como se muestra en la figura 2.6.

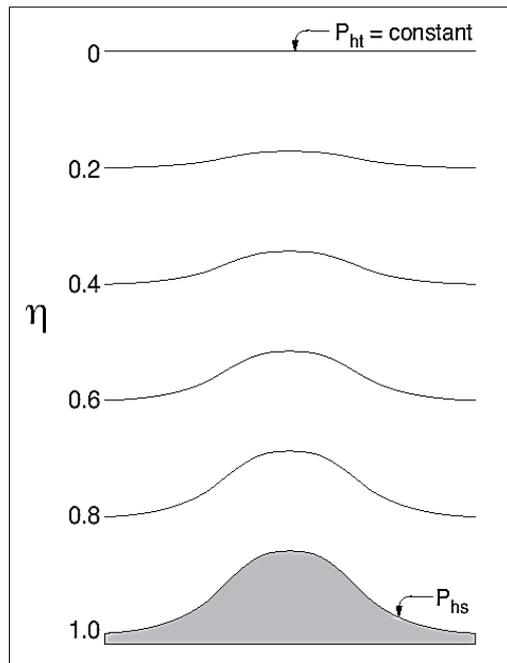


Figura 2.6. Coordenadas Verticales del Modelo WRF-ARW

FUENTE: Skamarock, W., et al. (2008)

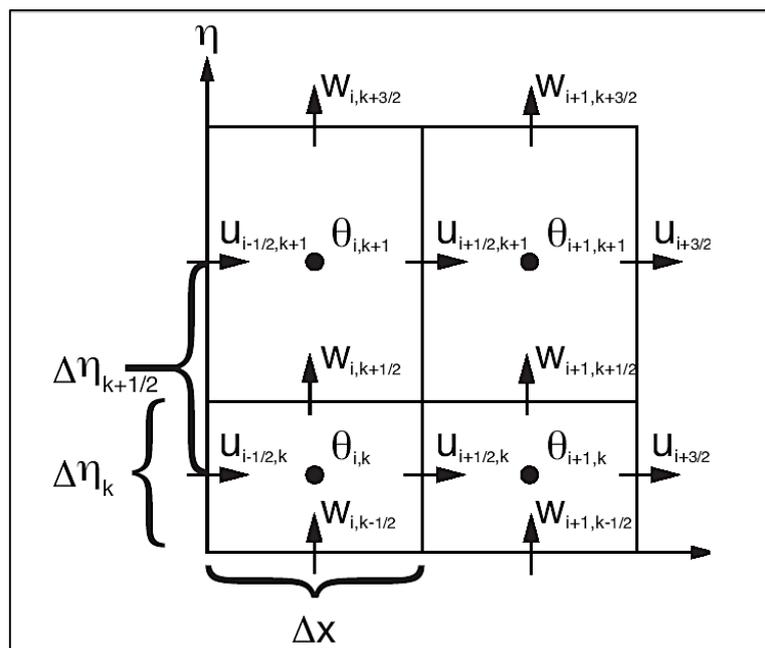


Figura 2.7. Grilla Vertical del Modelo WRF-ARW

FUENTE: Skamarock, W., et al. (2008)

2.7. VALIDACIÓN DE MODELOS DE PREDICCIÓN NUMÉRICA

En textos de modelamiento numérico de la atmósfera se usa verificación y validación indistintamente para referirse a los procedimientos necesarios para evaluar la

representatividad de las simulaciones (Warner, T. T., 2011, p.294). Sin embargo, en (Debbabi, M. et al. 2010, p.75) se hace una diferencia entre estos dos términos, primero se menciona que *verificación* se refiere a la comprobación de si un modelo ha sido construido correctamente, y *validación* se refiere a la comprobación de si un modelo es el adecuado para lo que se busca representar.

En el presente estudio se utilizará el término validación y verificación indistintamente. En cualquier caso la credibilidad de los resultados de un modelo de predicción numérica involucra la comparación entre valores simulados y valores observados, utilizando técnicas estadísticas y/o métodos gráficos de comparación (Warner, T., 2011, p.294).

Es necesario considerar que la validación de un modelo de predicción numérica es necesario antes de su utilización en una determinada región del globo, principalmente en zonas de alta variabilidad topográfica (Warner, T. T., 2011, p.301).

2.7.1. MEDIDAS DE PRECISIÓN

Según (Jolliffe, I. T. et al. 2003, p.26), para evaluar la calidad de los pronósticos existen medidas de precisión (*accuracy*), medidas de asociación, y medidas de capacidad o destreza (*skill*). El análisis de medidas de precisión hoy es el más utilizado al evaluar estadísticamente pronósticos de variables discretas de modelos de predicción numérica, sobre todo las el error medio absoluto (MAE), la raíz del error cuadrático medio RMSE y el coeficiente de correlación. Sin embargo, existen en la bibliografía diferentes formas de evaluar los pronósticos con otras medidas de precisión más elaboradas y con otras medidas que miden no solo precisión, sino también la habilidad (*skill*) del modelo para pronosticar. Más información se puede encontrar en (Wilks, D. S. 2006, p.280). Cada una de las medidas de precisión explica algún tipo de relación que pueda haber entre los valores simulados y observados basándose en la diferencia entre valores simulados y observados; esa diferencia también se conoce como *error de pronóstico*, *error de simulación*, o *residuo*.

Según (Willmott, C. J., 1982), para analizar los errores de pronóstico se deben calcular e interpretar como mínimo, las siguientes medidas: la media de los valores observados (\bar{O}), la media de los valores pronosticados (\bar{P}), la desviación estándar de los variable pronosticada (S_p), la desviación estándar de la variable observada (S_o), el intercepto de la ecuación de

regresión lineal (a), la pendiente de la ecuación de regresión lineal (b), el error absoluto medio MAE, la raíz del error cuadrático medio RMSE, el coeficiente de correlación (r), y por último el índice de Willmott. Como tanto el MAE como el RMSE son medidas que no tienen valores límites, (Willmott, C. J., 1982) hace uso de un índice de concordancia (d), que para el presente estudio se llamará índice de Willmott y que se explicará más adelante.

De ese modo, las siguientes medidas de precisión son las medidas de mayor uso hoy en día al evaluar pronósticos y/o resultados de simulación:

A. Sesgo o *bias*

El sesgo o *bias* es la diferencia entre la media de los valores simulados con la media de los valores observados. Aunque (Wilks, D. S., 2006) no considera a esta medida una medida de precisión en sí, esta medida es importante para evaluar que tan alejado está la media de los valores simulados con los valores observados. Pronósticos que son, en promedio, sobrestiman a las observaciones presentarán un $bias > 0$, y pronósticos que, en promedio, subestiman a las observaciones presentarán un $bias < 0$. (Jolliffe, I. T. et al. 2003, p.21) recomienda que este valor debe ser pequeño tomando en cuenta que un *bias* de cero significaría que las medias de los pronósticos y de las observaciones son exactamente iguales, aun cuando existiera un error de pronóstico. Esta medida se calcula de la siguiente forma:

$$bias = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)$$

Dónde:

N : Número de datos (puede ser número de tiempos o el número de pares (P_i, O_i))

P_i : Valor simulado en el tiempo i

O_i : Valor observado en el tiempo i

B. RMSE

La raíz del error cuadrático medio, RMSE por sus siglas en inglés, es la medida de precisión más usada para evaluar pronósticos. Esta medida es sensible a valores atípicos (*outliers*) presentes en la muestra de datos, ya que los errores derivados de estos valores atípicos son elevados al cuadrado. Una estimación exacta de los valores observados daría como resultado un RMSE de cero, que sería lo ideal; por eso siempre se busca que este valor sea el menor posible para interpretar una determinada precisión en los resultados de la simulación. Si no se tomara la raíz cuadrada de esta medida, esta no tendría las mismas unidades que las variables analizadas. El RMSE se calcula de la siguiente forma:

$$RMSE = \left\{ \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \right\}^{1/2}$$

Dónde:

N : Número de datos (puede ser número de tiempos o el número de pares (P_i, O_i))

P_i : Valor simulado en el tiempo i

O_i : Valor observado en el tiempo i

C. MAE

Una forma de evadir que errores positivos y negativos se cancelen entre sí, como ocurre con el cálculo del *bias*, es calcular el error medio absoluto, MAE por sus siglas en inglés. El MAE considera el valor absoluto de los errores y los promedia. Debido a que el MAE es más resistente a valores atípicos (*outliers*) que el RMSE, el MAE es menos riguroso, y por lo tanto representa un grado de precisión menor que el RMSE, sin embargo su facilidad de cálculo permite que sea usado para dar una primera impresión del error medio. Esta medida además se usa para calcular otras medidas de precisión y/o habilidad de los pronósticos (Wilks, D. S. 2006, p. 281). Esta medida se calcula de la siguiente forma:

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i|$$

Dónde:

N : Número de datos (puede ser número de tiempos o el número de pares (P_i, O_i))

P_i : Valor simulado en el tiempo i

O_i : Valor observado en el tiempo i

D. Coeficiente de correlación (r)

Parte de la verificación de los pronósticos del tiempo también es analizar el grado de asociación entre los valores simulados y los valores observados. Este grado de asociación es importante sobre todo para determinar la firmeza de la variación conjunta entre los valores simulados y observados. Uno de los grados de asociación más comunes que se dan en la naturaleza es el grado de asociación lineal entre estos dos conjuntos de datos. Esta asociación lineal se calcula con uno de los estadísticos más utilizados actualmente llamado Coeficiente de Correlación de Pearson o simplemente Coeficiente de Correlación.

El grado de asociación lineal entre las variables X e Y significa el grado al cual los puntos de la gráfica de dispersión de las variables X e Y están cerca de una línea recta. Sin embargo, el análisis de la validación de pronósticos en muchos casos involucra saber que tan alejado están los valores pronosticados y las observados de ser exactamente iguales, y para lograr eso el análisis de dispersión debe hacerse con respecto a una recta ideal donde los valores de la variable X deben ser exactamente iguales a los valores de la variable Y.

Para hallar el Coeficiente de Correlación se deben cumplir dos condiciones, primero que las variables X (temperaturas observadas) e Y (temperaturas simuladas) sean variables aleatorias, y segundo, que la variación de estas dos variables genere una distribución de probabilidad bivariada normal. Para el caso de la primera condición se asumirá que tanto las variables X como Y son variables aleatorias y que por lo tanto son independientes, aunque esto no sea del todo cierto cuando se analiza variables meteorológicas (Wilks, D. S. 2006, p.143), y para el caso de la segunda condición, según (Wilks, D. S. 2006, p.88), estos dos conjuntos de datos (observados y simulados) pueden comportarse como elementos de una distribución normal bivariada.

El Coeficiente de Correlación es sensible a *outliers*, sin embargo no es sensible a los errores de pronóstico (RMSE o MAE), siempre y cuando estos errores sean regulares. De ese modo se puede tener una correlación muy buena y sin embargo un error promedio grande. Existen varias formas de calcular el valor del Coeficiente de Correlación. Tener en cuenta que el Coeficiente de Correlación de Pearson varía entre -1 y 1. Un valor de -1 indica una correlación perfecta, pero negativa donde las dos variables son inversamente proporcionales; un valor de cero indica ninguna relación lineal; y un valor de 1 indica una variación lineal conjunta ideal, donde las dos variables son directamente proporcionales. Se prefiere mostrar la fórmula utilizada en (Ramachandran, K. M. et al., 2009) por la simplicidad del cálculo.

$$r = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2 \sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad ; \quad -1 \leq r \leq 1$$

Dónde:

N : Número de datos (puede ser número de tiempos o el número de pares (P_i, O_i))

X_i : Variable independiente (podría ser temperatura observada en el tiempo i)

Y_i : Variable dependiente (podría ser temperatura simulada en el tiempo i)

E. Ecuación de regresión lineal simple

Esta ecuación es el resultado de aplicar la solución de mínimos cuadrados a dos variables que tienden a tener una relación lineal. Por lineal se entiende que la ecuación que define la relación de estas dos variables es una recta, y simple quiere decir que solo está involucrada una variable independiente. Esta ecuación es obtenida desde un diagrama de dispersión de las dos variables involucradas.

Para establecer esta ecuación se tiene que asumir que las variables Y correspondientes a un determinado valor X tienen una distribución normal y que por lo tanto son variables aleatorias estadísticamente independientes. Es más probable que esta suposición se viole cuando se trabaje con series temporales, tal como la distribución de temperaturas en un intervalo de tiempo; sin embargo, según (Bowerman, B., 2007, p.98) hay resultados que demuestran que la regresión lineal no es muy sensible a ligeras desviaciones de esta

suposición. Recordar que esta ecuación es un estimado de la verdadera relación lineal que existiría entre las dos variables. La ecuación de regresión lineal simple tiene la siguiente forma:

$$Y = a + bX$$

Donde:

X : Variable independiente (podría ser temperatura observada)

Y : Variable dependiente (podría ser temperatura simulada)

a : Ordenada de origen o Intercepto

b : Pendiente

Para el caso especial en que $a = 0$ y $b = 1$ la variable Y tendría el mismo valor que la variable X para cualquier valor de X . Este caso se utiliza bastante cuando se hace comparaciones entre valores simulados y valores reales, como una forma de cuantificar que tan alejado se encuentra la ecuación de la recta calculada de una recta ideal con $a = 0$ y $b = 1$.

F. Índice de Willmott

El índice de Willmott es un índice que refleja el grado al cual la variable observada es estimada por la variable simulada (Willmott, C. J., 1982). Este índice se propone en (Willmott, C. J., 1982) como una medida que ayude a las demás medidas de precisión mencionadas anteriormente para determinar precisión. Este índice es adimensional y varía entre 0 y 1. Un valor de uno indica una concordancia perfecta entre los valores pronosticados y observados, un valor de cero indica ninguna concordancia. Este índice no es una medida de correlación o asociación. Este índice complementa la información contenida en MAE y RMSE. A diferencia del coeficiente de correlación (r), el índice de Willmott es sensible al tamaño de los errores de pronósticos, ya que el índice de Willmott se calcula utilizando estos errores.

$$d = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N [|P_i - \bar{O}| + |O_i - \bar{O}|]} \quad ; \quad 0 \leq d \leq 1$$

Donde:

P_i : Variables pronosticadas o simuladas en el tiempo i

O_i : Variables observadas en el tiempo i

\bar{O} : Valor promedio de las observaciones

N : Número total de datos (puede ser número de tiempos o el número de pares (P_i, O_i))

2.7.2. PRUEBAS ESTADÍSTICAS PARA VALIDACIÓN DE RESULTADOS

Cuando se trata de usar pruebas estadísticas para validar pronósticos se pueden usar las pruebas estadísticas estudiadas en *estadística clásica* tales como intervalos de confianza o pruebas de hipótesis, etc., sin embargo, actualmente, según la diversidad de artículos científicos que se pueden encontrar en relación a la verificación de pronósticos tales como (Gonzales M., Carlos et al, 2014) y (Lara Fanego, V. et al, 2012), las *medidas de precisión*, descritas en la sección 2.6.1, vienen siendo más utilizadas que las pruebas estadísticas en relación a la determinación de precisión de los pronósticos.

Existen otras técnicas estadísticas que ayudan a evaluar los resultados de un pronóstico dependiendo si los pronósticos son probabilísticos o determinísticos, y también dependiendo si se va a validar el pronóstico en toda una región o solo se quiere validar el pronóstico en puntos específicos. Para mayor información de pruebas estadísticas utilizadas en verificación de pronósticos se puede revisar (Jolliffe et al. 2010) y (Wilks, D. S. 2006).

III. MATERIALES Y MÉTODOS

3.1. EQUIPOS Y/O MATERIALES

Las principales herramientas para el desarrollo de la tesis se clasifican en tangibles e intangibles. Los equipos de cómputo conforman las herramientas tangibles y los *softwares* necesarios para el desarrollo del presente estudio conforman las herramientas intangibles.

Las herramientas tangibles son los siguientes:

- Ordenador personal de investigación
- Tres ordenadores para realizar las simulaciones (Las características de estos ordenadores se muestra en la tabla 3.14)

Los softwares que conforman las herramientas intangibles son los siguientes:

- WRF Model.3.4.1
- WPS 3.4.1
- ARWpost 3.1
- GRADS 2.0.2
- Microsoft Office 2013
- ArcGIS 10.2

3.2. METODOLOGÍA

Con el propósito de lograr los dos objetivos específicos la metodología del presente estudio consistió en realizar dos principales procedimientos. El primero consistió en ejecutar el modelo para obtener pronósticos de temperaturas a dos metros de la superficie con 120 horas de anticipación. El segundo procedimiento consistió en ejecutar el modelo para obtener temperaturas simuladas (no pronosticadas) a dos metros de la superficie.

Como ya se explicó en la sección 2.5, para obtener pronósticos con un modelo de mesoescala se tienen que utilizar *datos de análisis* como *condiciones iniciales* y *datos de pronóstico* como *condiciones de frontera*, el cual fue el caso del primer procedimiento. Sin embargo, cuando se quiere estudiar eventos meteorológicos pasados con el modelo es conveniente utilizar *datos de análisis* como *condiciones iniciales* y también como *condiciones de frontera*, el cual fue el caso del segundo procedimiento, ya que el mayor grado de precisión de los *datos de análisis* logra generalmente mejores simulaciones de eventos pasados.

Realizar pronósticos estrictamente también es realizar simulaciones con el modelo, solo que éstas son simulaciones de eventos futuros; por eso cuando se realizan pronósticos se utilizan *datos de pronóstico* como condiciones de frontera. En cambio cuando se quiere estudiar eventos pasados generalmente se utilizan *datos de análisis* como condiciones de frontera, ya que el mayor grado de precisión de los *datos de análisis* logra generalmente mejores simulaciones. A los resultados de la simulación de eventos pasados también se le suelen llamar pronósticos, sin embargo para no entrar en confusiones, en el presente estudio a los resultados obtenidos utilizando *datos de pronóstico* como condiciones de frontera se le llamará *pronósticos*, que es el caso del primer procedimiento que se explica en la sección 3.2.1. A los resultados de las simulaciones de temperaturas realizadas usando *datos de análisis* como condiciones de frontera se le llamará simplemente *simulaciones*, que es el caso del segundo procedimiento que se detalla en la sección 3.2.2.

El primer procedimiento se llevó a cabo para evaluar el comportamiento del modelo al *pronosticar* temperaturas a dos metros de la superficie. El segundo procedimiento se llevó a cabo para evaluar el comportamiento del modelo para simular temperaturas a dos metros de la superficie utilizando puramente *datos de análisis*. Los resultados de los dos procedimientos no solo fueron necesarios para determinar si el comportamiento del modelo

es el adecuado, sino también al mismo tiempo permitieron comprobar si calidad de la data utilizada como condiciones iniciales y de frontera provenientes del modelo global GFS es la apropiada.

La metodología del presente estudio se resume en la figura 3.1.

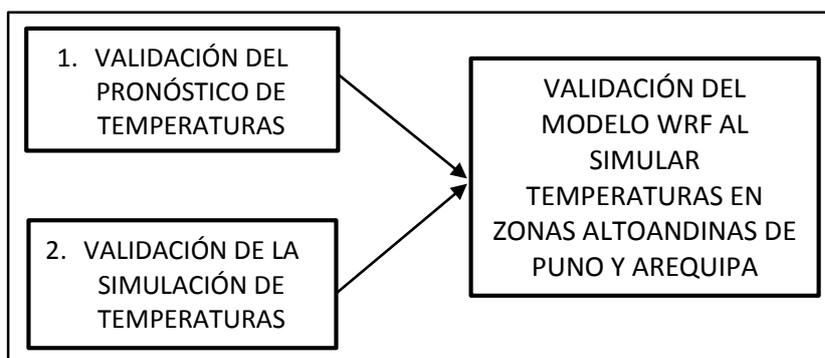


Figura 3.1. Los dos principales procedimientos de la metodología

FUENTE: Elaboración propia.

3.2.1. VALIDACIÓN DEL PRONÓSTICO DE TEMPERATURAS

Es bien sabida que la predictibilidad determinista en modelos de mesoescala es de 2 a 3 días (Carvalho, D. et al, 2012, p.25). Sin embargo, en el presente estudio se realizaron pronósticos hasta con 120 horas de anticipación (5 días), ya que según (Wang, W., 2014), el modelo en algunos estudios ha llegado a ser utilizado con esos días de anticipación brindando buenos resultados. De ese modo, en el presente estudio la verificación de los pronósticos hasta con 120 horas de anticipación fue estadísticamente representativa. En la figura 3.2, se resumen los principales pasos que se siguieron en el procedimiento para el pronóstico de temperaturas a 2 metros de la superficie. El primer paso se describe en el punto “a”. El segundo paso de la configuración del modelo, se explica desde el punto “b”. El tercer paso, que es el de la ejecución de los pronósticos se desarrolla en el punto “c”. El cuarto paso del postprocesamiento de los pronósticos se describe en la sección “d”. El último paso, que se refiere al cálculo de las medidas de precisión de los pronósticos, se explica en la sección “e”.

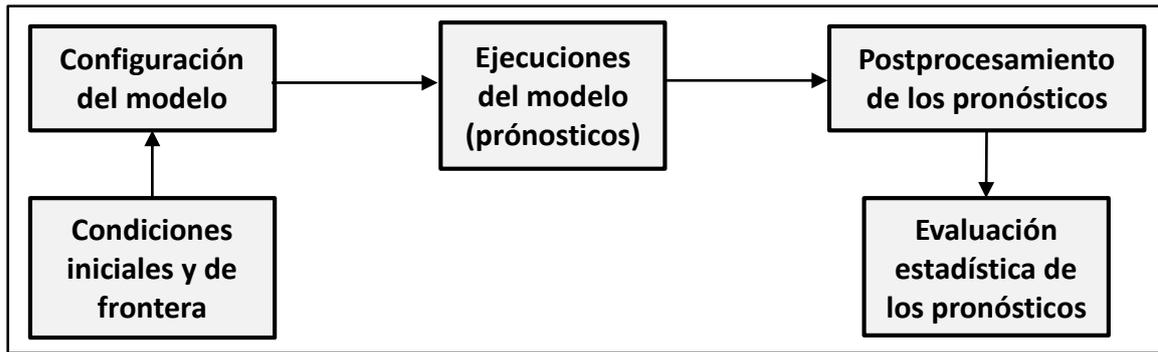


Figura 3.2. Diagrama de flujo para el pronóstico de temperaturas

FUENTE: Elaboración propia

a. CONDICIONES INICIALES Y CONDICIONES DE FRONTERA

Ya que en este caso se realizan pronósticos, en la tabla 3.1 se puede ver que las condiciones iniciales son *datos de análisis* y las condiciones de frontera son *datos de pronóstico*. Los dos tipos de datos provienen del modelo global GFS con una resolución temporal de 6 horas, lo que quiere decir que se descargaron datos de las horas 00Z, 06Z, 12Z y 18Z de los 5 días necesarios para realizar una sola ejecución del modelo. En cada mes se realizaron cuatro ejecuciones del modelo y cada ejecución generó pronósticos hasta 120 horas. Si bien el pronóstico es de 120 horas, también se obtuvieron pronósticos menores a 120 horas, ya que la resolución temporal de salida del modelo se ajustó a una hora. Las primeras 12 horas de los pronósticos se obviaron debido al efecto *spin-up*. Según (Coiffier, J. 2011, p.259) este efecto se debe a que durante las primeras horas de integración de los pronósticos se presentan oscilaciones a causa de la formación de ondas inerciales-gravitacionales que se propagan, y que después de cierto tiempo, se dispersan y se atenúan a causa de procesos disipativos en el modelo.

Tabla 3.1. Características de los datos de entrada al modelo

	Para las condiciones iniciales	Para las condiciones de frontera
Tipo de datos	Datos de Análisis	Datos de Pronóstico
Fuente (Modelo global)	GFS	GFS
Resolución Espacial	0.5°x0.5°	0.5°x0.5°
Resolución temporal	-	6 horas
Formato de archivo	GRIB2	GRIB2

La cantidad de datos a recopilarse que sirvan como fuente de entrada al modelo dependió del tiempo de pronóstico elegido (120 horas), del número de ejecuciones que se realizaron y de la resolución temporal de estos datos de entrada. Como la resolución temporal de estos datos es de seis horas, para un pronóstico de cinco días se tiene que descargar 21 datos (1 para las condiciones iniciales y 20 para las condiciones de frontera). La cantidad de datos que se recopilaron se obtuvo multiplicando el número total de ejecuciones por la cantidad total de datos descargados para una ejecución del modelo, tal y como lo muestra la tabla 3.2. Tener en cuenta que tanto las condiciones iniciales como las condiciones de frontera se descargaron desde el modelo global GFS.

Tabla 3.2. Total de archivos descargados como fuente de entrada al modelo WRF

Periodo	N° de ejecuciones	Resolución temporal	CI	CF	Total
Mayo/2014	4	6 horas	4x1=4	4x20=80	84
Julio/2014	4	6 horas	4x1=4	4x20=80	84
Total – 2 meses	8	-	8	160	168

CI: Condiciones iniciales, CF: Condiciones de frontera

b. CONFIGURACIÓN DEL MODELO

Para lograr una correcta configuración del modelo se siguió principalmente las recomendaciones de la Guía de Usuario del modelo, no obstante algunas recomendaciones importantes se tomaron desde la página web oficial del modelo para usuarios: <http://www2.mmm.ucar.edu/wrf/users/>, en donde cada cierto tiempo se dan a conocer tutoriales para un correcto manejo del modelo.

b.1. Dominios y anidamientos de simulación

Como se explicó en la sección 2.5, el uso de modelos de mesoescala implica tener que establecer las dimensiones de un espacio tridimensional en el globo (planeta), en donde se realizará los pronósticos de las variables meteorológicas. No obstante, existen espacios tridimensionales más pequeños que se pueden incluir dentro de este espacio tridimensional, estos espacios son de menores dimensiones y se conocen como *anidamientos*. El espacio tridimensional más grande se conoce como dominio padre. En el presente estudio se estableció un dominio padre y dos anidamientos para ejecutar el modelo, tal y como se puede

ver en la figura 3.3. El dominio padre tiene una resolución espacial de 27 km, el primer anidamiento tiene una resolución espacial de 9 km y el segundo anidamiento tiene una resolución espacial de 3 km. Según las resoluciones espaciales de estos espacios tridimensionales las conformaciones de las dimensiones de estos espacios se pueden ver en la tabla 3.3. Como el último anidamiento se enfocó en zonas altoandinas de Puno y Arequipa, los pronósticos obtenidos desde este anidamiento fueron los que se utilizaron para la validación del modelo.

Los anidamientos se establecieron simétricamente de forma telescópica como se puede ver en la figura 3.3. La coordenada centro que se usó como referencia para la conformación del dominio padre y de los anidamientos fue la siguiente: 15.49° SUR de latitud y 71.12° OESTE de longitud.

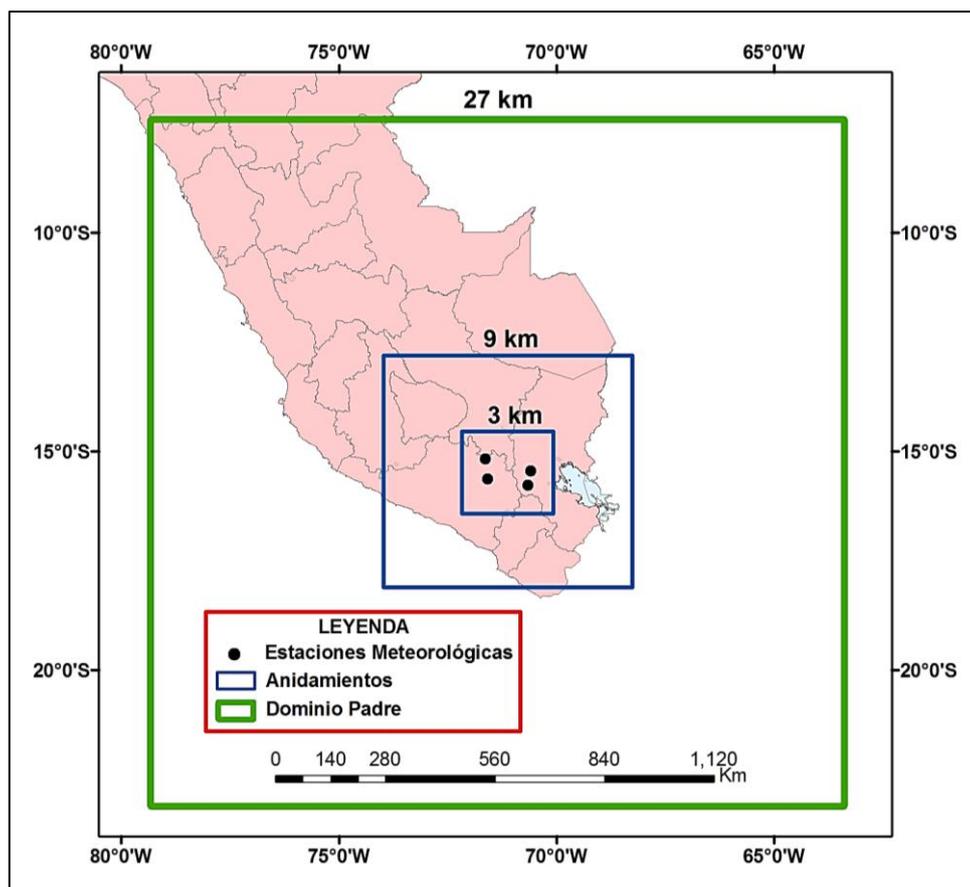


Figura 3.3. Dimensiones del dominio padre y de los anidamientos

FUENTE: Elaboración Propia

b.2. Opciones generales elegidas en el modelo

Las opciones generales elegidas en el modelo para realizar pronósticos se muestran en la tabla 3.3. Estas opciones tenían que ver principalmente con configurar el modelo tanto en la dimensión espacial como en la dimensión temporal. Se puede ver que las resoluciones horizontales en los ejes x e y varían según el dominio de simulación, y se eligieron teniendo en cuenta la resolución espacial de los datos de entrada que eran de 0.5° . El número de niveles verticales son las diferentes alturas que consideró el modelo según las coordenadas verticales del modelo. El tiempo de paso se eligió según (Kalnay, E. 2003, p.6). El número de puntos en los ejes x , y y z está relacionado con el número de celdas tridimensionales que obtuvo el modelamiento. El tipo de anidamiento es de tipo *two-way*, el cual permitió que los anidamientos retroalimenten al dominio padre y de ese modo enriquecer el mecanismo de simulación (Guía de usuario WRF, 2014, p.5-12). Se eligió el núcleo dinámico ARW debido a que este se adecua mucho mejor al tipo de simulación elegido en el presente estudio. La resolución temporal de 1 hora se eligió porque de esa forma se obtendrían temperaturas pronosticadas horarias, el cual facilita el análisis del comportamiento de temperaturas en la zona de estudio.

Todas las opciones anteriores se eligieron modificando primero el archivo de texto acoplado al modelo: *namelist.wps*, y luego el *namelist.input*. Estos archivos se pueden ver en los anexos 1 y 2 respectivamente.

Tabla 3.3. Configuración general elegida en el modelo

Opciones	Dominios	Dominio Padre (1er dominio)	1er Anidamiento (2do dominio)	2do Anidamiento (3er dominio)
Niveles verticales		41	41	41
Resol. horizontal dx		27 km	9 km	3 km
Resol. horizontal dy		27 km	9 km	3 km
Resolución temporal		1 hora	1 hora	1 hora
Tiempo de paso (seg.)		60	30	10
N° de puntos (X, Y, Z)		76x76x41	76x76x41	76x76x41
Tipo de Anidamiento		Two-way		
Núcleo Dinámico		ARW		
Versión del modelo WRF		3.4.1		

b.3. Elección de las opciones de física en el modelo

La física del modelo WRF es de gran importancia cuando se lleva a cabo los pronósticos. Para este estudio se eligió las opciones de física que se recomiendan en la *Guía de Usuario del Modelo WRF* para regiones frías (Guía de Usuario WRF. 2012, p.5.26). Las principales opciones de la física del modelo que se eligieron se muestran en la tabla 3.4.

Todas las opciones de física y dinámica del modelo se eligen modificando el archivo de texto *namelist.input*, que es el archivo que se tiene que modificar también para configurar el procesador WRF del modelo. Para una completa revisión de todas las opciones de la física y dinámica elegidas en los pronósticos se puede ver el anexo 2.

Algunas opciones, por ejemplo la de elegir una física de cúmulos en el último anidamiento (tabla 3.4), fueron recomendaciones que realizan los desarrolladores del modelo WRF en la página web oficial del modelo: <http://www2.mmm.ucar.edu/wrf/users/>.

Tabla 3.4. Opciones de física elegidas en el modelo para los pronósticos

	Dominio Padre (1er dominio)	1er Anidamiento (2do dominio)	2do Anidamiento (3er dominio)
Capa límite planetaria (PBL)	Mellor-Yamada-Janjic (Eta) TKE		
Microfísica de nubes	WSM 5-class		
Interacción superficie-tierra	<i>unified</i> Noah		
Cúmulos	<i>new</i> Kain-Fritsch	<i>new</i> Kain-Fritsch	no cúmulos
Capa superficial	Monin-Obukhov (Janjic Eta)		
Radiación en onda larga	RRTMG		
Radiación en onda corta	<i>(old)</i> GODDARD		

FUENTE: Guía de Usuario, modelo WRF v3.4

c. EJECUCIONES DEL MODELO

c.1. Diagrama de flujo elegido para ejecutar el modelo

El manejo del modelo WRF no se restringe a un solo camino o flujo de simulación como ya se mencionó en la sección 2.6.1.

Para fines del presente estudio se utilizó el flujo de simulación que se muestra en la figura 3.4. Se eligió este tipo de modelamiento primero porque se tiene fácil acceso a las herramientas involucradas en los pasos de este flujo, y segundo porque el actual adiestramiento se adecua convenientemente a este diagrama de flujo elemental.

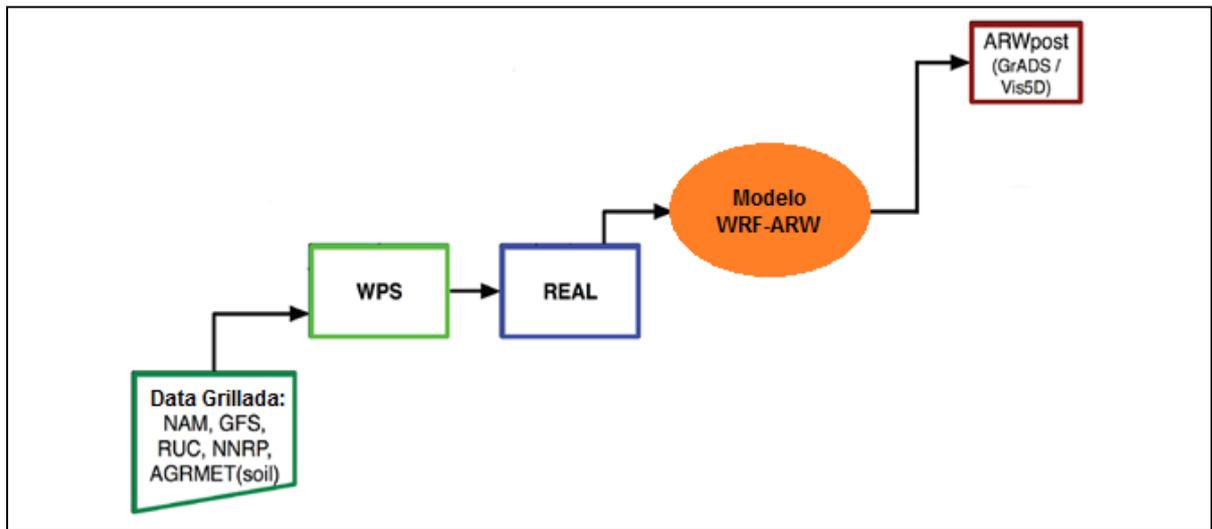


Figura 3.4. Diagrama de flujo elegido en el estudio. Adaptación de la Figura 2.2

FUENTE: WRF-ARW User's Guide (2014)

c.2. Número de ejecuciones del modelo para obtener los pronósticos

Para verificar la precisión de los pronósticos se ejecutó el modelo un cierto número de veces. La cantidad total de ejecuciones del modelo (es decir los pronósticos propiamente dichos) y sus respectivas horas de inicialización se muestra en la tabla 3.5. Como cada ejecución realiza un pronóstico de 120 horas, en la tabla 3.5 también se aprecia la hora que finalizó cada ejecución. Esto quiere decir que en una determinada ejecución del modelo se obtuvieron 120 horas pronosticadas. Como la resolución temporal de salida del modelo que se eligió fue de 1 hora, el total de tiempos pronosticados obtenidos en todas las ejecuciones del modelo se muestra en la tabla 3.7.

Como en cada ejecución se obtuvieron 120 horas pronosticadas, en cada hora pronosticada se generaron diferentes variables meteorológicas. La elección de la cantidad y el tipo de variables meteorológicas que se obtendrían se dejó por defecto en el modelo. Para fines del presente estudio solamente se extrajo la variable: temperatura a dos metros de la superficie.

Debido al efecto *spin-up* (Coiffier, J. 2011, p.259), se consideró a las primeras 12 horas pronosticadas como *no representativas*, por lo tanto se obviaron para el análisis estadístico.

Tabla 3.5. Hora de inicio y fin para cada pronóstico

	Pronósticos	Hora de inicialización	Hora de finalización
Mayo 2014	1ra ejecución	00Z 01 Mayo 2014	00Z 06 Mayo 2014
	2da ejecución	00Z 09 Mayo 2014	00Z 14 Mayo 2014
	3ra ejecución	00Z 16 Mayo 2014	00Z 21 Mayo 2014
	4ta ejecución	00Z 24 Mayo 2014	00Z 29 Mayo 2014
Julio 2014	1ra ejecución	00Z 01 Julio 2014	00Z 06 Julio 2014
	2da ejecución	00Z 09 Julio 2014	00Z 14 Julio 2014
	3ra ejecución	00Z 16 Julio 2014	00Z 21 Julio 2014
	4ta ejecución	00Z 24 Julio 2014	00Z 29 Julio 2014

En total se realizaron ocho ejecuciones del modelo como lo muestra la tabla 3.5. Las ejecuciones se realizaron en los dos meses en donde se eligió evaluar el comportamiento del modelo. El mes de mayo se eligió porque, en la zona de estudio, en este mes se empiezan a registrar las primeras heladas y suelen ser las que causan mayor daño. El mes de julio se eligió porque en este mes suelen ocurrir las heladas más intensas y con mayor frecuencia.

Considerando una determinada coordenada geográfica; como en una determinada ejecución del modelo se obtuvo 120 horas pronosticadas, en cada hora se obtuvo una determinada temperatura pronosticada, formando de esa forma en total 120 temperaturas pronosticadas en un determinado punto geográfico. Estos 120 datos son suficientes para analizar estadísticamente una serie temporal según varios ejemplos mostrados en (Bowerman, B., et al. 2007). No obstante, contando todos los datos obtenidos para un determinado punto geográfico, se obtuvo en total 960 temperaturas pronosticadas, de los cuales se utilizaron 872, ya que debido al efecto *spin-up* (Coiffier, J. 2011, p.259) se obviaron las primeras 12 horas de cada pronóstico. De ese modo esta muestra de 872 datos es aún más representativa para realizar análisis estadísticos.

c.3. Procedimiento para una sola ejecución del modelo

Para ejecutar el modelo correctamente se siguió principalmente las indicaciones y recomendaciones dispuestas en la *Guía de Usuario* del modelo y en tutoriales provistos en la página web oficial del modelo: <http://www2.mmm.ucar.edu/wrf/users/>.

El manejo del modelo para la ejecución de la simulación se realizó en las instalaciones de la Universidad Nacional Agraria La Molina (UNALM), en el Departamento de Ingeniería Ambiental, Física y Meteorología, y gracias a la colaboración de la Dirección General de Investigación Ambiental perteneciente al Servicio Nacional de Meteorología e Hidrología (SENAMHI).

Los ordenadores que se utilizaron para el manejo del modelo tienen las características que se muestran en la tabla 3.6. En total se utilizaron tres ordenadores, en los cuales se instaló el modelo y otros softwares necesarios (sección 3.1) para la realización del estudio.

Tabla 3.6. Características del ordenador utilizado para los pronósticos

Característica	Tipo
Procesador	Intel Core i7 – 3.40 Ghz
Memoria RAM	4 GB
Capacidad Disco Duro	1 Terabyte
Número de Núcleos	8
Sistema Operativo (SO)	Kubuntu 12.4 – 32 bits

Teniendo en cuenta el tiempo necesario para la adecuación de los ordenadores y el tiempo de manejo del modelo para la simulación, el tiempo para completar los pasos de este procedimiento para el pronóstico de temperaturas fue cerca de 2 semanas.

Todos los archivos involucrados en la simulación ingresaron y se obtuvieron en horas del Meridiano de Greenwich (hora Z).

Todas las ejecuciones del modelo se realizaron en la consola del sistema operativo (SO) mencionado en la tabla 3.6.

c.3.1. Manejo del preprocesador - WRF *Preprocessing System* (WPS)

Dentro de la ruta donde se ubica el preprocesador (WPS) del modelo, la utilización del WPS consistió en modificar un archivo de texto ubicado en esta ruta. Este archivo de texto posee el nombre *namelist.wps* (anexo 1), y es en este archivo donde se encuentran todas las opciones necesarias para configurar los programas que conforman el WPS: *geogrid*, *ungrib* y *metgrid*.

Con el archivo de texto *namelist.wps* configurado correctamente (anexo 1), se procedió a ejecutar los programas del WPS secuencialmente, primero el *geogrid*, luego el *ungrib*, y por último el *metgrid*. Una vez completada la ejecución del WPS se obtuvieron los archivos de salida del WPS, que eran del tipo: *met_em.d0*.yyyy-mm-dd_hh:mm:ss.nc*, los cuales sirvieron como archivos de entrada para el siguiente proceso de simulación.

Según la configuración elegida en el modelo, y según la capacidad del ordenador para procesar los datos, el tiempo de corrida del preprocesador solo para una ejecución del modelo fue cerca de media hora.

c.3.2. Manejo del Procesador WRF

Los archivos provenientes de la ejecución del WPS se enlazaron al directorio o ruta donde se encontraban los programas del procesador WRF: *real* y *wrf*. En este directorio también se encontraba un archivo de texto de nombre *namelist.input*. Este archivo es crucial en el modelo porque en él se eligió la resolución temporal y espacial de la simulación, así como también la física del modelo (parametrizaciones). Una vez configurado correctamente el *namelist.input* (anexo 2), se procedió a ejecutar los programas que conforman el procesador WRF. Primero se ejecutó el programa *real*, el cual generó en total cuatro archivos, tres archivos del tipo *wrfinput_d0**, que eran las condiciones iniciales de los dominios de simulación, y un archivo del tipo *wrfbdy_d0**, que contenían la condiciones de frontera del dominio padre.

Luego de obtener los archivos generados por el programa *real* (4 archivos) se procedió a ejecutar el programa *wrf*. Este último es el programa más importante del modelo porque es el que realiza el pronóstico de las variables meteorológicas en el área de estudio. La

ejecución del programa *wrf* generó 3 archivos, un archivo correspondiente al dominio padre y dos archivos correspondientes a los anidamientos. Estos tres archivos poseen un nombre del tipo: *wrfout_d0*_yyyy-mm-dd_hh:mm:ss*.

Considerando la configuración elegida en el modelo y la capacidad del ordenador donde se realizaron los pronósticos, la duración de solo una ejecución del programa *real* fue cerca de un minuto, a diferencia de la duración de la corrida del programa *wrf* que duró cerca de doce horas.

c.4. Número de horas pronosticadas obtenidas en las ejecuciones

De acuerdo a la resolución temporal de salida elegida en el modelo, en la tabla 3.7 se aprecia la cantidad exacta de horas pronosticadas que fueron obtenidas en todas las ejecuciones del modelo. Tener en cuenta que en esta tabla no se está considerando a la condición inicial como hora pronosticada, pero como igualmente esa hora se obtiene al final de las simulaciones, se contó en el total de tiempos obtenidos.

Tabla 3.7. Total de horas obtenidas en los pronósticos

Mes/Año	Nº de pronósticos	Resolución temporal de salida	CI	Horas pronosticadas obtenidas	Total de horas obtenidas
Mayo/2014	4	1 hora	4x1h=4	4x120h=480	484
Julio/2014	4	1 hora	4x1h=4	4x120h=480	484
Total	8	-	8	960	968

CI: Condiciones iniciales

d. POSTPROCESAMIENTO DE LOS PRONÓSTICOS

Como los archivos de salida del procesador WRF aún estaban en formato *.nc* y no podían ser visualizados de forma directa, estos tenían que pasar por un postprocesamiento, de modo que se puedan visualizar los pronósticos. El principal objetivo del postprocesamiento fue básicamente convertir los archivos de salida a un formato adecuado para que puedan ser visualizados y analizados fácilmente con otro *software*.

El postprocesamiento de las salidas del modelo consistió en ejecutar el programa AWRpost, pero primero éste tuvo que ser configurado modificando el archivo de texto acoplado llamado *namelist.ARWpost* (anexo 3). La configuración de este archivo consistió básicamente en colocar las fechas y la resolución temporal de los pronósticos y principalmente colocar el nombre del archivo de salida del procesador WRF del dominio correspondiente; como se explicó en el punto c.3.2 cada dominio de simulación genera su propio archivo, y como solo se consideró el último dominio para extraer los datos se colocó el nombre correspondiente a este archivo: *wrfout_d03_**. Una vez configurado el *namelist.ARWpost* se ejecutó el programa ARWpost, el cual convirtió el archivo de salida del procesador WRF en dos archivos en formatos *.ctl* y *.dat*. Una vez que se obtuvieron estos dos archivos en *.ctl* y *.dat*, recién los resultados pudieron ser visualizados con el *software* GRADS. En el punto e.4 de esta sección, se explicará cómo se extrajo la información necesaria de estos archivos para la evaluación estadística de los pronósticos.

Teniendo en cuenta la configuración elegida en el modelo y la capacidad del ordenador donde se realiza los pronósticos, la duración de la corrida del programa ARWpost fue cerca de 4 minutos solo para una ejecución del modelo.

e. EVALUACIÓN ESTADÍSTICA DE LOS PRONÓSTICOS

Cuando se habla de evaluación estadística se está refiriendo básicamente a los procedimientos necesarios para cuantificar la precisión de los pronósticos.

e.1. Número de puntos para la evaluación estadística

Según (Jolliffe, I.T. 2003, p.124) el número de puntos para la validación del modelo depende del propósito de los pronósticos, de esa forma la cantidad de puntos puede variar de unos pocos a muchos puntos, dependiendo de los lugares en los que se está interesado hacer pronósticos.

Ya que solo existen cuatro estaciones meteorológicas de donde se extrajeron las observaciones, en el presente estudio se utilizaron precisamente estas cuatro estaciones meteorológicas como puntos de validación. Estas estaciones se eligieron porque son las únicas estaciones automáticas operativas disponibles dentro de la zona de estudio (figura

3.3). En la tabla 3.8 se muestran las características de estas estaciones. Todas estas estaciones son estaciones monitoreadas por SENAMHI.

Tabla 3.8. Estaciones meteorológicas para la validación del modelo

Nombre de Estación	Longitud	Latitud	Altitud (m)	Tipo de Estación	Distrito	Provincia	Región
Chivay	71°36'1"O	15°38'1"S	3634	Automática	Chivay	Caylloma	Arequipa
La Angostura	71°38'58"O	15°10'47"S	4256	Automática	Caylloma	Caylloma	Arequipa
Lagunillas	70° 49' 40.68"O	15° 46' 4.8"S	4367	Automática	Santa Lucia	Lampa	Puno
Pampahuta	70°35' 56.35"O	15° 27' 8.36"S	4250	Automática	Paratia	Lampa	Puno

e.2. Datos incompletos y limpieza de datos en las observaciones

Los datos provenientes de las estaciones meteorológicas y que son los datos reales medidos *in situ* son conocidos simplemente como *observaciones*. Estos últimos tienen también errores naturales debido a factores operacionales. En el presente estudio se asumió que este error en las observaciones es despreciable, ya que los valores de las observaciones no presentaron un comportamiento anómalo. Sin embargo, las observaciones sí pasaron por un proceso de depuración, el cual consistió en detectar algunos datos que no se ajustaban a la realidad o que estaban fuera de contexto. Para lograr esto se hizo uso de gráficos y cuadros donde se podía identificar datos atípicos (*outliers*), ya que según (Hand, D. 2001, p.50), al analizar solo una variable se puede detectar *outliers* utilizando solo cuadros y/o gráficos. No obstante, no se registraron *outliers* en ningún punto de validación.

También, algunos datos faltantes en las observaciones fueron completados. En (Bramer, M. 2007, p.17) se menciona que en el caso de variables continuas, como las temperaturas, se puede estimar estos valores faltantes por medio de una interpolación de los datos más cercanos a estos valores. De ese modo algunos valores faltantes en las observaciones fueron estimados gracias a una interpolación de los datos más cercanos a estos valores faltantes.

e.3. Elección de las variables meteorológicas para la evaluación estadística

El resultado de cada ejecución del modelo generó diferentes variables meteorológicas pronosticadas (temperatura, viento, precipitación, etc.), a diferentes horas, a diferentes alturas, niveles de presión, etc.; sin embargo para fines del presente estudio solo se analizó la variable temperatura a dos metros de la superficie, ya que el enfoque del presente estudio está en el pronóstico de temperaturas extremas frías, aun cuando otros factores meteorológicos estén relacionados con las heladas en la zona de estudio.

e.4. Elección de las coordenadas de validación

Como se explicó en la sección 2.2.3, el sistema de modelamiento de un modelo está relacionado con la conformación de celdas tridimensionales. En el punto medio del centro de cada celda tridimensional es donde se simulan o pronostican las variables meteorológicas escalares tal como la variable temperatura. El valor de esta variable en el punto medio de una celda representa el promedio de esa variable en todo ese espacio limitado por esa misma celda (figura 2.1). Estos puntos medios ya están establecidos dentro del sistema de modelamiento de un *modelo de predicción numérica* y no necesariamente van a coincidir con las coordenadas de los puntos que se pretende evaluar. Por eso, cuando se quiere validar un *modelo* en un determinado punto geográfico se elige el punto de simulación generado en el *modelo*, pero que esté más cercano al punto geográfico de interés. Este proceso se realiza gracias al *software* GRADS, el cual detecta cual es el punto más cercano a la coordenada de interés. Sin embargo, se tiene que utilizar un *script* si se quiere extraer la información dispuesta en este punto. Un *script*, en este caso, es un archivo ejecutable escrito en lenguaje de programación GRADS (ver anexo 4). Este *script* actúa sobre el archivo de salida del ARWpost y tiene la función de extraer las temperaturas pronosticadas en el punto más cercano a la coordenada de interés dentro de un archivo en formato *.txt*.

Como en este caso solo se está interesado en cuatro coordenadas de validación (cuatro puntos de validación), se crearon cuatro *scripts* diferentes para cada ejecución del modelo. La cantidad total de *scripts* creados en todas las ejecuciones del modelo se muestran en la tabla 3.9. Una vez creados los *scripts*, se ejecutó cada *script* uno por uno en la *consola* del sistema operativo. Un determinado *script* extrajo los valores de las temperaturas pronosticadas en

todas las horas pronosticadas en cada ejecución del modelo, pero para un solo punto de validación (una única coordenada geográfica).

Tabla 3.9. Total de scripts creados por cada ejecución del modelo

	Pronósticos	Número de puntos de validación	Cantidad scripts creados
Mayo 2014	1ra ejecución	4	4
	2da ejecución	4	4
	3ra ejecución	4	4
	4ta ejecución	4	4
Julio 2014	1ra ejecución	4	4
	2da ejecución	4	4
	3ra ejecución	4	4
	4ta ejecución	4	4
Total		32	32

La altitud real de la zona de estudio y la altitud que considera el modelo para realizar la simulación no son exactamente iguales, de hecho los *modelos de mesoescala* tienen diferentes formas de representar las características topografías (altitud, tipo de suelo, vegetación, cobertura de nieve, etc.). En (Warner, T. 2011, p.301) se señala que si bien solucionar el problema de la diferencia de las altitudes no es sencillo, sobre todo si no se tiene el adiestramiento adecuado, es necesario tener siempre presente estas diferencias al momento de evaluar los resultados. De ese modo, en el presente estudio se consideró que la altitud que toma el modelo es aproximadamente la misma altitud real de la zona de estudio, una suposición elemental válida ya que las diferencias verificadas no fueron considerables.

e.5. Cálculo de las medidas de precisión

Tener en cuenta que en una determinada ejecución del modelo se extrajo información de cuatro puntos de validación. De esa forma, en cada punto de validación se obtuvo 120 horas pronosticadas, sin embargo se realizó el análisis estadístico con solo 109 horas; ya que las primeras 12 horas fueron obviadas debido al efecto *spin-up* (Coiffier, J. 2011, p.259), generándose de ese modo 109 temperaturas pronosticadas en cada punto de validación. Sin embargo, como para cada punto de validación corresponden ocho ejecuciones del modelo,

en total en cada punto se hizo la evaluación estadística con una muestra de 872 datos. De ese modo, cada ejecución del modelo, en un determinado punto de validación está representado por un grupo de medidas de precisión. Asimismo se utilizaron estas medidas de precisión calculadas en cada punto para obtener promedios mensuales, y de ese modo, comparar la precisión de los pronósticos entre todos los puntos de validación.

Para la evaluación estadística de los pronósticos se hizo el cálculo de las siguientes medidas de precisión descritas en la sección 2.7.1:

- **Media de las temperaturas pronosticadas (\bar{P})**

Cada ejecución del modelo generó un *set* de tiempos pronosticados. Esta medida es el promedio de todas esas temperaturas pronosticadas obtenidas en cada ejecución del modelo. Se utilizaron las medias de todas las ejecuciones para promediar la media de todas las ejecuciones en los dos meses donde se hicieron los pronósticos, y de ese modo obtener una media de los valores pronosticados que represente a cada punto de validación.

- **Media de las temperaturas observadas (\bar{O})**

En este caso se eligieron las temperaturas observadas correspondientes a cada ejecución del modelo y se obtuvo la media. Se utilizaron las medias de todas las ejecuciones para promediar la media de todas las ejecuciones en los dos meses donde se hicieron los pronósticos, y de ese modo obtener una media de los valores observados que represente a cada punto de validación.

- **Desviación estándar de las temperaturas pronosticadas (S_p)**

Se calculó la desviación estándar de las temperaturas pronosticadas en cada ejecución del modelo. Luego se utilizaron las desviaciones estándar de todas las ejecuciones para promediar la desviación estándar de todas las ejecuciones en los dos meses donde se hicieron los pronósticos, y de ese modo obtener una desviación estándar que represente a cada punto de validación.

- **Desviación estándar de las temperaturas observadas (S_o)**

En cada ejecución del modelo igualmente se extrajo las observaciones correspondientes a las horas pronosticadas en cada ejecución del modelo y se calculó la desviación estándar de estas observaciones. Luego igualmente se utilizaron estas desviaciones estándar en cada ejecución para asimismo calcular la desviación estándar que represente a los dos meses en donde se hicieron los pronósticos, y de ese modo obtener una desviación estándar que represente a cada punto de validación.

- **Error absoluto medio (MAE)**

Igualmente se calculó el MAE para todas las ejecuciones del modelo y luego se promediaron estos para obtener un MAE promedio que represente a los dos meses en donde se realizaron las ejecuciones del modelo, y de ese modo obtener un MAE que represente a cada punto de validación. Este valor no está limitado por un cierto intervalo de valores, de modo que no se puede determinar algún grado de precisión de los pronósticos, sin embargo teóricamente un valor de cero significaría pronósticos exactos (ideales).

- **Raíz del error cuadrático medio (RMSE)**

Se realizaron los cálculos siguiendo el mismo procedimiento para calcular el MAE. Tener en cuenta que esta medida es más sensible a valores atípicos (*outliers*) debido que el error es elevado al cuadrado, de modo que es una medida de mayor precisión que el MAE. Este valor no está limitado por un cierto intervalo de valores, de modo que no se puede determinar algún grado de precisión de los pronósticos, sin embargo teóricamente un valor de cero significaría pronósticos exactos (ideales).

- **Índice de Willmott (d)**

Este índice se calculó también para cada ejecución del modelo. Este índice está en función principalmente de los errores de pronóstico. Los resultados demuestran que pronósticos que en promedio tienen valores de este índice entre 0.7 y 0.8 logran considerables errores. Este índice se analizó conjuntamente con las demás medidas calculadas en cada punto de validación, de forma que se pudo determinar dónde y cuándo se logran los mejores

pronósticos. Este índice sí tiene límites y varía de cero a uno, donde cero significa ninguna concordancia entre pronósticos y observaciones, y un valor de uno significa una concordancia completa o ideal.

- **Intercepto de regresión lineal (a)**

Cada ejecución del modelo tiene su correspondiente ecuación de regresión lineal explicada en la sección 2.6.1, por lo que cada ecuación generó un determinado intercepto. En teoría este valor debe ser cero para pronósticos ideales (sin error de pronóstico). Los interceptos de todas las ejecuciones realizadas se utilizaron para promediar un intercepto promedio que represente a todos los pronósticos realizados en los dos meses donde se realizaron las ejecuciones, y de ese modo obtener un intercepto promedio mensual que represente a cada punto de validación.

- **Pendiente de regresión lineal (b)**

Igual que con el caso del intercepto, la pendiente se extrajo de la ecuación de regresión lineal obtenida en cada ejecución del modelo. Explicado en la sección 2.7.1, este valor en teoría debe ser uno para pronósticos ideales (exactos). Igualmente en este caso se utilizaron las pendientes calculadas en cada ejecución del modelo para promediar una pendiente que represente a los dos meses donde se realizaron las ejecuciones, y de ese modo obtener una pendiente que represente a cada punto de validación

- **Coefficiente de correlación (r)**

El coeficiente de correlación explicado en la sección 2.7.1 se calculó para cada ejecución del modelo. Igualmente se usaron los coeficientes obtenidos en cada ejecución del modelo para obtener coeficientes de correlación mensuales, para luego comparar en cual o cuales puntos de validación se obtiene mejores valores del coeficiente de correlación.

Se usó el criterio que se encuentra en (Roxy, P. 2012, p.228), figura 3.5, para determinar el grado de correlación entre los valores simulados y las observaciones. Para cada ejecución del modelo se realizó un determinado gráfico de dispersión, de modo que en cada ejecución se verificó el grado de dispersión de las temperaturas pronosticadas en relación a las

temperaturas observadas. Estos gráficos de dispersión ayudaron a verificar la precisión de las simulaciones, ya que en cada gráfico se trazó una recta ideal con $a=0$ y $b=1$, que es la recta donde las temperaturas pronosticadas son exactamente iguales a las temperaturas observadas. Los pronósticos con una recta de regresión lineal más cerca de esta recta ideal verificaron mayor precisión en sus resultados.

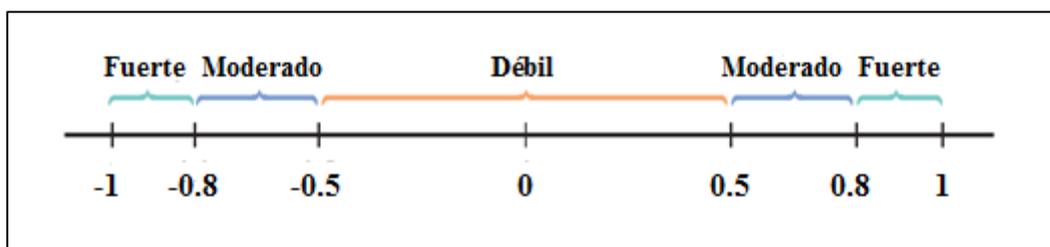


Figura 3.5. Fuerza en el grado de correlación

FUENTE: Roxy, P., 2012.

3.2.2. VALIDACIÓN DE LA SIMULACIÓN DE TEMPERATURAS

Considerando pronósticos deterministas, es bien sabido que la predictibilidad en modelos de mesoescala es de 2 a 3 días (Carvalho, D. et al, 2012, p.25). En base a este conocimiento lo que se realizó en este punto no fueron pronósticos de temperaturas en sí, sino solo simulaciones de temperaturas llevadas una mayor resolución utilizando la física y dinámica del modelo WRF. La diferencia principal con la realización de *pronósticos* es que, en este caso, se eligieron *datos de análisis* tanto para condiciones iniciales como para condiciones de frontera. El objetivo en este caso fue analizar el error de las simulaciones más allá de la predictibilidad teórica en modelos de mesoescala, y al mismo tiempo evaluar la confiabilidad de estos *datos de análisis* utilizados como fuente de entrada al modelo, de modo que estos *datos* puedan usarse en el modelo para hacer simulaciones de eventos atmosféricos pasados, y de ese modo verificar la consolidación de un buen comportamiento del modelo en zonas altoandinas de Puno y Arequipa. En la figura 3.6, se resumen los principales pasos que conllevaron a la obtención de los resultados en este procedimiento para obtener las temperaturas simuladas igualmente a 2 metros de la superficie.

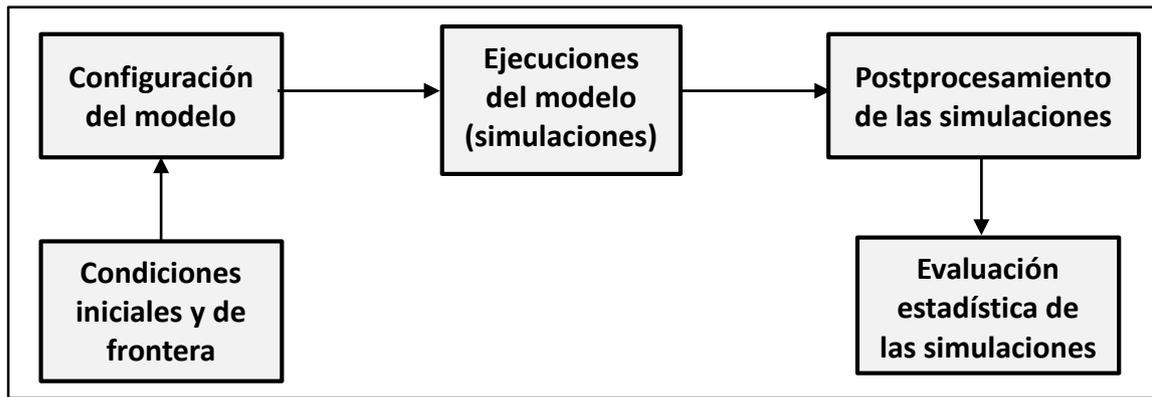


Figura 3.6. Diagrama de flujo para la simulación de temperaturas

FUENTE: Elaboración propia

a. CONDICIONES INICIALES Y DE FRONTERA

Las características de los datos de entrada para el modelo WRF que se utilizaron en este caso se pueden ver en la tabla 3.10. En esta tabla se puede ver que las condiciones iniciales y de frontera son *datos de análisis*, ya que en este caso se realizaron simulaciones de temperaturas y no estrictamente pronósticos. Estos datos provienen del modelo global GFS con una resolución temporal de 6 horas, lo que quiere decir que para el periodo de simulación elegido se descargaron datos de análisis de las horas 00Z, 06Z, 12Z y 18Z de los 31 días necesarios para realizar una ejecución del modelo.

Si bien el periodo de simulación que se eligió fue de un mes, en una ejecución del modelo también se obtienen diferentes horas simuladas menores a un mes, ya que la resolución de salida del modelo se ajustó a una hora. De ese modo la cantidad exacta de horas que se obtuvieron se puede ver en la tabla 3.15. Las primeras 12 horas de cada ejecución se obviaron debido al efecto *spin-up* (Coiffier, J. 2011, p.259), el cual es necesario ya que las primeras horas de pronóstico suelen ser alteradas a causa de la estabilización del modelo.

Tabla 3.10. Características de los datos de entrada para las simulaciones

	Para las condiciones iniciales	Para las condiciones de frontera
Tipo de datos	Datos de Análisis	Datos de Análisis
Fuente (Modelo global)	GFS	GFS
Resolución Espacial	0.5°x0.5°	0.5°x0.5°
Resolución temporal	-	6 horas
Formato de archivo	GRIB2	GRIB2

La cantidad de datos a recopilarse para que sirvan como fuente de entrada al modelo depende básicamente de la cantidad de ejecuciones que se realizan y de la resolución temporal de estos datos. Como la resolución temporal es de 6 horas, para un simulación de 31 días se tiene que descargar 125 datos (1 para las condiciones iniciales y 124 para las condiciones de frontera), la cantidad de datos que se recopilaron se obtuvo multiplicando el número total de ejecuciones por la cantidad total de datos descargados para una ejecución del modelo, tal y como lo muestra la tabla 3.11.

Tabla 3.11. Total de archivos descargados para realizar las simulaciones

Periodo	N° de ejecuciones	Resolución temporal	CI	CF	Total
Mayo/2014	1	6 horas (00z, 06z, 12z, 18z)	1x1=1	1x124=124	125
Julio/2014	1	6 horas (00z, 06z, 12z, 18z)	1x1=1	1x124=124	125
Total – 2 meses	2	-	2	248	250

CI: Condiciones iniciales, CF: Condiciones de frontera

b. CONFIGURACIÓN DEL MODELO

Igualmente para lograr una correcta configuración del modelo se siguieron principalmente recomendaciones de la *Guía de Usuario* del modelo y de tutoriales provistos en la página web oficial del modelo: <http://www2.mmm.ucar.edu/wrf/users/>, que ayudan al usuario a hacer un uso correcto del modelo y a entender el funcionamiento de modelo.

b.1. Dominios y anidamientos de simulación

En este caso la conformación del dominio padre y de los anidamientos es el mismo del que se estableció en la sección 3.2.1, con la diferencia que en este caso la decisión de establecer anidamientos es mucho más necesario debido a que el intervalo de simulación no es 120 horas, sino de un mes; de modo que se necesita con mayor razón economizar recurso computacional.

Igualmente, en este caso el dominio padre tiene una resolución espacial de 27 km, el primer anidamiento tiene una resolución espacial de 9 km y el segundo anidamiento tiene una resolución espacial de 3 km.

b.2. Opciones generales elegidas para la configuración del modelo

En la tabla 3.12 se resume las opciones principales elegidas para la configuración del modelo. En esta tabla también se muestra que se está configurando el modelo con un dominio padre y con dos anidamientos. Estos anidamientos también tienen que tener una determinada configuración en sus dimensiones como se puede ver en la tabla. Igualmente, cada una de las opciones que aparecen en la tabla 3.12 se eligen modificando los archivos de texto acoplados al modelo, primero el *namelist.wps* para ejecutar el preprocesador WPS y luego el archivo *namelist.input* para ejecutar del procesador. Estos archivos de texto se muestran en los anexos 1 y 2.

La resolución temporal elegida para hacer la simulación del modelo fue de una hora, tal y como se ve en la tabla 3.12. Esta resolución permitió no solo analizar con mayor precisión y a mayor detalle el comportamiento del modelo al simular temperaturas superficiales a 2 metros, sino también permitió verificar cómo las temperaturas extremas frías, que son las que producen las más intensas heladas, son simuladas con el modelo.

Tabla 3.12. Configuración general elegida para las simulaciones

Opciones \ Dominios	Dominio Padre (1er dominio)	1er Anidamiento (2do dominio)	2do Anidamiento (3er dominio)
Niveles verticales	41	41	41
Resol. horizontal dx	27 km	9 km	3 km
Resol. horizontal dy	27 km	9 km	3 km
Resolución temporal	1 hora	1 hora	1 hora
Tiempo de paso (seg.)	60	30	10
N° de puntos (X, Y, Z)	76x76x41	76x76x41	76x76x41
Tipo de Anidamiento	Two-way		
Núcleo Dinámico	ARW		
Versión del modelo WRF	3.4.1		

b.3. Elección de las opciones de física en el modelo

Para la simulación de temperaturas se usa las mismas opciones de física que se usaron en la sección 3.2.1. Se eligieron las opciones de física para regiones frías que se recomiendan en la *Guía de Usuario del Modelo WRF* (Guía de Usuario WRF. 2012, p.5.26). Las opciones de física (parametrizaciones) más importantes elegidas para las simulaciones se muestran en la tabla 3.13.

Igualmente, para una completa revisión de todas las opciones de la física y dinámica elegidas en este procedimiento se puede ver el anexo 2.

Tabla 3.13. Opciones de física elegidas para realizar las simulaciones

Proceso físico	Dominio Padre	1er Anidamiento	2do Anidamiento
Capa límite planetaria (PBL)	Mellor-Yamada-Janjic (Eta) TKE		
Microfísica de nubes	WSM 5-class		
Interacción superficie-tierra	<i>unified</i> Noah		
Cúmulos	<i>new</i> Kain-Fritsch	<i>new</i> Kain-Fritsch	no cúmulos
Capa superficial	Monin-Obukhov (Janjic Eta)		
Radiación en onda larga	RRTMG		
Radiación en onda corta	<i>(old)</i> GODDARD		

c. EJECUCIONES DEL MODELO

Para ejecutar el modelo correctamente se siguió principalmente las indicaciones y recomendaciones dispuestas en la *Guía de Usuario del modelo* y en tutoriales provistos en la página web oficial del modelo: <http://www2.mmm.ucar.edu/wrf/users/>.

c.1. Diagrama de flujo elegido para ejecutar el modelo

En este caso se utilizó también el flujo de simulación que se muestra en la figura 3.4. Igualmente se eligió este flujo de simulación primero porque se tiene fácil acceso a las herramientas involucradas en los procesos de simulación de este flujo, y segundo porque el adiestramiento existente se adecua convenientemente a este flujo.

c.2. Número de ejecuciones del modelo

En este punto se realizaron dos ejecuciones del modelo. Cada ejecución se realizó en una determinada hora de inicialización (condición inicial), como se puede ver en la tabla 3.14. Como no se puede dejar correr el modelo de forma infinita, se tiene que elegir un periodo de simulación o intervalo de tiempo en donde se tiene que realizar las simulaciones, por eso, en este caso, cada ejecución del modelo corrió para un intervalo de un mes, de modo que la hora de finalización también se muestra en la tabla 3.14. Como la resolución temporal de salida del modelo que se eligió fue de una hora, en total se obtuvieron 744 horas simuladas en cada ejecución del modelo. De ese modo, en cada hora simulada se obtuvieron diferentes variables meteorológicas simuladas, sin embargo para fines del presente estudio solamente se analizó la variable: temperatura a dos metros de la superficie. Debido al efecto *spin-up* (Coiffier, J. 2011, p.259) se obviaron las primeras 12 horas de las 745 horas obtenidas en cada simulación (o ejecución del modelo).

Tabla 3.14. Hora de inicio y fin de las simulaciones

Periodo de simulación	Simulaciones	Hora de inicialización	Hora de finalización
Mayo 2014	1ra ejecución	00Z 01 Mayo 2014	00Z 01 Junio 2014
Julio 2014	1ra ejecución	00Z 01 Julio 2014	00Z 01 Agosto 2014

Igualmente que en la sección 3.2.1, el mes de mayo se eligió porque en este mes se empiezan a registrar las primeras heladas, de modo que se quería saber si el modelo lograba simular adecuadamente estas heladas tempranas. El mes de julio se eligió porque en este mes suelen ocurrir heladas con mayor frecuencia y con mayor intensidad.

De las 745 horas obtenidas en cada ejecución, 12 horas fueron obviadas debido al efecto *spin-up* (Coiffier, J. 2011, p.259), de modo que al final se obtuvieron 733 horas simuladas para un punto de la *grilla* de simulación establecida. De ese modo, el tamaño de muestra para un punto de la *grilla* fue de 733 datos. Según (Bowerman, B., et al. 2007) este tamaño es más que suficiente para analizar estadísticamente series temporales.

c.3. Procedimiento para una sola ejecución del modelo

Para realizar las simulaciones de este caso también se utilizaron los ordenadores del Departamento de Ingeniería Ambiental, Física y Meteorología, de la Universidad Nacional Agraria La Molina (UNALM), con la colaboración también de la Dirección General de Investigación Ambiental perteneciente al Servicio Nacional de Meteorología e Hidrología (SENAMHI).

Los ordenadores que se utilizaron para el manejo del modelo tienen las características que se muestran en la tabla 3.15. En total se utilizaron tres ordenadores, en los cuales se instaló el modelo y otros softwares necesarios (sección 3.1) para la realización del estudio.

Tabla 3.15. Característica del ordenador utilizado para las simulaciones

Característica	Tipo
Procesador	Intel Core i7 – 3.40 Ghz
Memoria RAM	4 GB
Capacidad Disco Duro	1 Terabyte
Número de Núcleos	8
Sistema Operativo	Kubuntu 12.4 – 32 bits

Teniendo en cuenta el tiempo necesario para la adecuación de los ordenadores y el tiempo de manejo del modelo para la simulación, el tiempo de operación para las dos ejecuciones del modelo en este procedimiento de simulación fue cerca de 2 semanas.

Todos los archivos involucrados en la simulación ingresaron y se obtuvieron en horas del Meridiano de Greenwich (hora Z).

Cada ejecución del modelo se realizó siguiendo los procedimientos descritos a continuación:

c.3.1. Manejo del preprocesador - WRF *Preprocessing System* (WPS)

El manejo del preprocesador es el mismo que el que se realizó en el punto c.3.1 de la sección 3.2.1.

Según la configuración elegida en el modelo y según la capacidad del ordenador, la corrida del preprocesador para cada ejecución del modelo duró cerca de 3 horas.

c.3.2. Manejo del Procesador WRF

Igualmente en este caso los procedimientos son los mismos que los que se siguieron en el punto c.3.2 de la sección 3.2.1.

Considerando la configuración elegida en el modelo y la capacidad del ordenador donde se realizaron las simulaciones, una ejecución del programa *real* duró cerca de 5 minutos, y la duración de la corrida del programa *wrf* para cada ejecución duró cerca de 3 días.

c.4. Número de horas pronosticadas obtenidas en las ejecuciones

De acuerdo a la resolución temporal de salida elegida en el modelo, en la tabla 3.16 se aprecia la cantidad exacta de horas simuladas que se obtuvieron en todas las ejecuciones del modelo. Tener en cuenta que en esta tabla no se está considerando a las condiciones iniciales como hora simulada, pero como igualmente éstas se obtuvieron al final de las simulaciones, se contaron en el total de tiempos obtenidos.

Tabla 3.16. Total de horas simuladas obtenidas en cada simulación

	Hora de inicio de la simulación	Resolución temporal de salida	CI	Horas simuladas obtenidas	Total de horas obtenidas
1ra simulación	00Z 01Mayo/2014	1 hora	1x1h=1	1x744=744	745
2da simulación	00Z 01Julio/2014	1 hora	1x1h=1	1x744=744	745
Total			2	1490	1492

CI: Condiciones iniciales

d. POSTPROCESAMIENTO DE LAS SIMULACIONES

Los procedimientos para el postprocesamiento de las salidas de las ejecuciones del modelo son los mismos a los descritos en el punto “d” de la sección 3.2.1.

Teniendo en cuenta la configuración elegida en el modelo y la capacidad del ordenador donde se realiza los pronósticos, la duración de la corrida del programa ARWpost solo para una ejecución del modelo, en este caso, fue cerca de 25 minutos.

e. EVALUACIÓN ESTADÍSTICA DE LAS SIMULACIONES

La evaluación estadística de las simulaciones en este caso se realizó suponiendo que los valores simulados obtenidos con el modelo WRF son de mayor precisión que esos que se obtendrían si se interpolaran (interpolación espacial y temporal) los datos del modelo global directamente a los puntos de validación del presente estudio. Esa suposición es razonable considerando que los *datos de análisis* que se interpolarían son de menor resolución y que la misma interpolación agregaría errores.

e.1. Número de puntos de validación

Igualmente en este procedimiento el número de puntos para la validación del modelo fueron los mismos puntos de validación que se establecieron en el punto e.1 de la sección 3.2.1.

e.2. Datos incompletos y limpieza de datos en las observaciones

Igualmente las observaciones pasaron por un proceso de depuración, que consistió en detectar algunos datos que no se ajusten a la realidad o que estén fuera de contexto. Esta depuración se realizó utilizando gráficos y cuadros donde se pueda identificar datos atípicos (*outliers*), ya que según (Hand, D. 2001, p.50), al analizar solo una variable se puede detectar *outliers* utilizando solo cuadros y/o gráficos.

Igualmente los datos faltantes en las observaciones fueron completados analíticamente. En (Bramer, M. 2007, p.17), se menciona que en el caso de variables continuas, como la variable meteorológica temperatura, se puede estimar estos valores faltantes por valores promedios. En el presente estudio estos valores promedios se obtuvieron interpolando los valores más cercanos a estos valores faltantes.

e.3. Elección de variables meteorológicas para la validación

El resultado de la simulación generó diferentes variables meteorológicas (temperatura, viento, precipitación, etc.) simuladas a diferentes alturas y niveles de presión, sin embargo para fines del presente estudio solo se analizó la variable temperatura a dos metros de la superficie, ya que el enfoque de este procedimiento de simulación es evaluar el error de simulación más allá de la predictibilidad estimada del modelo (2 a 3 días).

e.4. Elección de las coordenadas de validación

En este caso se siguieron los mismos pasos descritos en el punto e.4 de la sección 3.2.1, solo que en este caso se configuró el *script* para extraer todos los tiempos generados en la simulación según la tabla 3.15. Tener en cuenta que en este procedimiento se realizaron solo dos ejecuciones del modelo, por lo que la cantidad de *scripts* utilizados fue menor que en el procedimiento del punto e.4 de la sección 3.2.1. La cantidad exacta de *scripts* diferentes creados para extraer todas las temperaturas simuladas necesarias para la evaluación estadística de este procedimiento se muestran en la tabla 3.17.

Tabla 3.17. Total de scripts creados para cada simulación

Periodo de simulación	Ejecuciones del modelo	Número de puntos de validación	Cantidad scripts creados
Mayo/2014	1ra simulación	4	4
Julio/2014	2da simulación	4	4
Total		4	8

e.5. Cálculo de medidas de precisión

Tener en cuenta que en cada ejecución del modelo se obtuvieron 744 horas simuladas. Sin embargo, para la evaluación estadística se obviaron las primeras doce horas de la simulación debido al efecto *spin-up* (Coiffier, J. 2011, p.259). De ese modo en cada ejecución del modelo se está realizando el análisis estadístico con una muestra de 733 datos. Luego se utilizaron los resultados de las medidas de precisión en cada ejecución del modelo para calcular medidas de precisión mensuales en cada punto de validación (estación meteorológica).

Se realizó el cálculo de las mismas medidas de precisión establecidas en el punto e.5 de la sección 3.2.1. Tener en cuenta también que en este caso a cada punto de validación le corresponde dos ejecuciones, uno en mayo y otro en julio.

IV. RESULTADOS Y DISCUSIÓN

4.1. VALIDACIÓN DEL PRONÓSTICO DE TEMPERATURAS

4.1.1. ANÁLISIS DE LAS MEDIDAS DE PRECISIÓN EN CADA PUNTO DE VALIDACIÓN

a. PRIMER PUNTO DE VALIDACIÓN – ESTACIÓN CHIVAY

Observando la figura 4.1 se puede suponer que la variación conjunta de los pronósticos y de las observaciones en este punto es similar, sin embargo se puede notar que en casi todas las ejecuciones existe una tendencia a la subestimación de las temperaturas máximas y una sobreestimación de las mínimas. El *bias* promedio en la tabla 4.1 confirma que tanto en mayo (-0.58°C) como en julio (-0.73°C) existe, en promedio, una subestimación de las temperaturas, ya que estos valores son negativos.

La tabla 4.1 muestra que la variabilidad de las observaciones es ligeramente mejor pronosticada en julio que en mayo ya que la desviación estándar de las observaciones (S_o) es ligeramente mejor pronosticada en julio que en mayo. En relación a los errores de pronóstico no existe una gran diferencia entre los MAE's y RMSE's mensuales de mayo (2.22 y 2.58) y los MAE's y RMSE's de julio (1.92 y 2.37). De igual modo, el índice de Willmott (0.948) y el *bias* (-0.58°C) sugieren que en julio los pronósticos son ligeramente más precisos que en mayo (0.938 y -0.73°C), un caso particular, ya que según (Warner, T. 2011, p.308), en los meses fríos los errores de pronóstico por lo general suelen ser mayores. Igualmente los valores de la pendiente y el intercepto en julio (1.77 y 0.64) logran mejores valores a los de mayo (2.49 y 0.67).

La única medida promedio favorable a mayo es el índice de correlación, con un valor de 0.958 sobre 0.953 en julio, no obstante estos valores no difieren mucho, además que son

valores que indican un alto grado de correlación. De cualquier modo observando el gráfico 4.2 se puede notar que en todas las ejecuciones el grado de correlación es de grado alto, lo que indica una alta correspondencia entre observaciones y pronósticos. Esta alta correspondencia no sería de tanta relevancia si los errores de pronóstico fueran valores altos. Sin embargo, con valores del (RMSE's) que oscilan entre 1.7 y 3.01°C, la correspondencia logra ser estadísticamente significativa.

El hecho que en julio las medidas de precisión sean más favorables refleja claramente que los procesos físicos de la atmósfera que predominan en este punto de validación son, en promedio, bien simulados por el modelo. Sin embargo, hay que recalcar que en los dos meses: mayo y julio, se obtienen resultados similares, por lo tanto, según el análisis de las medidas de precisión realizado anteriormente, los pronósticos en este punto son estadísticamente significativos.

**Tabla 4.1. Resumen de las medidas de precisión calculadas para cada pronóstico.
Estación Chivay**

	Hora de inicio de pronóstico ¹	Bias	S_o	S_p	a	b	MAE	RMSE	d	r
Mayo 2014	01 00Z	-1.17	5.92	4.23	2.36	0.68	2.13	2.53	0.937	0.956
	09 00Z	-1	5.55	4.29	1.43	0.73	1.78	2.22	0.948	0.950
	16 00Z	-0.83	6.20	4.29	2.56	0.66	2.20	2.54	0.940	0.959
	24 00Z	0.08	6.92	4.22	3.59	0.59	2.76	3.01	0.925	0.968
	Promedio del mes	-0.73	6.15	4.26	2.49	0.67	2.22	2.58	0.938	0.958
Julio 2014	01 00Z	0.84	5.94	4.25	3.68	0.68	1.96	2.39	0.944	0.956
	09 00Z	-2.2	6.26	4.99	0.77	0.28	2.37	2.95	0.933	0.962
	16 00Z	-0.29	4.79	4.52	0.84	0.88	1.37	1.72	0.964	0.935
	24 00Z	-0.69	6.31	4.62	1.78	0.70	1.97	2.41	0.950	0.957
	Promedio del mes	-0.58	5.83	4.60	1.77	0.64	1.92	2.37	0.948	0.953
	Promedio total	-0.66	5.99	4.43	2.13	0.65	2.07	2.47	0.942	0.955

¹Para hacer los cálculos se obviaron las 12 primeras horas en cada ejecución por el efecto *spin-up*.

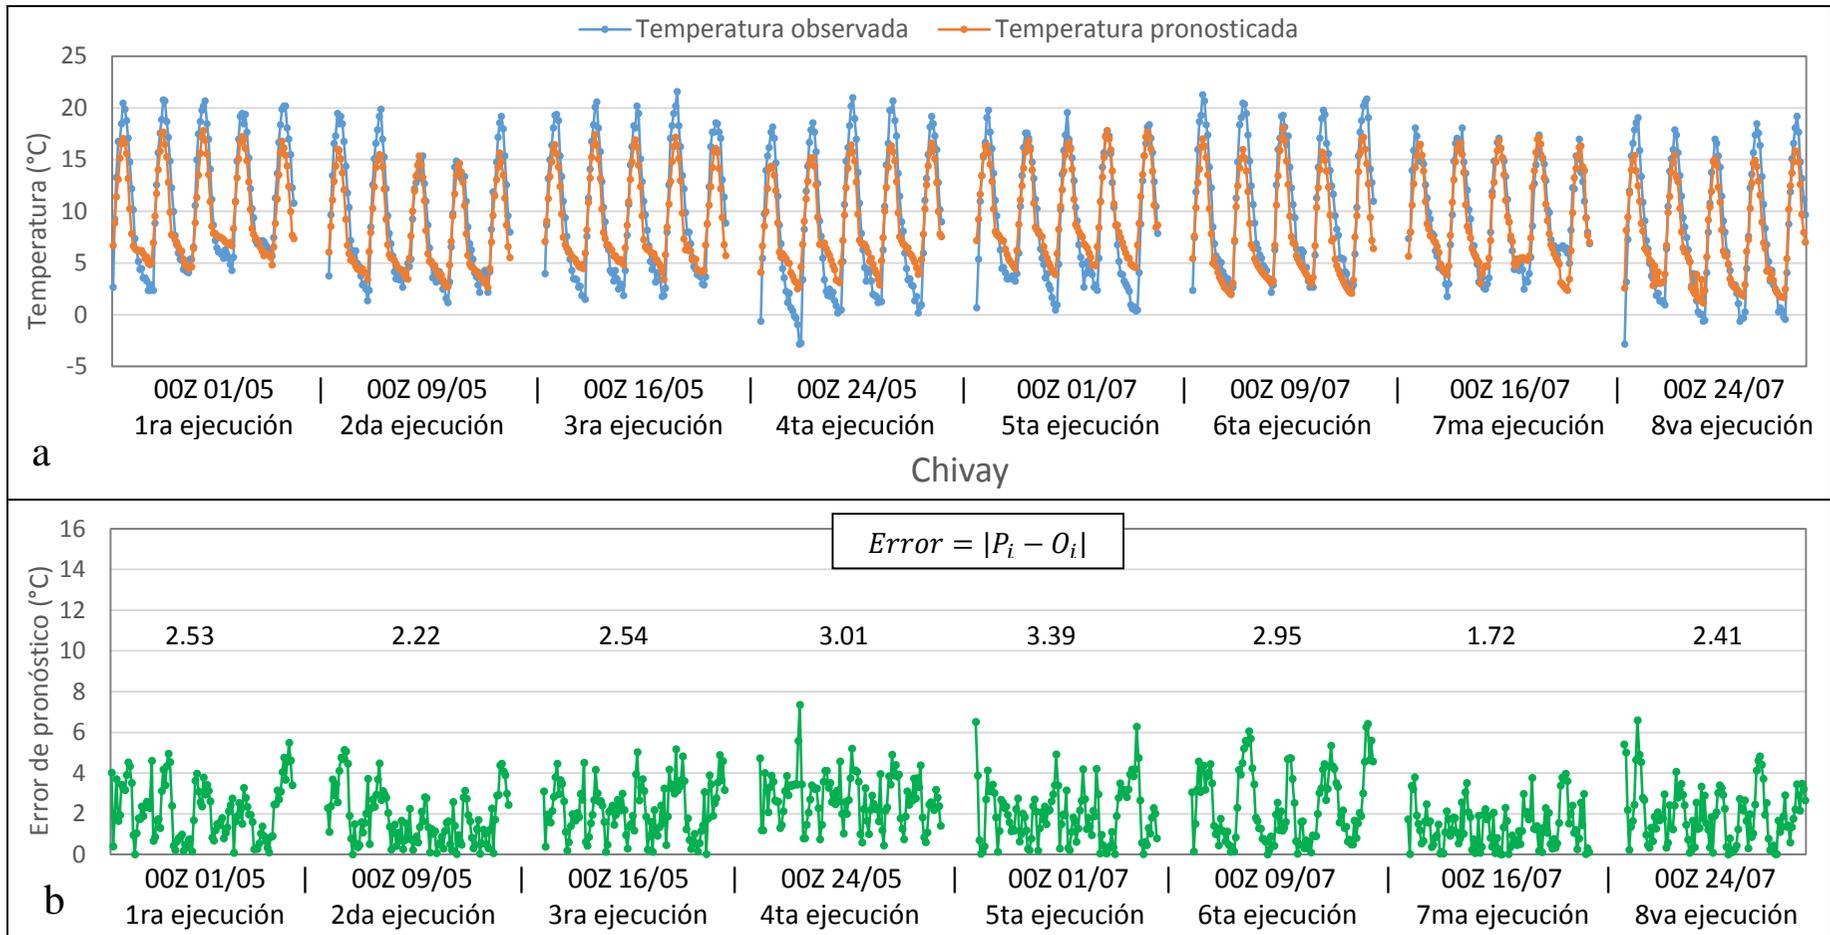


Figura 4.1. Comparación de temperaturas observadas y pronosticadas en la estación Chivay. (a) Serie temporal horaria de temperaturas observadas y de las temperaturas pronosticadas. Cada pronóstico se realizó con 120 horas de anticipación, sin embargo las primeras 12 horas se obviaron debido al efecto *spin-up*. Se muestra cada pronóstico con su respectiva hora de inicialización. (b) Serie temporal horaria del valor absoluto de los errores de pronóstico para cada ejecución a través de los dos meses donde se realizaron los pronósticos. Sobre cada ejecución se puede observar también el valor de su RMSE correspondiente.

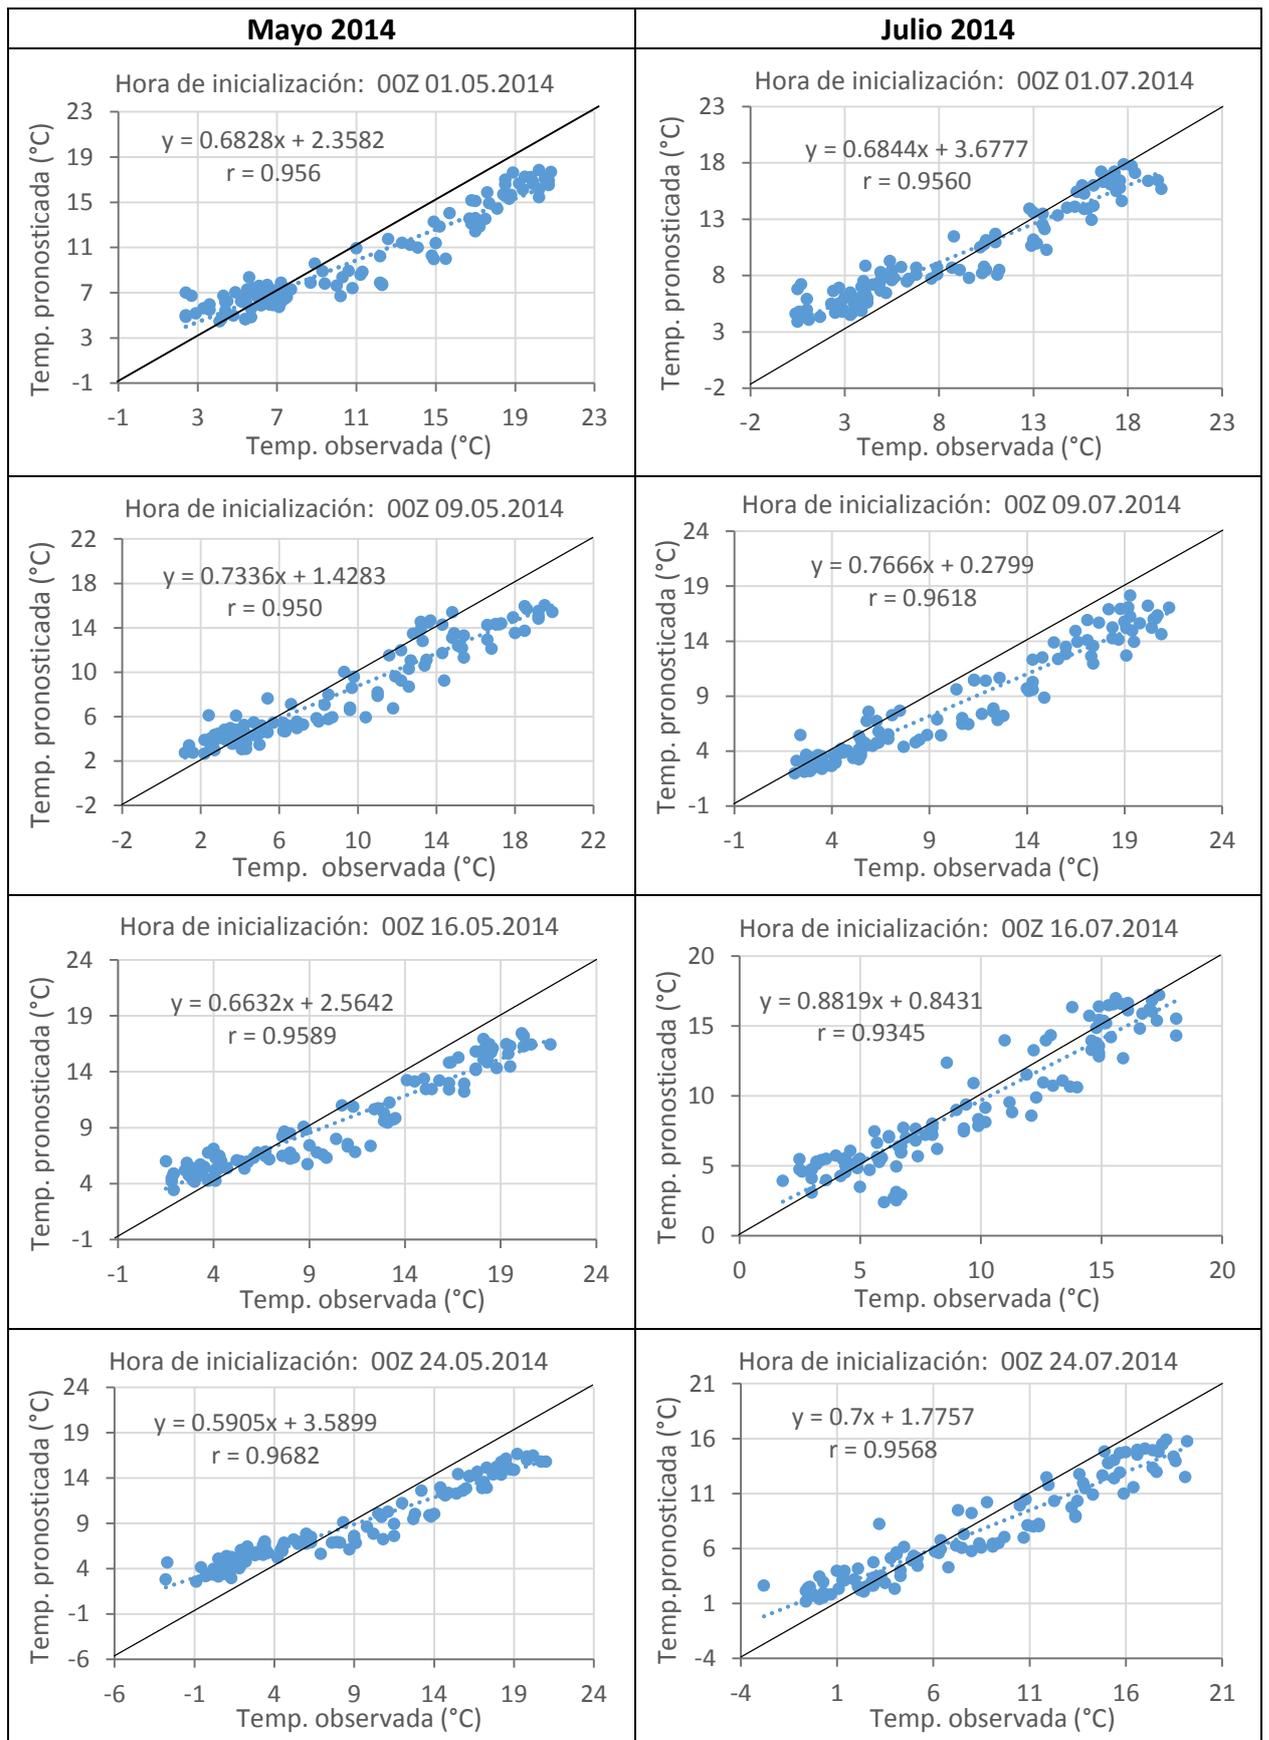


Figura 4.2. Diagramas de dispersión y regresión lineal de los pronósticos - Estación Chivay. En cada caso se muestra la hora de inicialización de cada pronóstico.

b. SEGUNDO PUNTO DE VALIDACIÓN - ESTACIÓN LA ANGOSTURA

Los altos valores del coeficiente de correlación en la tabla 4.2 en todas las ejecuciones del modelo precisan que la variación conjunta de las temperaturas pronosticadas y observadas es representativa. Sin embargo, el intercepto promedio (a) en mayo y en julio, 1.71 y 2.5 respectivamente, sugieren que existe errores de pronóstico considerables; aun cuando la pendiente promedio (b) en mayo y en julio, (0.84 y 0.52), sean cercanos a la unidad. Los errores MAE y RMSE aumentan considerablemente en el mes de julio, llegando hasta 4.57°C en la octava ejecución.

Observando la figura 4.3b se puede ver que el modelo simula bien las temperaturas en las tres primeras ejecuciones correspondientes al mes de mayo, a partir de esta fecha las temperaturas mínimas empiezan a aumentar y el modelo no logra simular correctamente estas temperaturas. Incluso en mayo ocurre una helada intensa que llega hasta -10.2°C el 25 de mayo (como se puede ver en la cuarta ejecución del mes de mayo), pero que el modelo lo estimó como -2.9°C, habiendo un considerable error de 7.3°C, y esto ocurrió al segundo día de pronóstico en esa ejecución del modelo, descartando que ese error se pueda deber a la predictibilidad estimada del modelo (2-3 días).

En este punto de validación se cumple lo señalado en (Warner, T. 2011, p.308): que en los meses fríos los errores de pronóstico tienden a aumentar. Efectivamente los errores aumentan en este punto, y lo hacen gracias a la llegada del invierno. Observando el gráfico 4.3 se puede ver que la ocurrencia de temperaturas extremas frías aumenta en julio, donde las temperaturas mínimas llegan a alcanzar valores muy por debajo de 0°C llegando hasta -10°C en algunos días. Así en el mes de julio intensas heladas se vuelven más frecuentes, lo que hace al modelo difícil pronosticarlas, ¿por qué al modelo le cuesta pronosticar estas temperaturas extremas frías en este punto de validación? Observando las series temporales en la figura 4.4, la predictibilidad del modelo (2-3 días) no tendría nada que ver con la precisión en que el modelo pronostica estas temperaturas, ya que las diferencias entre las temperaturas mínimas de los pronósticos y las temperaturas mínimas de las observaciones a partir de la cuarta ejecución se reflejan en altos valores del RMSE, llegando a 4.57°C en la octava ejecución. Las razones podrían deberse más a las opciones de física elegidas en el modelo que no son las adecuadas según los factores meteorológicos que dominan este punto geográfico. Otras de las razones también puede ser las características topográficas (altitud,

albedo, tipo de suelo, cobertura de vegetación, etc.) que el modelo estima dentro de su sistema de modelamiento, conocidas también como *data estática*, porque son características propias del lugar que no varían considerablemente con el tiempo; en este punto el modelo no lograría representar adecuadamente estas características.

Si bien, el modelo no logra estimar adecuadamente las temperaturas extremas mínimas en este punto, el gráfico 4.4 muestra que la variación conjunta de las temperaturas pronosticadas y observadas es significativa, esto se muestra en los altos valores del coeficiente de correlación promedio en mayo y julio (0.947 y 0.894 respectivamente). Cuando se habla de variación conjunta, se refiere a la variación simultánea temporal entre los datos pronosticados obtenidos con el modelo y los datos observados: que si el valor observado aumenta, el pronosticado también lo hace; que si el valor observado disminuye, el pronosticado también lo hace. Que la variación conjunta sea similar es un indicio que mejorando las opciones de física del modelo se podrían obtener mejores pronósticos.

Ya observando la figura 4.3 se puede anticipar que el *bias* en los dos meses será positivo, ¿por qué? La figura muestra que existe mayormente sobreestimación de las temperaturas mínimas, lo que contribuye mayormente a obtener un *bias* positivo, de hecho en todas las ejecuciones se tiene un *bias* positivo. Si bien el *bias* promedio es ligeramente mayor en mayo que en julio (1.08 y 0.95°C respectivamente), los valores promedio del MAE y del RMSE en mayo (1.94 y 2.41°C) y además el mayor valor del índice de Willmott en mayo (0.954) que en julio (0.862) confirman que en mayo se obtienen mejores pronósticos, sobre todo en la primera y segunda ejecución.

En este punto se puede notar que valores del *bias* cercanos al valor ideal de cero no necesariamente indica que exista una alta precisión, simplemente indica que tan alejado están las medias de los valores pronosticados y los observados, y si existe en promedio sobreestimación o subestimación de los valores reales (observaciones). Un caso similar ocurre con el índice de correlación promedio (r), 0.947 en mayo y 0.894 en julio; estos valores no necesariamente se pueden interpretar como un alto grado de precisión, ya que, como se puede ver en la tabla 4.2, el error (RMSE) va aumentando su valor hasta llegar a un valor considerable de 4.57 °C en la última ejecución y sin embargo el valor del “ r ” es 0.814. Este ejemplo muestra que altos grados de correlación no significan necesariamente un alto grado de precisión. El “ r ” solo refleja el grado de correspondencia, en este caso, entre

pronósticos y observaciones, y que a pesar de los errores altos en el mes de julio (3.59, 3.67, 3.10, 4.57) la correlación es de grado alto según la tabla 4.2 y la figura 3.5.

**Tabla 4.2. Resumen de las medidas de precisión calculadas para cada pronóstico.
Estación La Angostura.**

	Hora de inicio del pronóstico ¹	<i>bias</i>	S_o	S_p	<i>a</i>	<i>b</i>	MAE	RMSE	<i>d</i>	<i>r</i>
Mayo 2014	01 00Z	1.14	5.25	5.69	0.90	1.04	1.57	1.96	0.967	0.960
	09 00Z	0.72	5.24	4.85	1.29	0.86	1.65	2.06	0.957	0.929
	16 00Z	1.14	6.13	5.06	2.19	0.78	1.85	2.35	0.955	0.949
	24 00Z	1.35	7.69	5.52	2.47	0.68	2.67	3.28	0.937	0.950
	Promedio mayo	1.08	6.08	5.28	1.71	0.84	1.94	2.41	0.954	0.947
Julio 2014	01 00Z	0.90	6.89	3.80	2.78	0.52	2.94	3.59	0.884	0.950
	09 00Z	0.27	7.02	4.23	2.25	0.54	2.97	3.67	0.888	0.903
	16 00Z	1.09	5.10	3.41	2.08	0.56	2.59	3.10	0.860	0.839
	24 00Z	1.53	7.16	3.57	2.88	0.44	3.88	4.57	0.814	0.885
		Promedio julio	0.95	6.54	3.75	2.50	0.52	3.10	3.73	0.862
	Promedio total	1.02	6.31	4.52	2.11	0.68	2.52	3.07	0.908	0.921

¹Para hacer los cálculos se obviaron las 12 primeras horas en cada ejecución por el efecto *spin-up*.

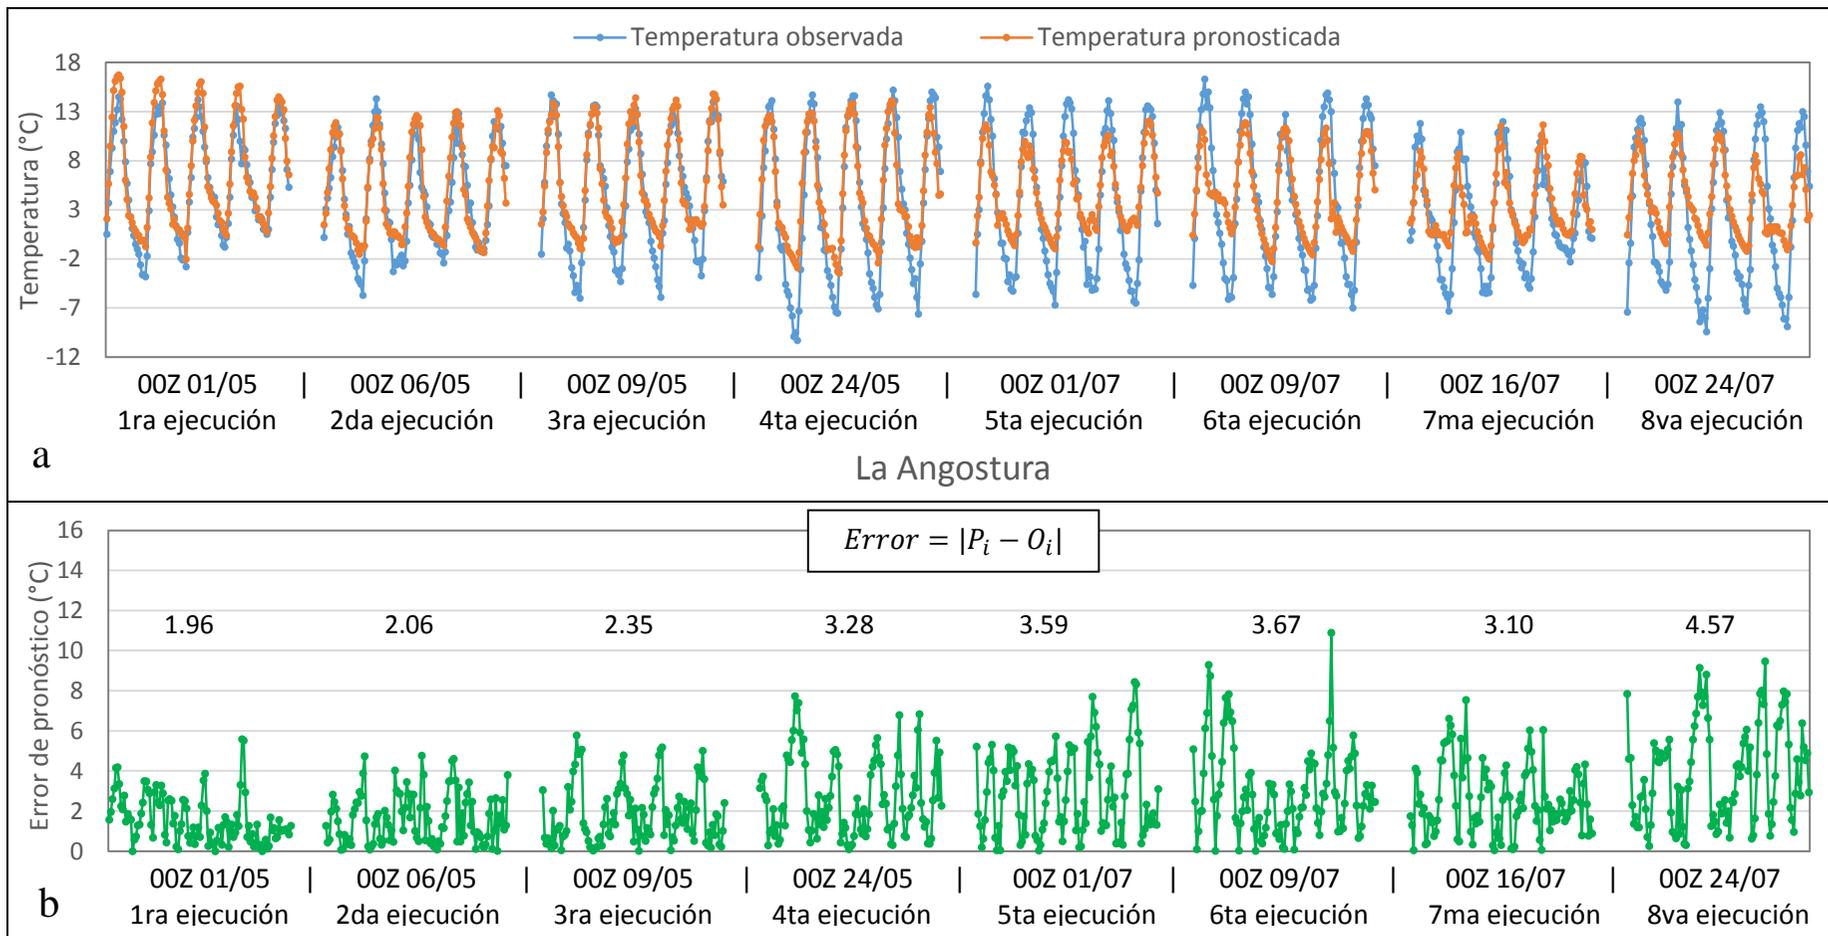


Figura 4.3. Comparación de temperaturas observadas y pronosticadas en la estación La Angostura. (a) Serie temporal horaria de temperaturas observadas y de las temperaturas pronosticadas. Cada pronóstico se realizó con 120 horas de anticipación, sin embargo las primeras 12 horas se obviaron debido al efecto *spin-up*. Se muestra cada pronóstico con su respectiva hora de inicialización. (b) Serie temporal horaria del valor absoluto de los errores de pronóstico para cada ejecución a través de los dos meses donde se realizaron los pronósticos. Sobre cada ejecución se puede observar también el valor de su RMSE correspondiente.

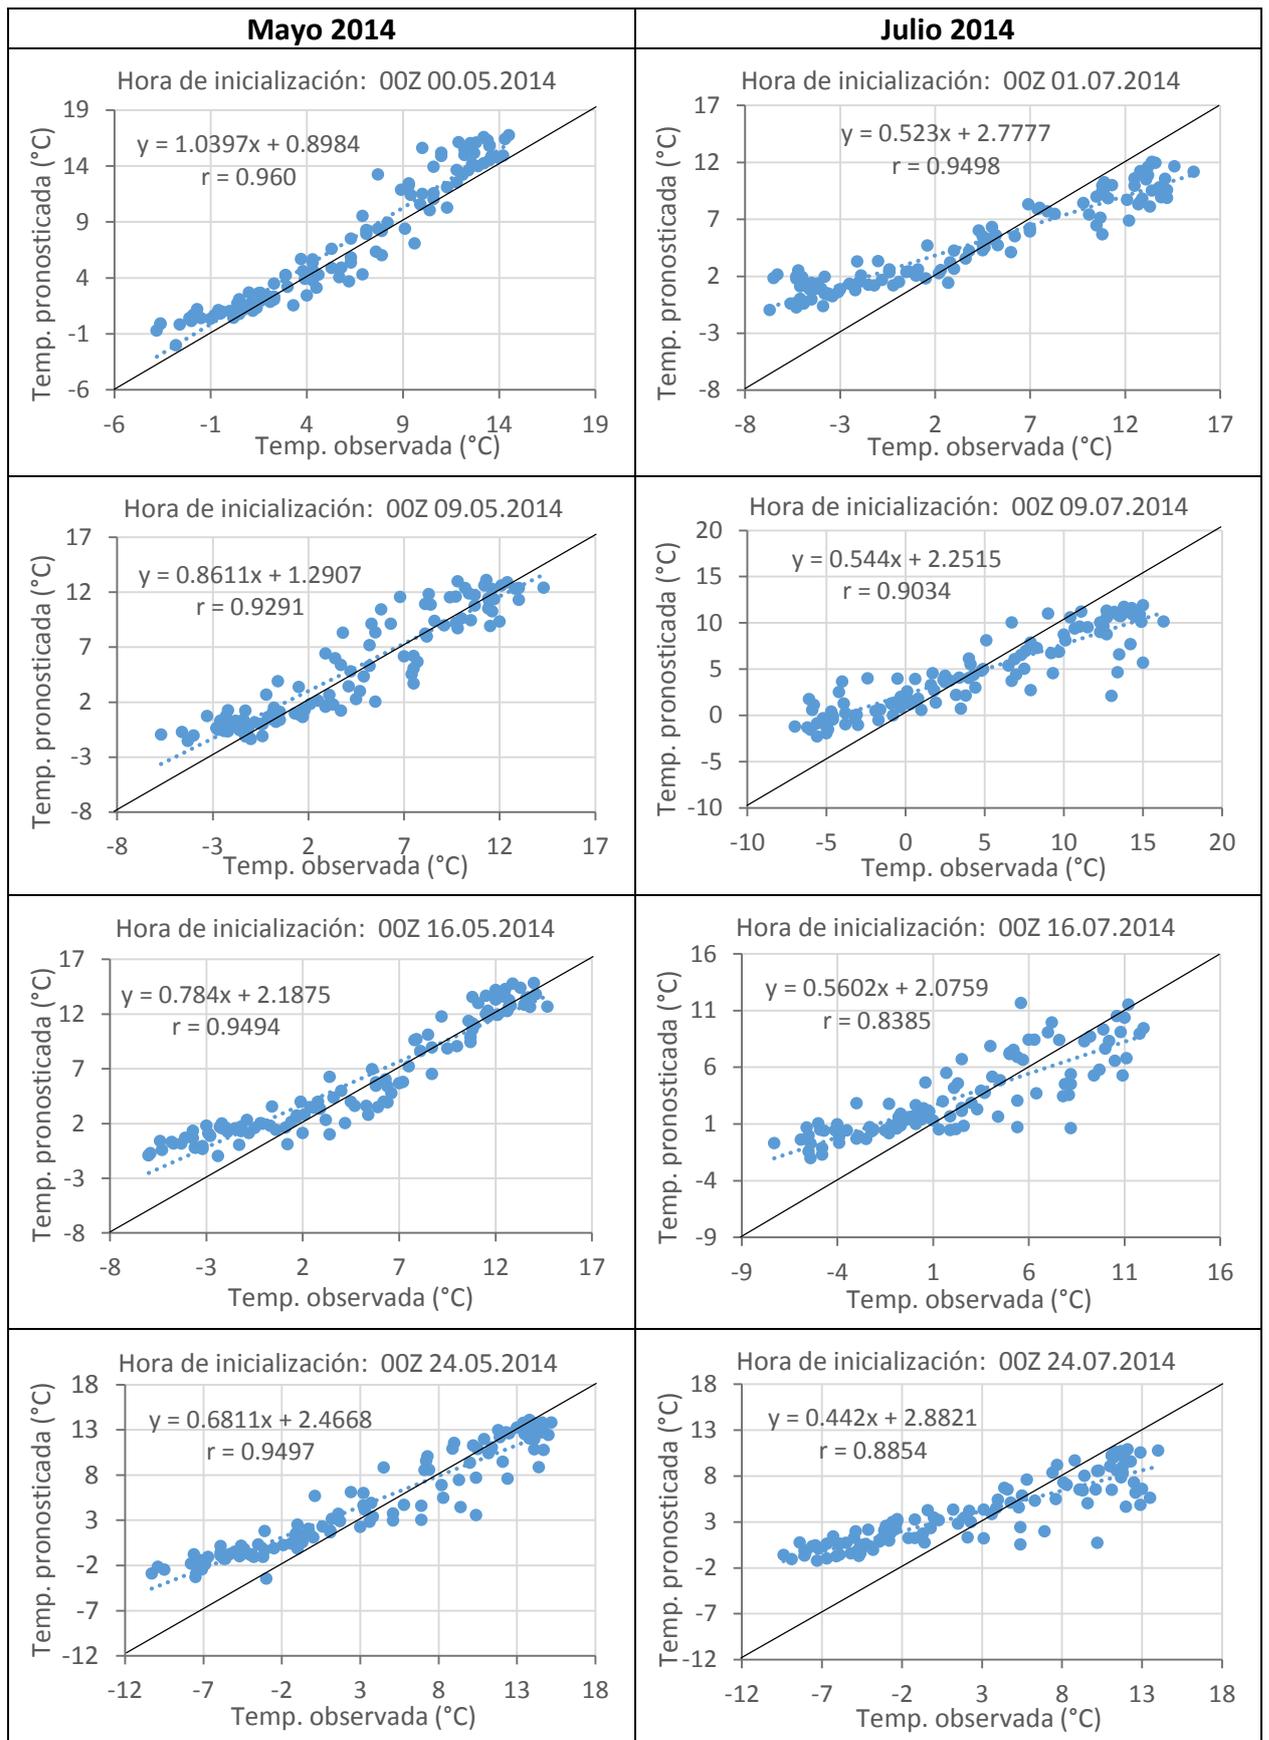


Figura 4.4. Diagramas de dispersión y regresión lineal de los pronósticos - Estación La Angostura. En cada caso se muestra la hora de inicialización de cada pronóstico.

c. TERCER PUNTO DE VALIDACIÓN - ESTACIÓN LAGUNILLAS

Observando la figura 4.5 se puede notar también que el comportamiento de las temperaturas pronosticadas y observadas es similar, sin embargo solo en la variación conjunta, ya que se tienen que revisar los valores de los errores para determinar si existe una precisión significativa. En ese sentido la tabla 4.3 muestra que el MAE en todas las ejecuciones del mes de mayo se mantiene alrededor de 1.5°C llegando hasta 1.62°C en la cuarta ejecución. El RMSE varía cercanamente alrededor de 2.5°C , sin embargo en la cuarta ejecución el valor del RMSE aumenta y llega hasta 3.08°C , ¿a qué se podría deber este aumento repentino del error en la cuarta ejecución del mes de mayo? Observando el gráfico 4.5 este aumento del error coincide con la disminución de las temperaturas mínimas. Hasta la tercera ejecución las temperaturas mínimas oscilaban cercanamente alrededor de -2°C ; a partir de la cuarta ejecución estas temperaturas empiezan a oscilar alrededor de -6°C . Esta disminución repentina de las temperaturas puede ser la causa del aumento del valor del RMSE en la cuarta ejecución. En el mes de julio el valor del RMSE casi no varía y se mantiene alrededor de 2.5°C llegando hasta 2.78°C en la octava ejecución. Estos resultados en los valores del MAE y del RMSE muestran que tanto en el mes de mayo como en julio el error de pronóstico logra un cierto grado de constancia y no logra variaciones significativas, por lo que se puede afirmar que tanto en mayo como en julio se consigue una precisión similar y significativa ya que los errores no son tan altos a comparación de otro puntos de validación.

El *bias* promedio en el mes de mayo y julio es -0.21°C y -0.78°C respectivamente (los dos valores negativos), lo que indica que en promedio existe una subestimación de las temperaturas en los dos meses, sugiriendo que los mayores errores se dan gracias a las diferencias entre las temperaturas máximas en el día entre pronósticos y observaciones. Sin embargo, como en el mes de mayo se obtiene un *bias* más cercano al valor cero se concluye que el mayo los pronósticos son ligeramente más representativos a los de julio. En el caso de la variabilidad de las temperaturas, esta variabilidad es bien simulada en el mes de mayo con un valor de la desviación estándar (S) de 5.09 sobre 5.22°C ; en julio la variabilidad no es tan bien pronosticada (3.65 sobre 5.33°C), y esto gracias a la disminución de las temperaturas mínimas en este mes. En este caso, en función a la desviación estándar, en mayo se logran mejores pronósticos que en julio. Igualmente la pendiente, el intercepto y el índice de Willmott, todos valores promedios, son más favorables para el mes de mayo. Sin

embargo, los errores (MAE y RMSE) y el coeficiente de correlación (todos valores promedios) son favorables para el mes de julio. No obstante, teniendo en cuenta que los errores (MAE y RMSE) y los coeficientes de correlación son valores cruciales al momento de determinar precisión, y teniendo en cuenta también que los valores de estas medidas es mayo (1.48, 2.64 y 0.883) no varían significativamente en julio (1.42, 2.59 y 0.918), se puede afirmar que en mayo se obtienen mejores pronósticos, aunque debido a la similitud en los valores se puede afirmar también que los pronósticos en mayo y en julio tienen el mismo grado de precisión.

Si bien es cierto que el RMSE es menor en julio, el índice de Willmott no lo es. Se puede ver también en la figura 4.6 que los coeficientes de correlación son mayores en julio que en mayo. Recordando que este coeficiente es sensible a valores atípicos (*outliers*), se puede ver que este valor está relacionado con el RMSE, ya que este valor también es sensible a *outliers*. Lo que quiere decir que mayores valores del RMSE reflejarán índices de correlación menores, sin embargo la frecuencia de valores atípicos es lo que influye considerablemente en el valor de coeficiente de correlación. Esto último es lo que sucede con los índices de correlación en julio, donde la frecuencia de *outliers* es menor que en mayo, lo que quiere decir que existen más *outliers* en mayo que en julio, y que son los que producen menores índices de correlación en mayo, a pesar que en mayo los RMSE's son similares a los RMSE's de julio.

Analizando las tablas 4.1, 4.2, 4.3 y 4.4, se llega a la conclusión que el índice de Willmott es una medida importante, que es sensible a valores atípicos (por lo tanto es similar al valor RMSE). Observando estas tablas también se deduce que un valor del índice de Willmott alto, cercano a uno, asegura que existe una buena correlación en los datos, pero no asegura que exista un error menor. Asimismo un valor del índice de Willmott, por ejemplo menor a 0.9, no significa que el coeficiente de correlación oscile alrededor de 0.9 o sea menor a 0.9, es más, puede haber un índice de Willmott menor a 0.9 y una correlación alta cercana a 1, en este caso el bajo valor del índice de Willmott se debe principalmente a los altos errores generados. Por eso es importante hacer el análisis de todas las medidas de precisión para determinar precisión en los pronósticos.

Lagunillas es el punto que tiene la mayor altitud, 4367 metros, y sin embargo los errores no son tan significativos y además la correlación es de grado alto. Este análisis permite concluir

que las opciones de física conjuntamente con la forma en que el modelo representa los factores topográficos de la zona (altitud, vegetación, tipo de suelo, albedo, etc.) son representativos para este punto de validación; se tendría que realizar otro estudio para encontrar las parametrizaciones que puedan generar menores errores.

Haciendo un análisis general del comportamiento del modelo en los dos meses, se llega a la conclusión que el modelo tiene un comportamiento significativo en este punto de validación a través de las medidas de precisión calculadas, tanto en mayo como en julio ¿En los demás meses se tendrá el mismo comportamiento? Basándose en lo establecido en (Warner, T. 2011), el comportamiento del modelo en los demás meses debería ser similar o aún mejor.

Tabla 4.3. Resumen de las medidas de precisión calculadas para cada pronóstico. Estación Lagunillas.

	Hora de inicio de pronóstico ¹	<i>bias</i>	<i>S_o</i>	<i>S_p</i>	<i>a</i>	<i>b</i>	MAE	RMSE	<i>d</i>	<i>r</i>
Mayo 2014	01 00Z	-0.79	4.88	5.28	-0.46	0.95	1.46	2.61	0.931	0.881
	09 00Z	-0.73	4.64	4.81	-0.33	0.92	1.37	2.34	0.936	0.889
	16 00Z	-0.36	5.17	5.06	0.45	0.86	1.46	2.54	0.935	0.878
	24 00Z	1.04	6.17	5.20	2.11	0.74	1.62	3.08	0.923	0.882
	Promedio del mes	-0.21	5.22	5.09	0.44	0.87	1.48	2.64	0.931	0.883
Julio 2014	01 00Z	-0.85	5.58	3.60	0.92	0.61	1.43	2.56	0.921	0.951
	09 00Z	-1.01	5.74	3.93	0.86	0.64	1.42	2.64	0.925	0.940
	16 00Z	-1-11	4.21	3.29	0.08	0.68	1.32	2.39	0.896	0.868
	24 00Z	-0.15	5.78	3.78	1.08	0.60	1.50	2.78	0.912	0.914
	Promedio del mes	-0.78	5.33	3.65	0.74	0.63	1.42	2.59	0.914	0.918
	Promedio	-0.50	5.27	4.37	0.59	0.75	1.45	2.62	0.922	0.900

¹Para hacer los cálculos se obviaron las 12 primeras horas en cada ejecución por el efecto *spin-up*.

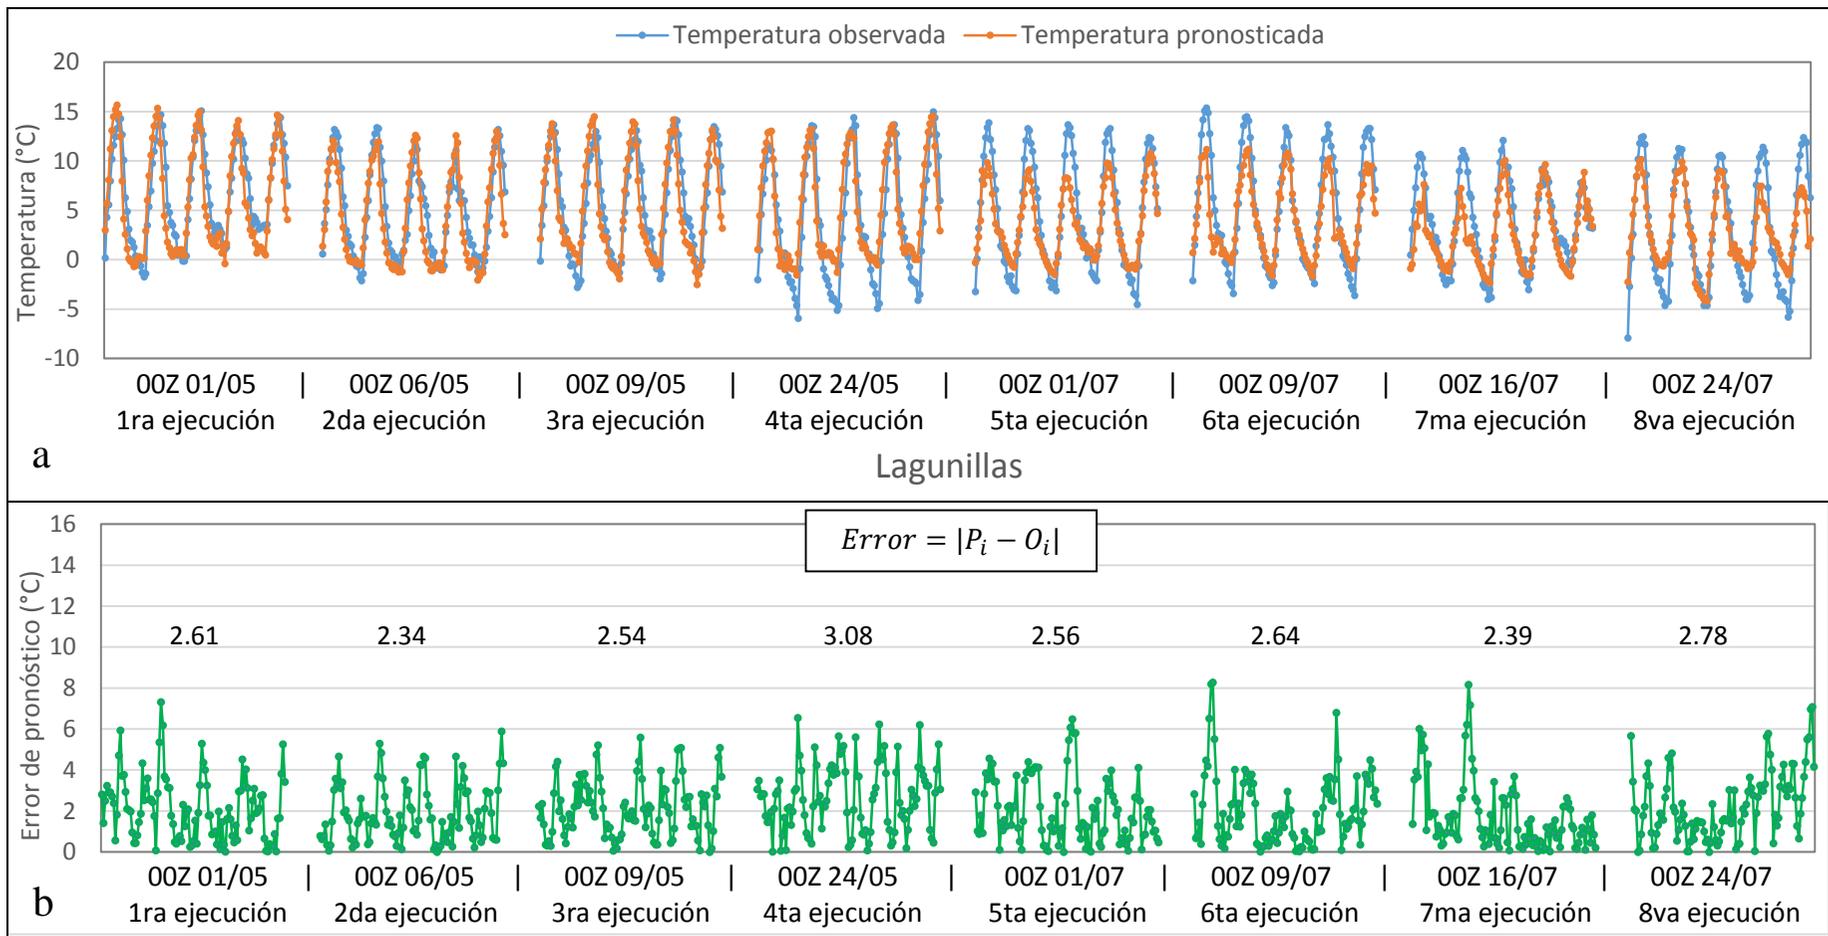


Figura 4.5. Comparación de temperaturas observadas y pronosticadas en la estación Lagunillas. (a) Serie temporal horaria de temperaturas observadas y de las temperaturas pronosticadas. Cada pronóstico se realizó con 120 horas de anticipación, sin embargo las primeras 12 horas se obviaron debido al efecto *spin-up*. Se muestra cada pronóstico con su respectiva hora de inicialización. (b) Serie temporal horaria del valor absoluto de los errores de pronóstico para cada ejecución a través de los dos meses donde se realizaron los pronósticos. Sobre cada ejecución se observa también el valor de su RMSE correspondiente.

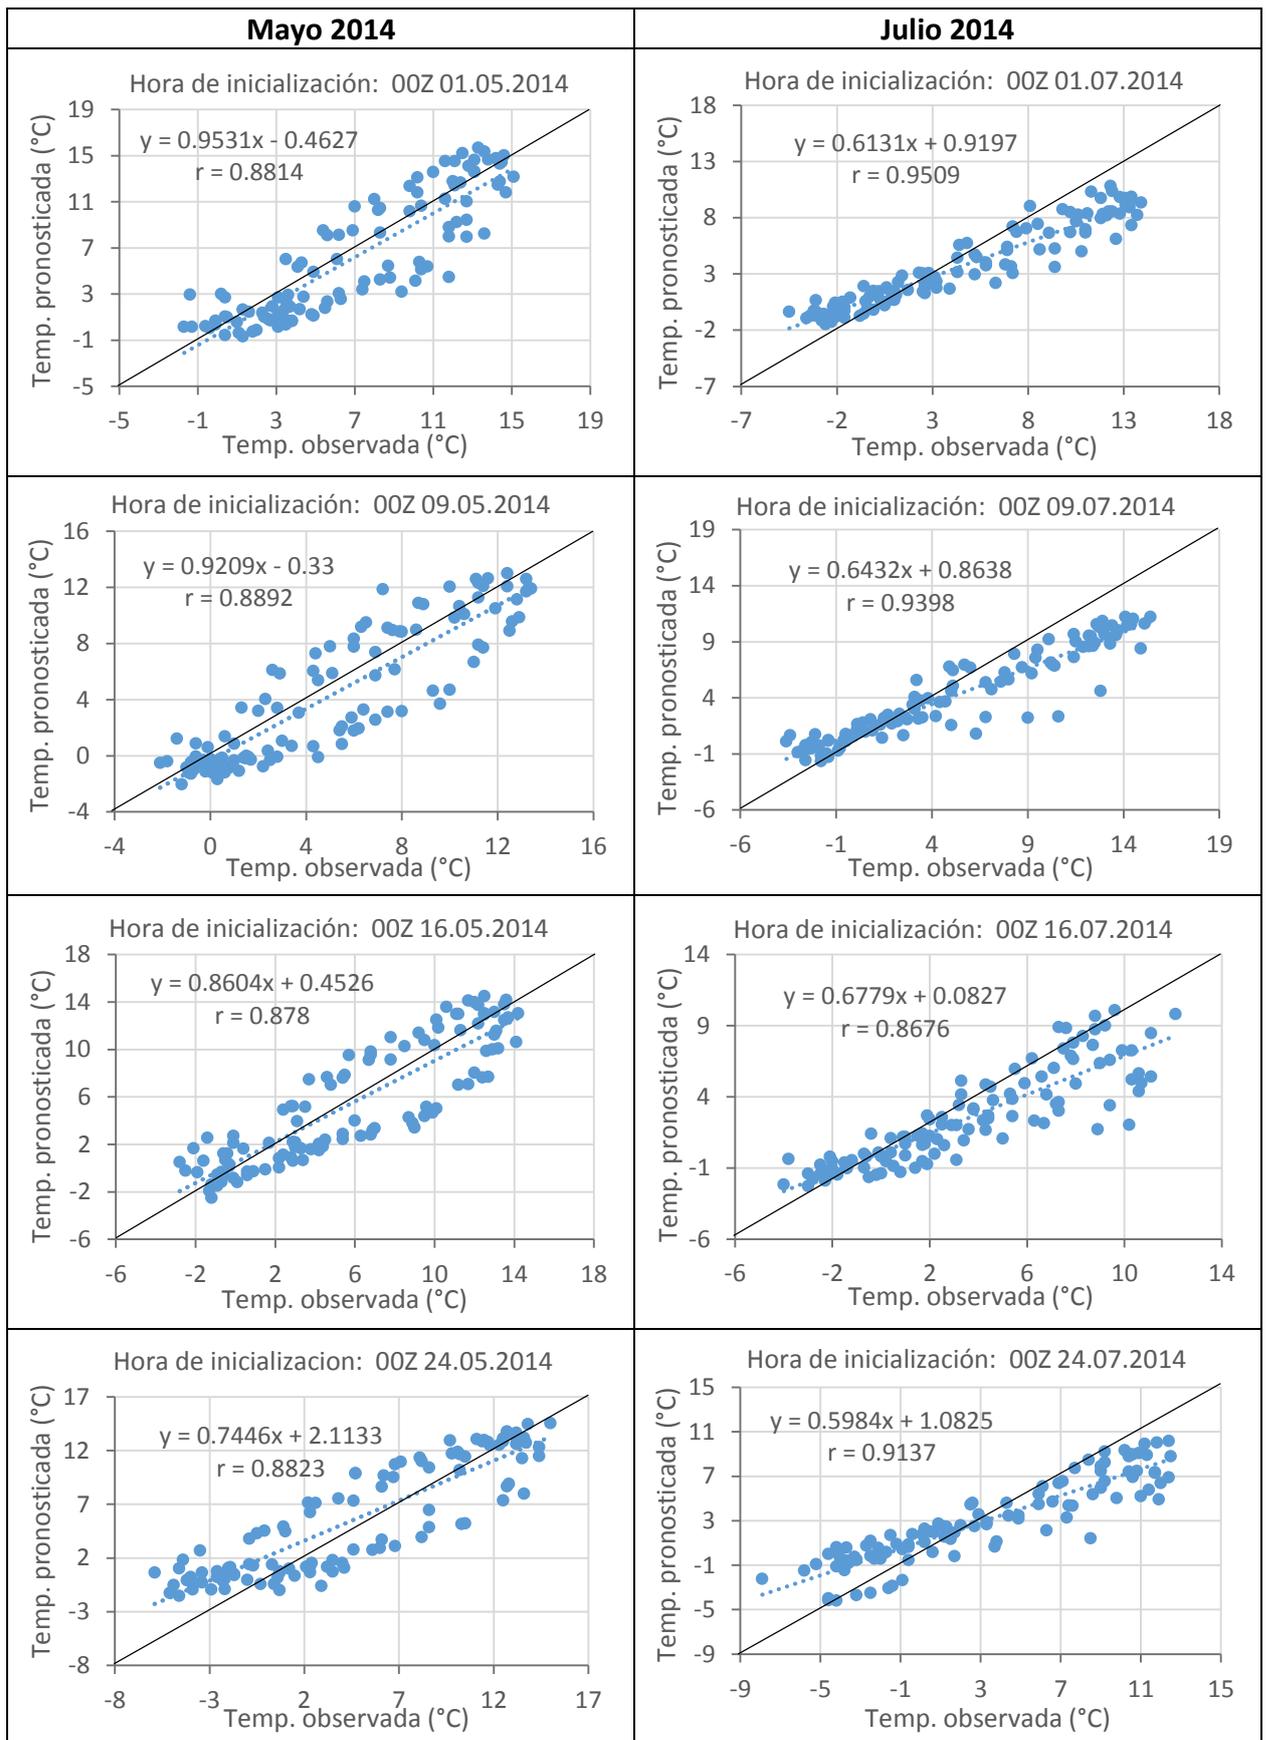


Figura 4.6. Diagramas de dispersión y regresión lineal de los pronósticos – Estación Lagunillas. En cada caso se muestra la hora de inicialización de pronóstico.

d. CUARTO PUNTO DE VALIDACIÓN - ESTACIÓN PAMPAHUTA

En este punto de validación se obtienen los mayores errores de pronóstico. Observando la figura 4.7 se puede apreciar que las diferencias entre las temperaturas pronosticadas y observadas son considerables. Estas diferencias se ven reflejadas en los altos valores del RMSE y MAE en todas las ejecuciones del modelo tanto en mayo y julio, llegando hasta 5.39°C en la quinta ejecución, en comparación con los valores de los RMSE's de los anteriores puntos de validación. Hay que resaltar que a pesar que los RMSE's son más altos en este punto, el grafico 4.8 muestra que los coeficientes de correlación logran aceptables valores manteniéndose en un grado medio e incluso llegando a valores de grado alto como 0.863 en la sexta ejecución. Estos valores del coeficiente de correlación indican que la variación conjunta de las temperaturas pronosticadas y observadas logra una correspondencia de grado medio, aunque los errores de pronóstico sean son altos. Este es un claro ejemplo de que índices de correlación altos no necesariamente van a generar errores de pronósticos bajos, el índice de correlación es una medida para verificar si existe una buena variación conjunta lineal entre dos variables, en este caso, entre pronósticos y observaciones.

El análisis de las medidas de precisión que se muestran en la tabla 4.4 favorece a los pronósticos realizados en mayo. Esta afirmación se logra gracias a que los valores de las siguientes medidas: desviación estándar, pendiente, MAE, RMSE e índice de Willmott, favorecen a los pronósticos realizados en mayo. En julio la correlación y el *bias*, en promedio, son mejores; no obstante las demás medidas terminan decidiendo que los mejores pronósticos se dan en mayo en lugar de julio. Recordar que el intercepto (a) está íntimamente relacionado con la pendiente, ya que pertenecen a la misma ecuación de regresión lineal. El intercepto es importante en el caso que se tenga dos pendientes iguales, de modo que el intercepto termina siendo el factor determinante para elegir cuál ecuación de regresión lineal representa mejor la variación lineal conjunta entre pronósticos y observaciones.

Observando la figura 4.7 el *bias* promedio tanto en mayo como en julio es negativo. Se puede observar que estos valores negativos se deben principalmente a la subestimación de las temperaturas en el día. Esta figura muestra también que las temperaturas mínimas, en los dos meses, tienden a sobreestimarse incluso cuando el *bias* promedio mensual es negativo en los dos meses. La sobreestimación de las temperaturas mínimas y la subestimación de las temperaturas máximas son los que producen los altos valores del RMSE promedio (4.30°C

en mayo y 4.63°C en julio), aun cuando el *bias* mensual en los dos meses no se alejan mucho de cero, con valores de -0.82°C y -0.36°C en mayo y julio respectivamente.

Más o menos a partir del 25 de mayo las temperaturas mínimas en esta estación empiezan a disminuir. Hasta esa fecha las temperaturas mínimas estaban oscilando cercanamente alrededor de -5°C , sin embargo a partir de esta fecha se empieza a sentir la llegada del invierno y las temperaturas mínimas empiezan a oscilar cercanamente alrededor de -7°C . Es justamente a partir de esta fecha donde también empiezan a aumentar los errores de pronóstico, y eso se puede observar en el valor del MAE y del RMSE en la cuarta ejecución (4.32°C y 5.23°C respectivamente).

Cabe resaltar que en este punto de validación la variabilidad de las temperaturas es mayor en comparación con las anteriores estaciones de validación, esto se refleja en los valores altos de la desviación estándar de las observaciones, 6.09 y 6.71°C en mayo y julio respectivamente. Estos altos valores de las desviaciones estándar coinciden con una mayor frecuencia de las temperaturas extremas frías, aun cuando en Pampahuta no ocurren las temperaturas frías más bajas. Los valores de la desviación estándar (*S*) empiezan a aumentar, sobre todo, a partir de la segunda ejecución. Esta alta variabilidad de los datos puede ser una de las razones por el cual los errores de pronóstico (RMSE's) son altos en este punto (4.30°C en mayo y 4.63°C en julio) comparado con los anteriores puntos de validación.

A pesar que en este punto ocurren también temperaturas extremas frías con una frecuencia considerable, en este punto no ocurren las temperaturas mínimas más intensas; es en la estación La angostura donde ocurren aún temperaturas mínimas más intensas. De ese modo, según el comportamiento del modelo observado en los anteriores puntos de validación, se esperaría mejores pronósticos en Pampahuta que en La Angostura debido a que en La Angostura ocurren las temperaturas más bajas; ¿a qué se podría deberse que los errores de pronóstico son mayores en Pampahuta si en La Angostura ocurren temperaturas mínimas más extremas? Una de las razones es que los factores topográficos (*data estática*) tales como albedo, tipo de suelo, altitud, cobertura de vegetación, etc., no llegan a ser bien representados por el modelo en los alrededores de Pampahuta. Asimismo otra explicación se puede encontrar en las opciones de física elegidas en el modelo para realizar los pronósticos. Sin embargo, los índices de correlación de grado medio en todas las ejecuciones del modelo son un indicio que la precisión de los pronósticos se podría mejorar probando otras opciones de

física que representen adecuadamente los procesos físicos que predominan en este punto de validación.

**Tabla 4.4. Resumen de las medidas de precisión calculadas para cada pronóstico.
Estación Pampahuta**

	Hora de inicio del pronóstico ¹	<i>bias</i>	S_o	S_p	<i>a</i>	<i>b</i>	MAE	RMSE	<i>d</i>	<i>r</i>	
Mayo 2014	01 00Z	-0.48	5.52	4.52	1.50	0.61	2.87	3.75	0.849	0.741	
	09 00Z	-1.85	5.34	3.74	0.02	0.51	3.33	4.05	0.797	0.733	
	16 00Z	-0.47	6.03	4.13	1.65	0.50	3.30	4.18	0.817	0.724	
	24 00Z	-0.52	7.48	4.68	1.12	0.45	4.32	5.23	0.798	0.721	
	Promedio del mes	-0.82	6.09	4.27	1.07	0.52	3.46	4.30	0.815	0.730	
Julio 2014	01 00Z	-0.68	7.30	2.97	1.21	0.31	4.71	5.39	0.709	0.766	
	09 00Z	-0.51	7.31	3.55	1.42	0.42	3.95	4.61	0.810	0.863	
	16 00Z	-0.48	4.98	3.06	0.49	0.47	2.64	3.28	0.822	0.771	
	24 00Z	0.20	7.24	3.21	0.91	0.33	4.42	5.25	0.726	0.753	
		Promedio del mes	-0.36	6.71	3.20	1.01	0.38	3.93	4.63	0.767	0.788
		Promedio total	-0.59	6.40	3.73	1.04	0.45	3.69	4.47	0.791	0.759

¹Para hacer los cálculos se obviaron las 12 primeras horas en cada ejecución por el efecto *spin-up*.

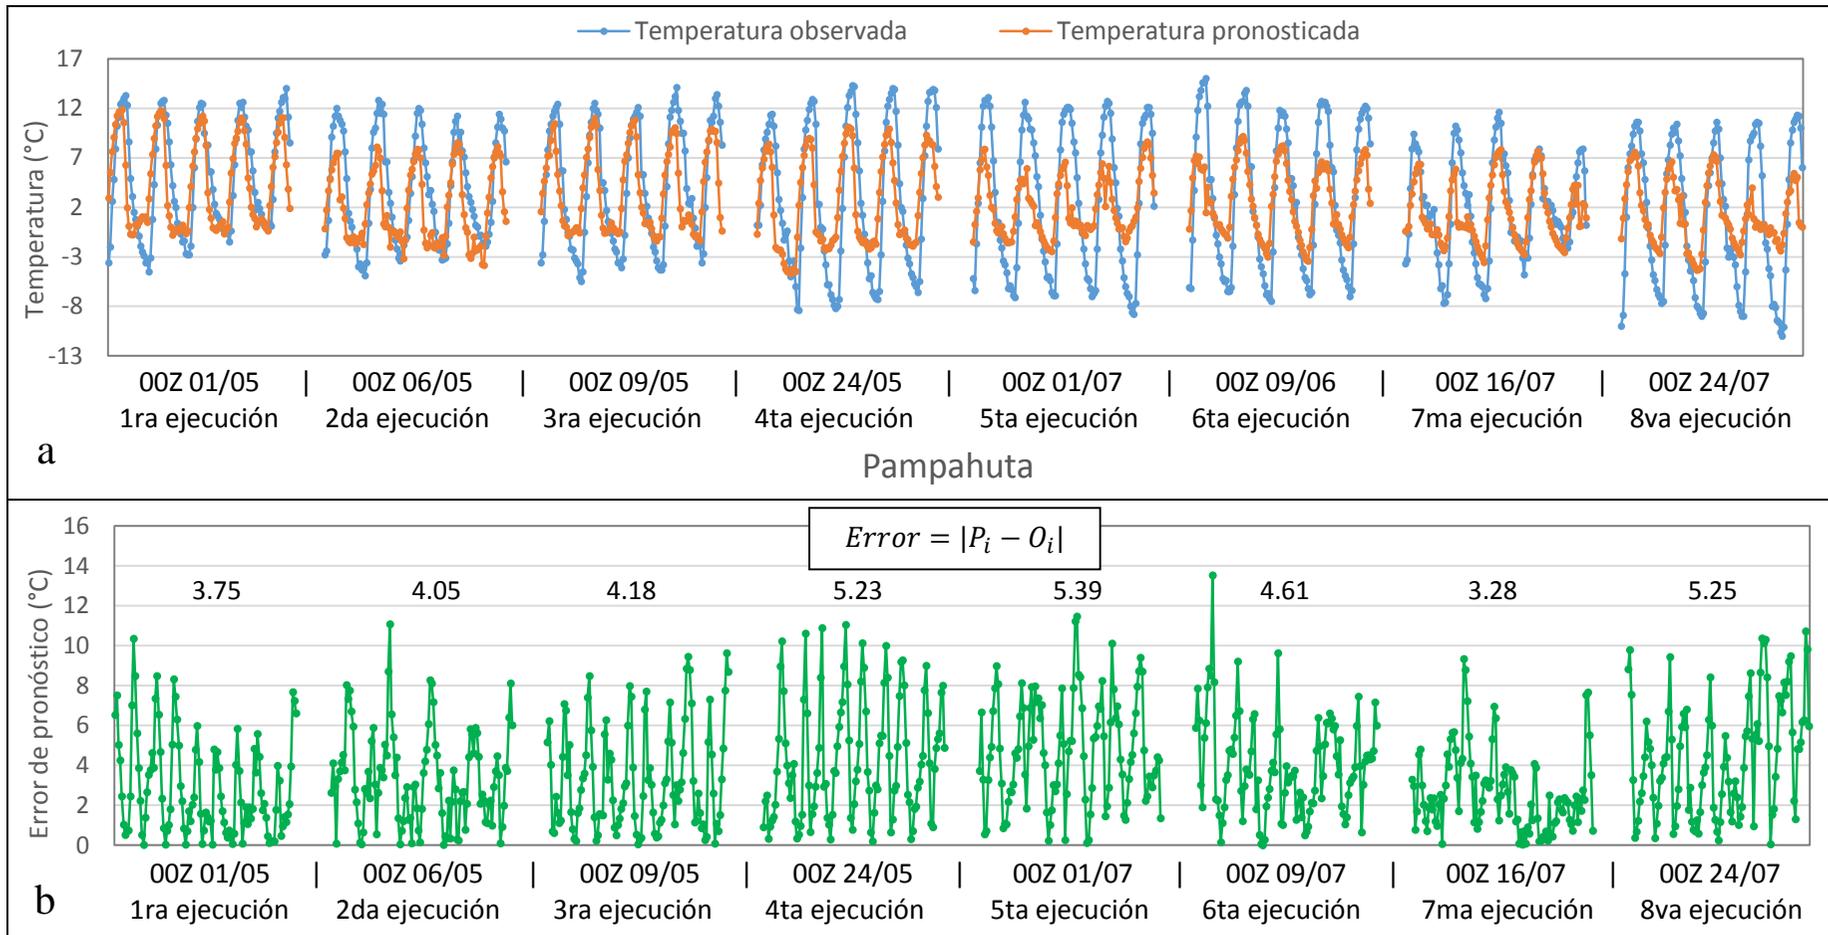


Figura 4.7. Comparación de temperaturas observadas y pronosticadas en la estación Pampahuta. (a) Serie temporal horaria de temperaturas observadas y de las temperaturas pronosticadas. Cada pronóstico se realizó con 120 horas de anticipación, sin embargo las primeras 12 horas se obviaron debido al efecto *spin-up*. Se muestra cada pronóstico con su respectiva hora de inicialización. (b) Serie temporal horaria del valor absoluto de los errores de pronóstico para cada ejecución a través de los dos meses donde se realizaron los pronósticos. Sobre cada ejecución se observa también el valor de su RMSE correspondiente.

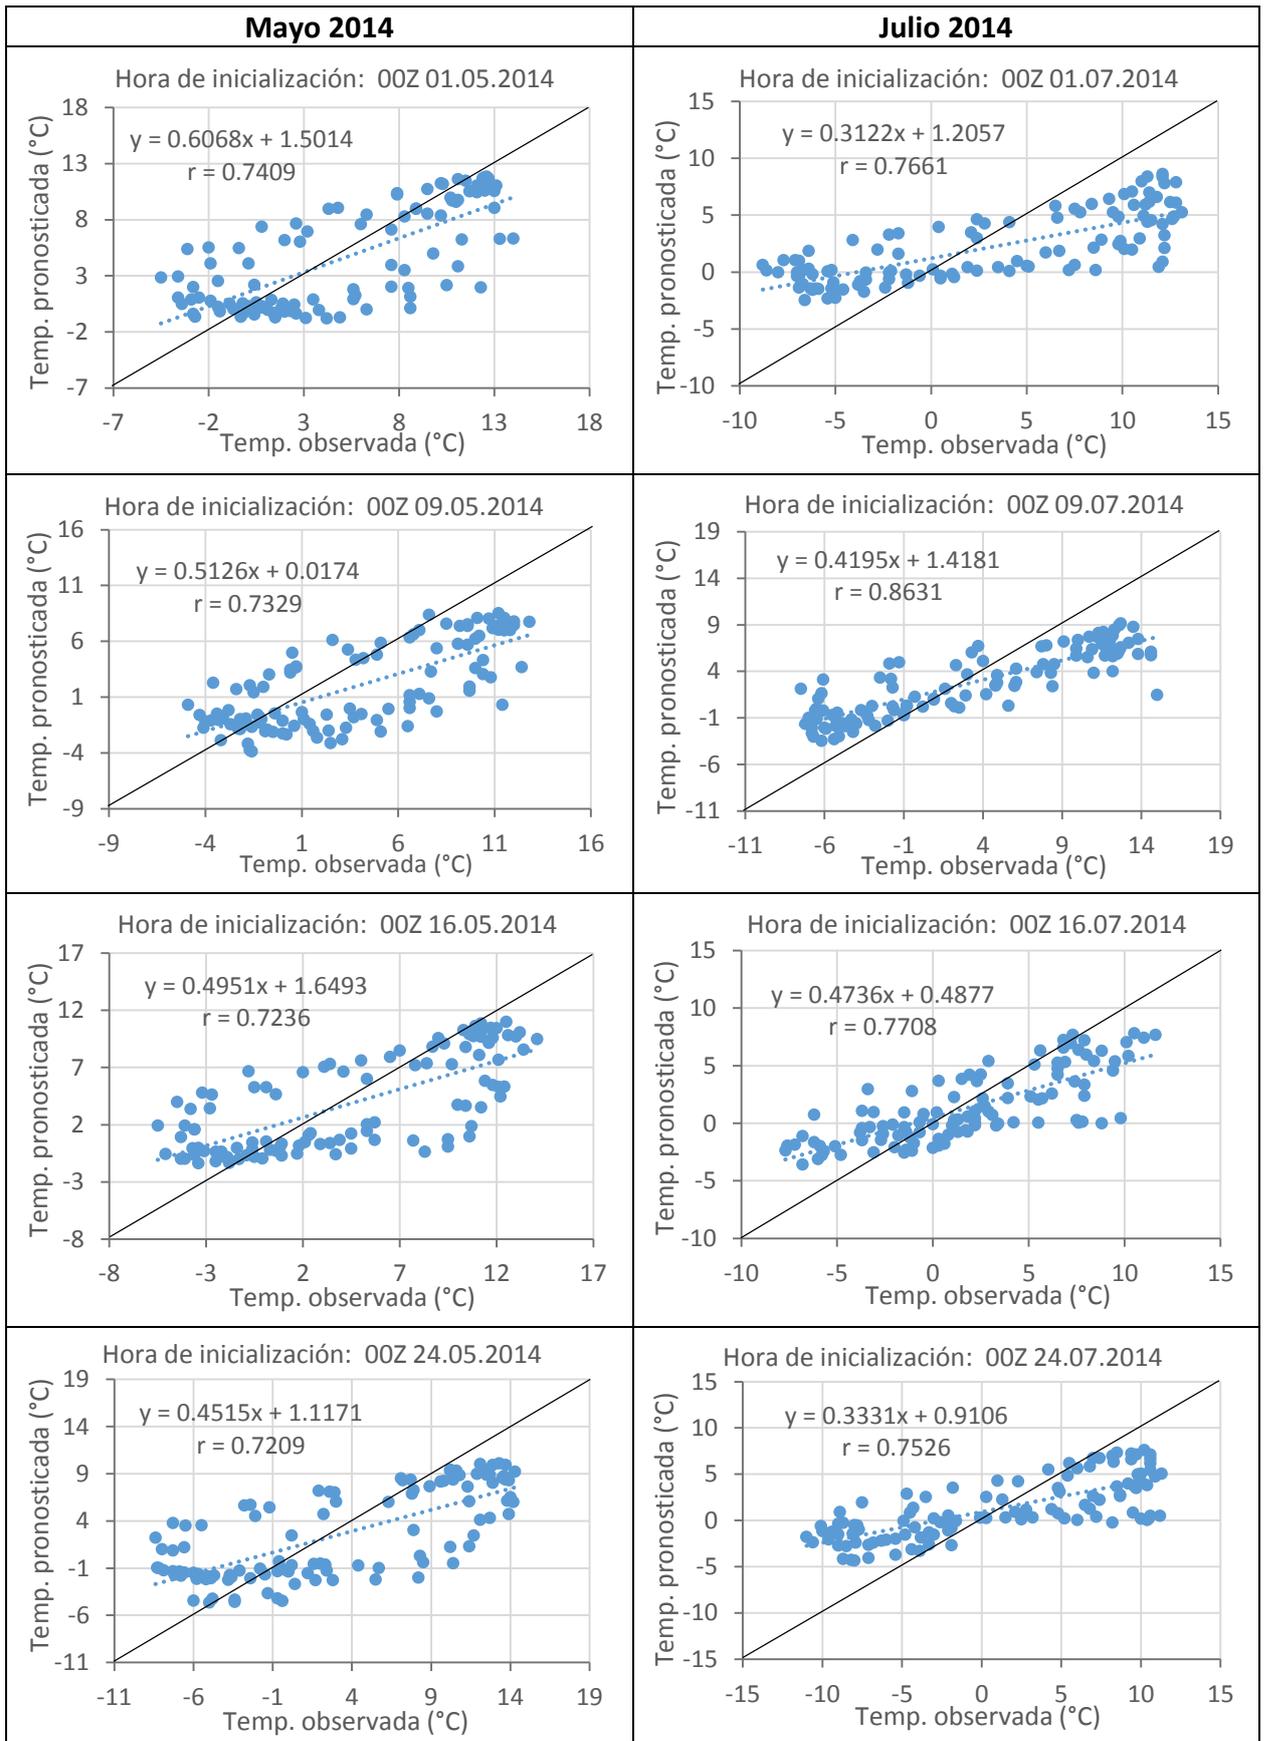


Figura 4.8. Diagramas de dispersión y regresión lineal de los pronósticos – Estación Pampahuta. En cada caso se muestra la hora de inicialización de pronóstico.

4.1.2. ANÁLISIS COMPARANDO LOS CUATRO PUNTOS DE VALIDACIÓN

La tabla 4.5 resume los promedios de las medidas de precisión calculadas en cada punto de validación. Esta tabla muestra los promedios mensuales en mayo y julio, y el promedio de las medidas de estos dos meses.

Tabla 4.5. Promedios mensuales de las medidas de precisión obtenidos en cada punto de validación.

	Periodo	<i>bias</i>	S_o	S_p	a	b	MAE	RMSE	d	r
Chivay	Mayo	-0.73	6.15	4.26	2.49	0.67	2.22	2.58	0.938	0.958
	Julio	-0.58	5.83	4.60	1.77	0.64	1.92	2.37	0.948	0.953
	Promedio	-0.66	5.99	4.43	2.13	0.65	2.07	2.47	0.942	0.955
La Angostura	Mayo	1.08	6.08	5.28	1.71	0.84	1.94	2.41	0.954	0.947
	Julio	0.95	6.54	3.75	2.50	0.52	3.10	3.73	0.862	0.894
	Promedio	1.02	6.31	4.52	2.11	0.68	2.52	3.07	0.908	0.921
Lagunillas	Mayo	-0.21	5.22	5.09	0.44	0.87	1.48	2.64	0.931	0.883
	Julio	-0.78	5.33	3.65	0.74	0.63	1.42	2.59	0.914	0.918
	Promedio	-0.50	5.27	4.37	0.59	0.75	1.45	2.62	0.922	0.900
Pampahuta	Mayo	-0.82	6.09	4.27	1.07	0.52	3.46	4.30	0.815	0.730
	Julio	-0.36	6.71	3.20	1.01	0.38	3.93	4.63	0.767	0.788
	Promedio	-0.59	6.40	3.73	1.04	0.45	3.69	4.47	0.791	0.759

El RMSE y el índice de Willmott por ser medidas representativas al momento de determinar precisión, se han elegido para ser mostradas en las figuras 4.9 y 4.10, en estas figuras se observa cómo varía el RMSE y el índice de Willmott en cada punto de validación a través de los dos meses donde se realizaron los pronósticos. Asimismo, en el caso RMSE's similares se tomarán en cuenta todas las medidas de precisión mostradas en la tabla 4.5 para determinar en qué punto se obtienen mejores pronósticos.

En las figuras 4.9 y 4.10 se puede observar que en mayo la estación La Angostura empieza con el RMSE promedio más bajo (2.41°C) que en las demás estaciones, y esto también se refleja en la figura 4.10, donde ocurre el valor más alto del índice de Willmott (0.954), sin embargo en julio el valor del RMSE en La Angostura aumenta considerablemente hasta 3.73°C y el índice de Willmott baja hasta 0.862. Esta gran variación de RMSE y del índice

de Willmott no se observa en los demás puntos de validación donde se presentan RMSE's e índices de Willmott más estables.

Al promediar los RMSE's en los dos meses, la tabla 4.5 muestra que Chivay y Lagunillas se obtiene resultados parecidos, de hecho podría decirse que existe una precisión similar de los pronósticos en estos dos puntos, sin embargo considerando que la pendiente, el intercepto, la desviación estándar y el MAE (0.59, 0.75, 5.27 y 1.45 respectivamente) logran mejores valores que esos obtenidos en Chivay (2.13, 0.65, 5.99 y 2.07) se puede afirmar que la mayor precisión de los pronósticos ocurre en Lagunillas. Aun cuando el gráfico 4.9 muestre que el RMSE en Chivay es ligeramente menor al de Lagunillas, el análisis de todas las medidas de precisión es el factor determinante para determinar precisión.

Las figuras 4.9 y 4.10 muestran que los mayores valores del RMSE ocurren en Pampahuta y que además el índice de Willmott logra el menor valor, por lo que se deduce que las parametrizaciones elegidas no aseguran pronósticos de calidad en esta estación. Se tendría que estudiar el comportamiento del modelo con otras parametrizaciones (opciones de física) para saber si los errores de pronósticos se podrían reducir en esta estación, los valores de los coeficientes de correlación que se muestran en la tabla 4.4 lo sugieren también así.

En el caso de los coeficientes de correlación, como se puede ver en la tabla 4.5, en todas las estaciones se mantiene un alto grado de correlación a excepción de la estación Pampahuta, donde el grado de correlación es moderado (según la figura 3.5). No obstante, según el análisis de los índices de correlación en todas las ejecuciones del modelo y en todos los puntos de validación, se puede afirmar que la variación conjunta de los pronósticos y las observaciones es representativa (tanto en mayo como en julio) en todos los puntos de validación.

El buen comportamiento del modelo en los puntos de validación Chivay y Lagunillas conlleva a deducir que los pronósticos de temperaturas a dos metros alrededor de estos puntos también serían representativos ¿Qué tan lejos de estos puntos los resultados serían representativos también? Según la configuración del modelo, lo más apropiado sería afirmar que dentro de un radio de 1.5 km los resultados serían similares ya que la resolución espacial del último anidamiento que se estableció en el modelo fue de 3 km; sin embargo debido a que las condiciones meteorológicas de un lugar no varían considerablemente muchos

kilómetros alrededor de ese punto (si se considera una variación espacial a la misma altitud), se puede asumir que si los resultados fueron representativos para un punto geográfico lo más probable es que también sean representativos hasta varios kilómetros alrededor de este punto, mayor incluso a 1.5 kilómetros.

Si bien los resultados de las temperaturas pronosticadas no garantizan que otras variables meteorológicas tales como velocidad de viento, humedad relativa, dirección del viento, etc. tengan el mismo comportamiento en los puntos de validación analizados, los resultados favorables en los cuatro puntos de validación sugieren que el comportamiento de otras variables meteorológicas tendría también un buen comportamiento. De ese modo, se demuestra la utilidad del modelo para otra clase de estudios, tales como estudios climáticos o estudios de calidad el aire.

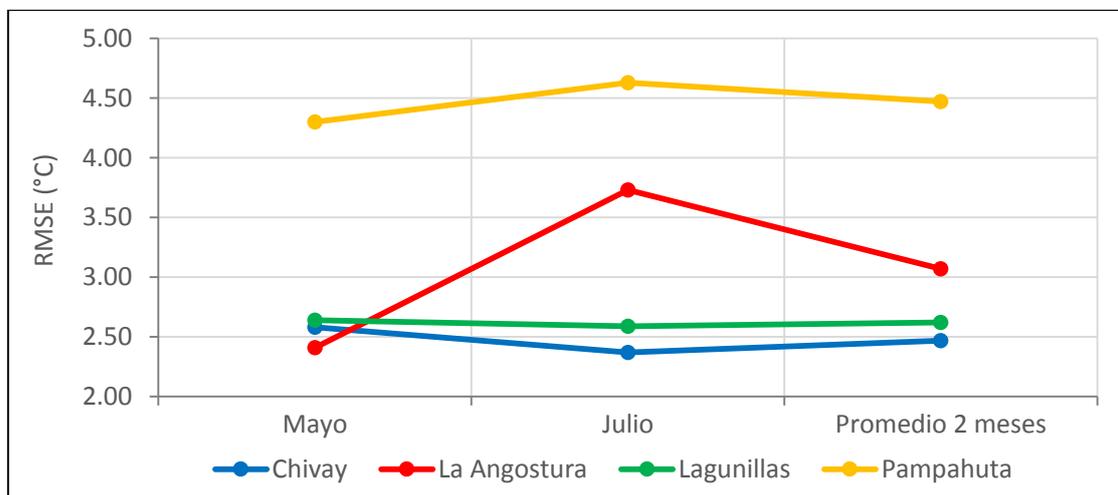


Figura 4.9. Variación del RMSE promedio para cada punto de validación

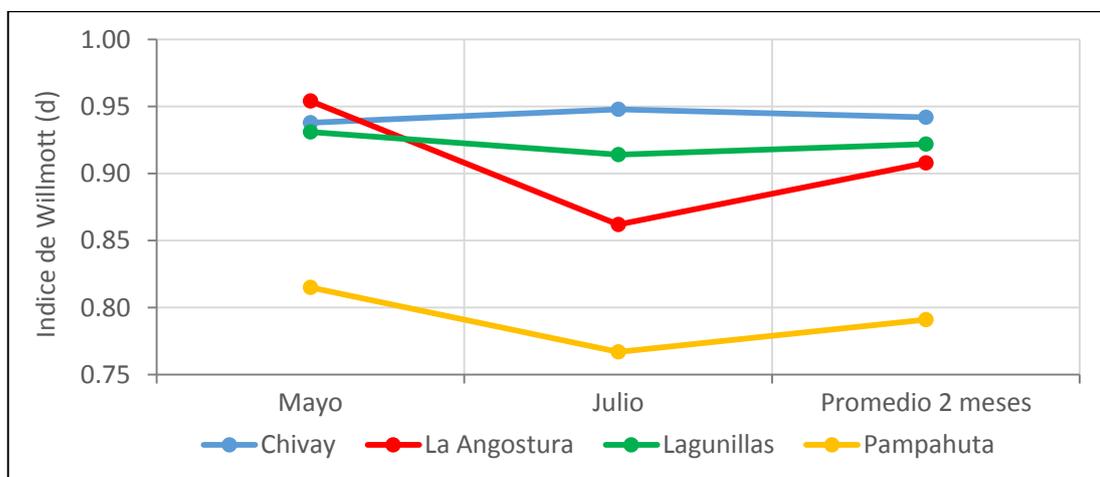


Figura 4.10. Variación del Índice de Willmott promedio para cada punto de validación

4.2. VALIDACIÓN DE LA SIMULACIÓN DE TEMPERATURAS

Al haber utilizado *datos de análisis* como condiciones de frontera, las simulaciones se realizaron como si se estuviera modelando dos eventos atmosféricos ya ocurridos, uno en el mes de mayo y otro en julio del 2014. Por eso, en este caso no se le llamará pronósticos a las temperaturas obtenidas con el modelo, sino solo simulaciones.

4.2.1. ANÁLISIS DE LAS MEDIDAS DE PRECISIÓN EN CADA PUNTO DE VALIDACIÓN

a. PRIMER PUNTO DE VALIDACIÓN – ESTACIÓN CHIVAY

La primera impresión observando la figura 4.11 es que el comportamiento conjunto de simulaciones y observaciones es representativo, sin embargo se tiene que analizar las medidas de precisión calculadas en los dos meses de simulación para cuantificar esa variación y determinar precisión.

Ya en invierno, en julio, no se observa una gran disminución de las temperaturas mínimas en las observaciones, sin embargo el grafico 4.11 muestra que a partir más o menos de la quincena de julio, la amplitud de los errores empieza a aumentar. Este aumento del error se ve reflejado en el valor del RMSE para de julio (3.16°C) sobre 2.60°C obtenido en mayo, sin embargo, aun así el grado la correlación se mantiene fuerte en julio con un valor de 0.930, aunque disminuyó con respecto a mayo (0.955) queriendo decir que a pesar que la amplitud de los errores aumenta a partir de la quincena de julio, los errores se mantienen oscilando aproximadamente a lo largo del error medio de julio. Como los errores MAE y RMSE en mayo (2.22 y 2.60) son significativamente diferentes a los errores de julio (2.63 y 3.16) se puede afirmar que en mayo se logran mejores pronósticos.

Revisando las otras medidas de precisión, la tabla 4.6 muestra que la variabilidad de las observaciones en mayo (6.24°C) es mayor a la de julio (5.99°C). De ese modo, variabilidad de las observaciones no sería la causa por la cual en julio ocurren mayores errores, entonces, ¿a qué se puede deber que las simulaciones generan mayores errores en julio? A partir de la quincena de julio el grafico 4.11 muestra que las temperaturas máximas disminuyen y que

las temperaturas mínimas también los hacen, por lo que esta variación repentina de las temperaturas observadas podría ser una de las causas. Este cambio, con la consolidación del invierno, es lo que genera la mayor amplitud de los errores de pronóstico, lo cual se refleja en el *bias* y RMSE del mes de julio (-1.64°C y 3.16°C respectivamente). Aun así cuando el RMSE es mayor en julio que en mayo, este no es de un valor demasiado alto, lo que sugiere que si bien las simulaciones en julio no son tan precisas, estos podrían ser mejorados haciendo otro estudio para elegir las parametrizaciones adecuadas. Otra causa podría ser la predictibilidad estimada del modelo (2 a 3 días), que con este cambio repentino del comportamiento de las temperaturas observadas a partir de la quincena de julio se acentúa la vulnerabilidad del modelo para realizar pronósticos representativos más allá de una predictibilidad adecuada para modelos de mesoescala.

En mayo es, sin duda, donde las simulaciones son más precisas, a pesar que existe mayor variabilidad de las observaciones en mayo (6.24°C) que en julio (5.99°C). Esta mayor precisión en mayo se logra primero, porque los valores del *bias*, MAE y RMSE (-0.48°C, 2.22°C y 2.60°C respectivamente) son considerablemente menores a esos valores obtenidos en julio (-1.64°C, 2.63°C y 3.16°C), y segundo, porque el índice de Willmott y el coeficiente de correlación logran mejores valores en mayo (0.937 y 0.955) que en julio (0.901 y 0.930).

La calidad de las condiciones iniciales y de frontera queda reflejada en las simulaciones realizadas en este punto de validación ya que el error de pronóstico no se aumentado de forma brusca después de la predictibilidad teórica en modelos de mesoescala (2 a 3 días). Las parametrizaciones elegidas permiten al modelo representar adecuadamente la variación de las temperaturas horarias en este punto de validación, al menos para todo el mes de mayo y los primeros 15 días de julio.

Tabla 4.6. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación Chivay.

	Hora de Inicial.	<i>bias</i>	S_o	S_p	a	b	MAE	RMSE	d	r
Mayo	00Z 01/05/2014	-0.48	6.24	4.19	2.77	0.64	2.22	2.60	0.937	0.955
Julio	00Z 01/07/2014	-1.64	5.99	4.02	1.75	0.62	2.63	3.16	0.901	0.930
Promedio		-1-05	6.12	4.11	2.26	0.63	2.44	2.89	0.919	0.943

¹Se obviaron las primeras 12 horas de simulación en cada ejecución debido el efecto spin-up.

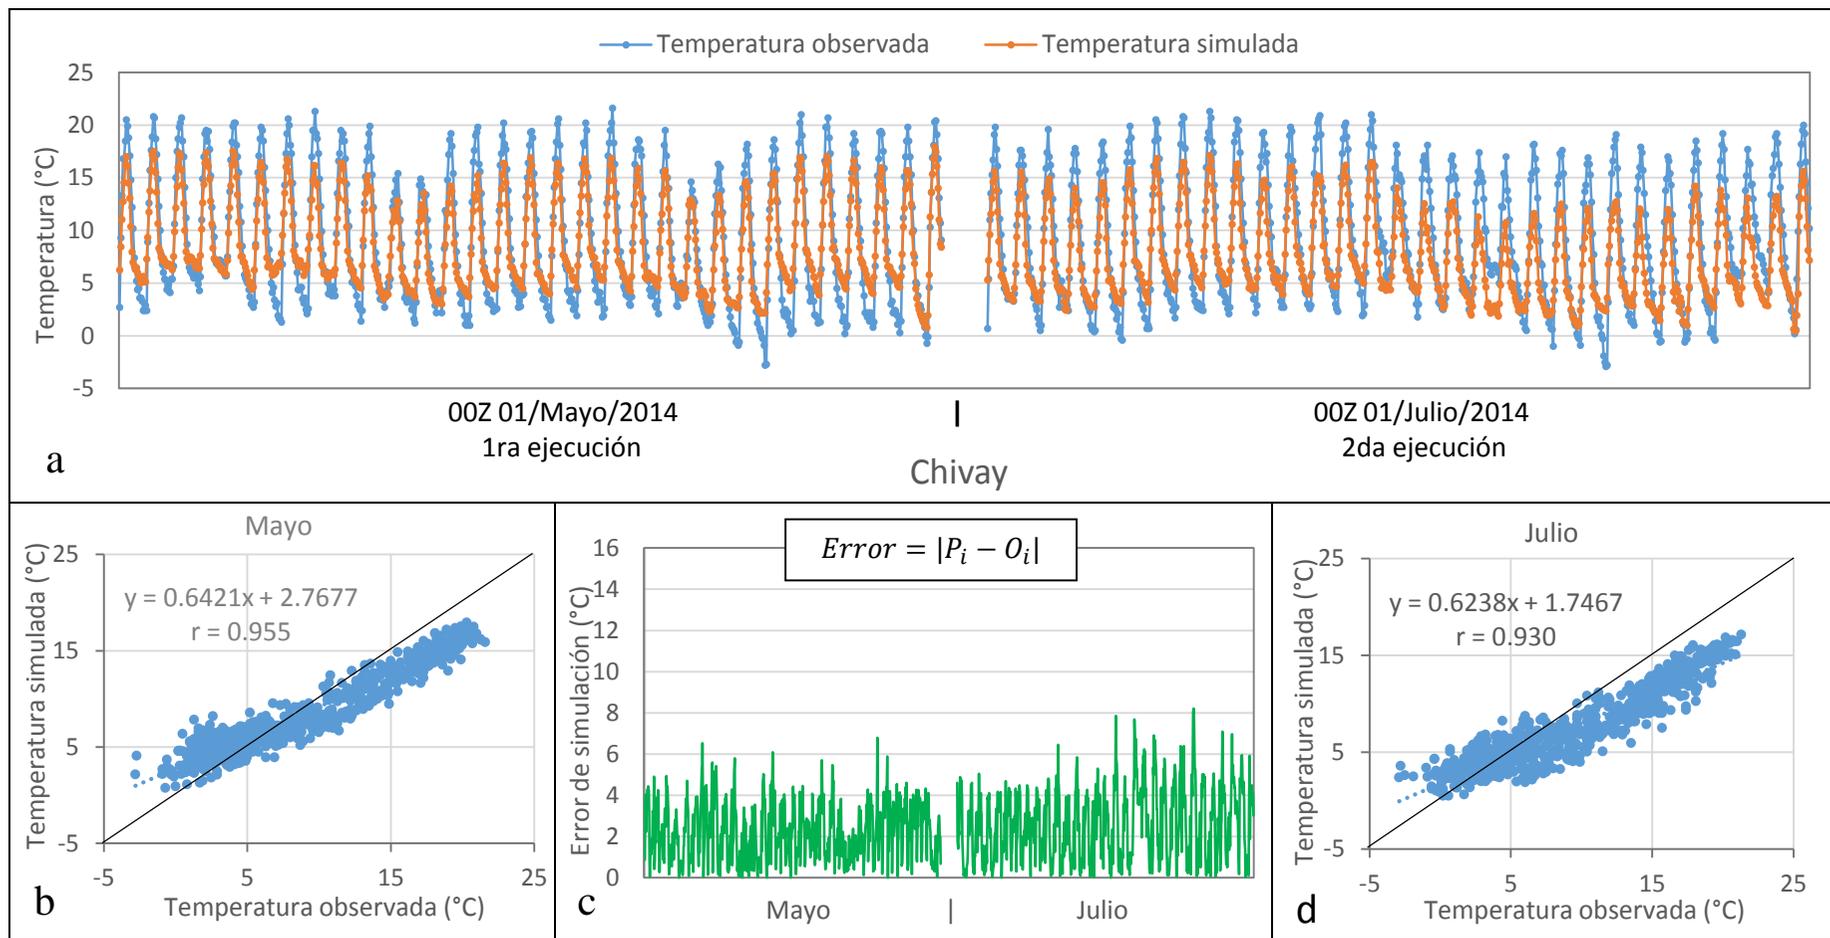


Figura 4.11. Comparación de temperaturas observadas y simuladas en la estación Chivay. (a) Serie temporal horaria de temperaturas a 2 metros de la superficie. Se muestra la serie temporal para cada mes con su respectiva hora de inicio de simulación. Las primeras 12 horas de simulación se obviaron por el efecto *spin-up*. (b) Dispersión y regresión lineal de temperaturas para el mes de mayo. (c) Serie temporal horaria del valor absoluto de los errores de simulación para los dos meses de simulación. (d) Dispersión y regresión lineal de temperaturas para el mes de julio.

b. SEGUNDO PUNTO DE VALIDACIÓN – ESTACIÓN LA ANGOSTURA

La figura 4.12 muestra claramente que en este punto de validación existen con mayor frecuencia temperaturas extremas frías. De hecho que con la llegada del invierno las temperaturas mínimas disminuyen notoriamente en la última tercera parte del mes de mayo, llegando hasta -10.3°C el 25 de mayo. Este comportamiento de las temperaturas mínimas se mantiene en julio, llegando hasta -10.1°C el 24 de julio. Esta disminución de las temperaturas mínimas motiva a pensar que los errores de simulación podrían aumentar, según (Warner, T., 2011, p.308), y eso es justamente lo que ocurre. La llegada del invierno se refleja con el aumento de los errores en julio, cuyo MAE y RMSE llegan a 2.75 y 3.37°C respectivamente, valores mayores a los de mayo (2.13 y 2.72°C). Asimismo, la variabilidad de las observaciones es mejor simulada en mayo (4.82 sobre 6.26) que en julio (4.38 sobre 6.63). El aumento de los errores trae consigo también la disminución de la correlación en el mes de julio, no obstante la correlación en los dos meses sigue siendo de grado alto según la figura 3.5, por lo que la variación conjunta de las simulaciones y las observaciones es significativa. Igualmente el valor del índice de Willmot favorece al mes de mayo (0.938) por sobre el mes de julio (0.902). La ecuación de regresión lineal también es más adecuada en el mes de mayo, ya que la pendiente (0.70) está más cerca del valor 1 que la pendiente de la ecuación de julio (0.59). Algo interesante sucede con los valores del *bias* obtenidos en la tabla 4.7. Para el mes de mayo el *bias* es positivo (0.44) y para el mes de julio el valor es negativo (-0.33), sin embargo el valor absoluto de estos valores no se diferencian considerablemente. Este hecho quiere decir que en mayo predomina, en promedio, la sobreestimación de las observaciones y que en julio, con la disminución de las temperaturas mínimas, predomina la subestimación de las observaciones. Se habría esperado que debido a la disminución de las temperaturas mínimas ocurriera también, en promedio una sobreestimación en el mes de julio, sin embargo, como muestra el gráfico 4.12, las simulaciones también subestiman las temperaturas máximas de forma considerable, predominando sobre la sobreestimación de las mínimas, obteniendo al final un *bias* negativo.

En función del análisis realizado de las medidas de precisión, la predictibilidad del modelo (2-3 días) en este punto de validación parece extenderse para todo el mes de simulación. Si bien es cierto que los errores no son los más favorables, está claro que los *datos de análisis* utilizados como condiciones iniciales y de frontera tienen una gran fiabilidad, ya que a pesar de la predictibilidad conocida en modelos de mesoescala, y de la gran variabilidad

topográfica que existe en la zona, y de la frecuencia de temperaturas extremas frías que ocurren en este punto de validación, las simulaciones alcanzan errores no muy altos en comparación con los errores obtenidos en Pampahuta, que es donde ocurre los más grandes errores de pronóstico y también temperaturas extremas frías considerables.

Tabla 4.7. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación La Angostura.

	Hora de Inicial.	<i>bias</i>	S_o	S_p	a	b	MAE	RMSE	d	r
Mayo	00Z 01/05/2014	0.44	6.26	4.82	1.68	0.70	2.13	2.72	0.938	0.915
Julio	00Z 01/07/2014	-0.33	6.63	4.38	0.80	0.59	2.75	3.37	0.902	0.893
Promedio		0.05	6.45	4.60	1.24	0.62	2.44	3.05	0.920	0.904

¹Se obviaron las primeras 12 horas de simulación en cada ejecución debido al efecto *spin-up*.

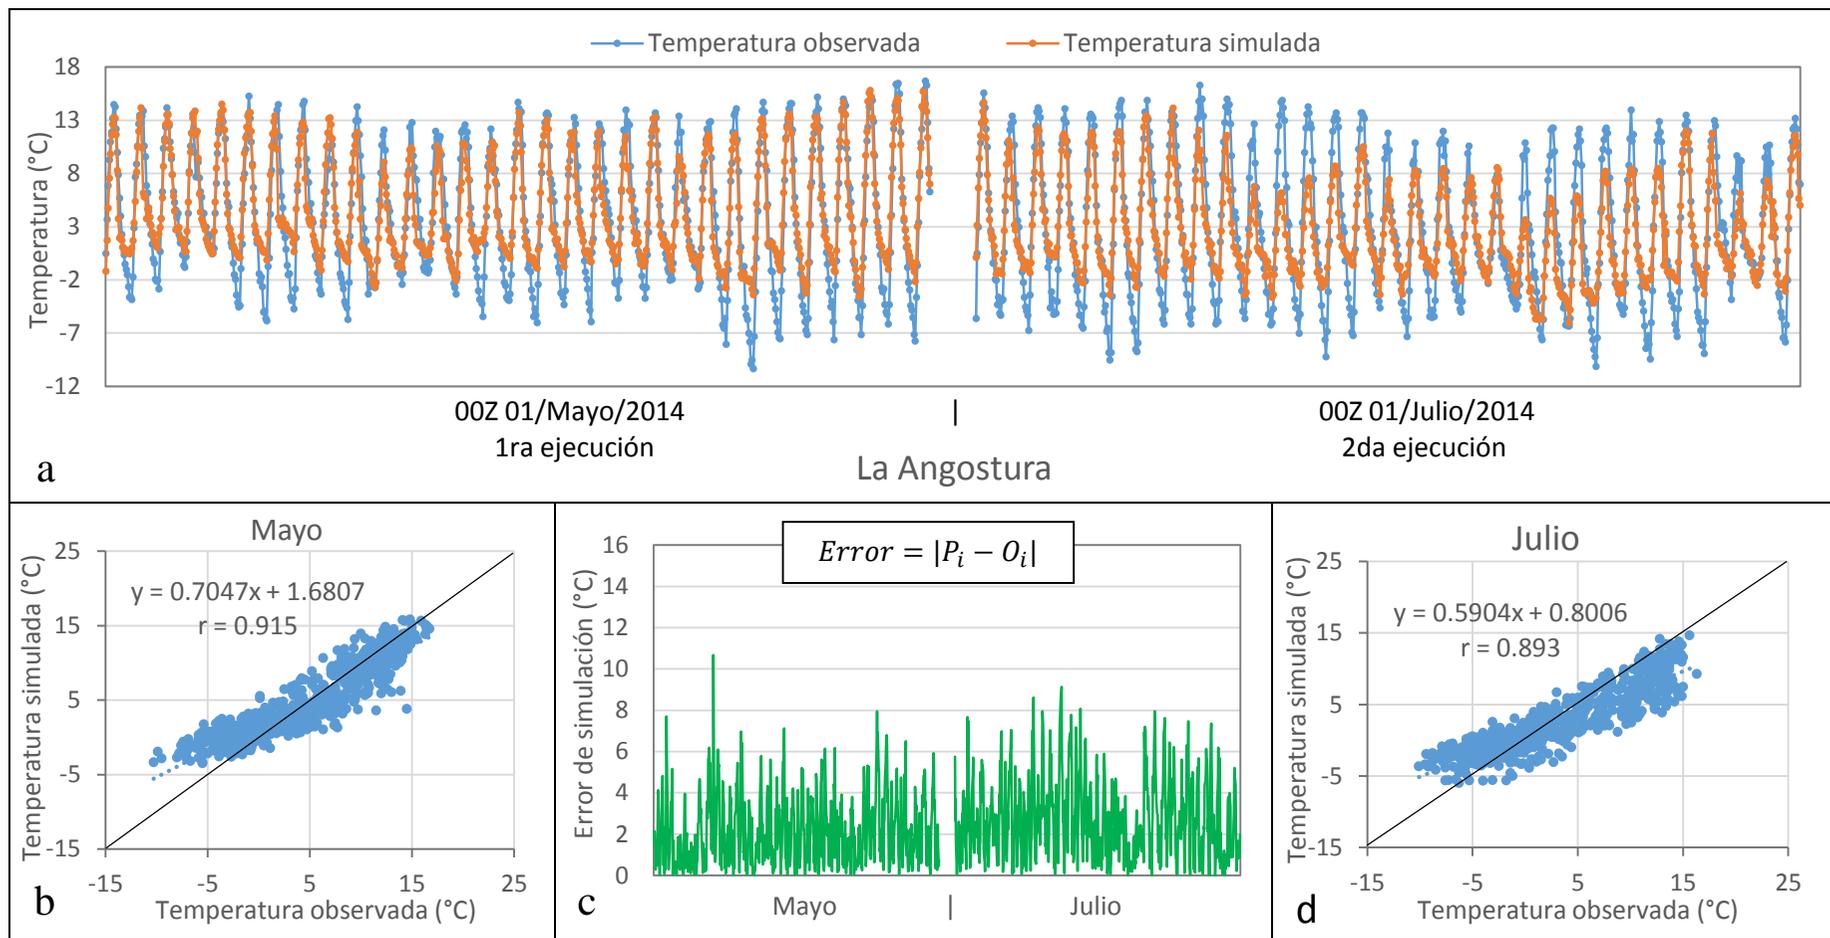


Figura 4.12. Comparación de temperaturas observadas y simuladas en la estación La Angostura. (a) Serie temporal horaria de temperaturas a 2 metros de la superficie. Se muestra la serie temporal para cada mes con su respectiva hora de inicio de simulación. Las primeras 12 horas de simulación se obviaron por el efecto *spin-up*. (b) Dispersión y regresión lineal de temperaturas para el mes de mayo. (c) Serie temporal horaria del valor absoluto de los errores de simulación para los dos meses de simulación. (d) Dispersión y regresión lineal de temperaturas para el mes de julio.

c. TERCER PUNTO DE VALIDACIÓN – ESTACIÓN LAGUNILLAS

Observando el gráfico 4.13, hasta el 26 de mayo tanto las temperaturas mínimas como máximas, en promedio, estaban siendo bien simuladas por el modelo a pesar de la predictibilidad teórica en modelos de mesoescala (2 a 3 días). El valor negativo del *bias* en mayo (-0.7°C) hace pensar que hasta antes del 26 de mayo los mayores errores se debían a la subestimación de las temperaturas máximas en el día, y que a partir de esta fecha considerables errores empiezan a producirse debido a la sobrestimación de las temperaturas mínimas. Sin embargo, como en la mayor parte del mes de mayo existen mayores subestimaciones que sobreestimaciones, el *bias* en este mes es negativo (-0.7°C). Si bien en julio el *bias* también es negativo (-0.65), la ocurrencia de temperaturas extremas frías en este mes es mayor. Este hecho haría pensar que existiría mayor sobreestimación de estas temperaturas y que el *bias* sería positivo, sin embargo el *bias* es negativo, pero de mayor valor que en mayo, lo que indica que la influencia de las temperaturas mínimas en julio hace que el *bias* sea menos negativo en julio, y por lo tanto ligeramente menos preciso.

La disminución de las temperaturas mínimas a partir del 26 de mayo trae consigo también un aumento en los errores de simulación MAE y RMSE, esto se confirma en el mes de julio donde el RMSE logra un valor de 2.77°C sobre 2.52°C obtenido en mayo, tal y como lo muestra la tabla 4.8. Si bien los valores de los errores MAE y RMSE en Lagunillas no son menores a los de La Angostura, la correlación no llega a ser tan significativa como en Chivay o La Angostura. El coeficiente de correlación es menor a 0.9 tanto en mayo (0.892) como en julio (0.872), sin embargo estos valores del coeficiente de correlación, según la figura 3.5, siguen siendo valores que representan altos grados de correspondencia. Esto significa que el grado de dispersión entre simulaciones y observaciones es mayor en Lagunillas, ¿por qué en Lagunillas el grado de correlación no es tan significativo como en Chivay o La Angostura? La razón puede deberse a la mayor presencia de valores atípicos en la correspondencia entre simulaciones y observaciones reflejado en los errores de pronóstico. Estos valores atípicos se presencian en el gráfico 4.12c, donde la ocurrencia de valores atípicos es mayor a la de Chivay o La Angostura. Aun así, los valores del coeficiente de correlación y de los errores de simulación en los dos meses (mayo y julio) permiten concluir que el comportamiento de las simulaciones es significativo en Lagunillas. Además también se debe mencionar que la variabilidad de las observaciones en los dos meses se simula bien como se puede apreciar en

la tabla 4.8 donde la desviación estándar en mayo (4.91 sobre 5.35°C) es ligeramente mejor simulada que en julio (4.63 sobre 5.50°C).

El índice de Willmott permanece por arriba de 0.9 en los dos meses de simulación, aunque en mayo (0.892) este índice es mayor que en julio (0.872), confirmando que en mayo las simulaciones en general son mejores. Adicionalmente, viendo la figura 4.13 las ecuaciones de regresión lineal alientan a pensar que en este punto de validación las simulaciones podrían llegar a ser aún más favorables, ya que los interceptos (0.22 en mayo y 0.35 en julio) y las pendientes (0.82 en mayo y 0.73 en julio) de estas ecuaciones están muy cerca de los valores ideales (0 y 1 respectivamente).

Considerando el análisis de todas las medidas de precisión hasta ahora en este punto de validación se han obtenido las simulaciones con mayor grado de precisión que en los anteriores puntos de validación ¿Por qué en este punto se obtienen simulaciones con el mayor grado de precisión a los demás puntos de validación? El análisis de las medidas de precisión obtenidas en Lagunillas es el factor determinante para afirmar que en Lagunillas ocurren las mejores simulaciones de temperaturas a 2 metros de la superficie. Asimismo, este hecho confirma que las opciones de física elegidas en el modelo representan adecuadamente las condiciones atmosféricas predominantes en los alrededores cercanos a Lagunillas. La calidad de los datos de análisis que se utilizaron como condiciones iniciales y de frontera es otro factor importante para obtener simulaciones y pronósticos de calidad, más aun cuando la predictibilidad de modelos de mesoescala tiende a ser de 2 a 3 días.

Tabla 4.8. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación Lagunillas.

	Hora de Inicio	<i>bias</i>	S_o	S_p	<i>a</i>	<i>b</i>	MAE	RMSE	<i>d</i>	<i>r</i>
Mayo	00Z 01/05/2014	-0.70	5.35	4.91	0.22	0.82	1.95	2.52	0.937	0.892
Julio	00Z 01/07/2014	-0.65	5.50	4.63	0.35	0.73	2.16	2.77	0.922	0.872
Promedio		-0.68	5.43	4.77	0.29	0.78	2.06	2.65	0.930	0.882

¹Se obviaron las primeras 12 horas de simulación en cada ejecución debido al efecto *spin-up*.

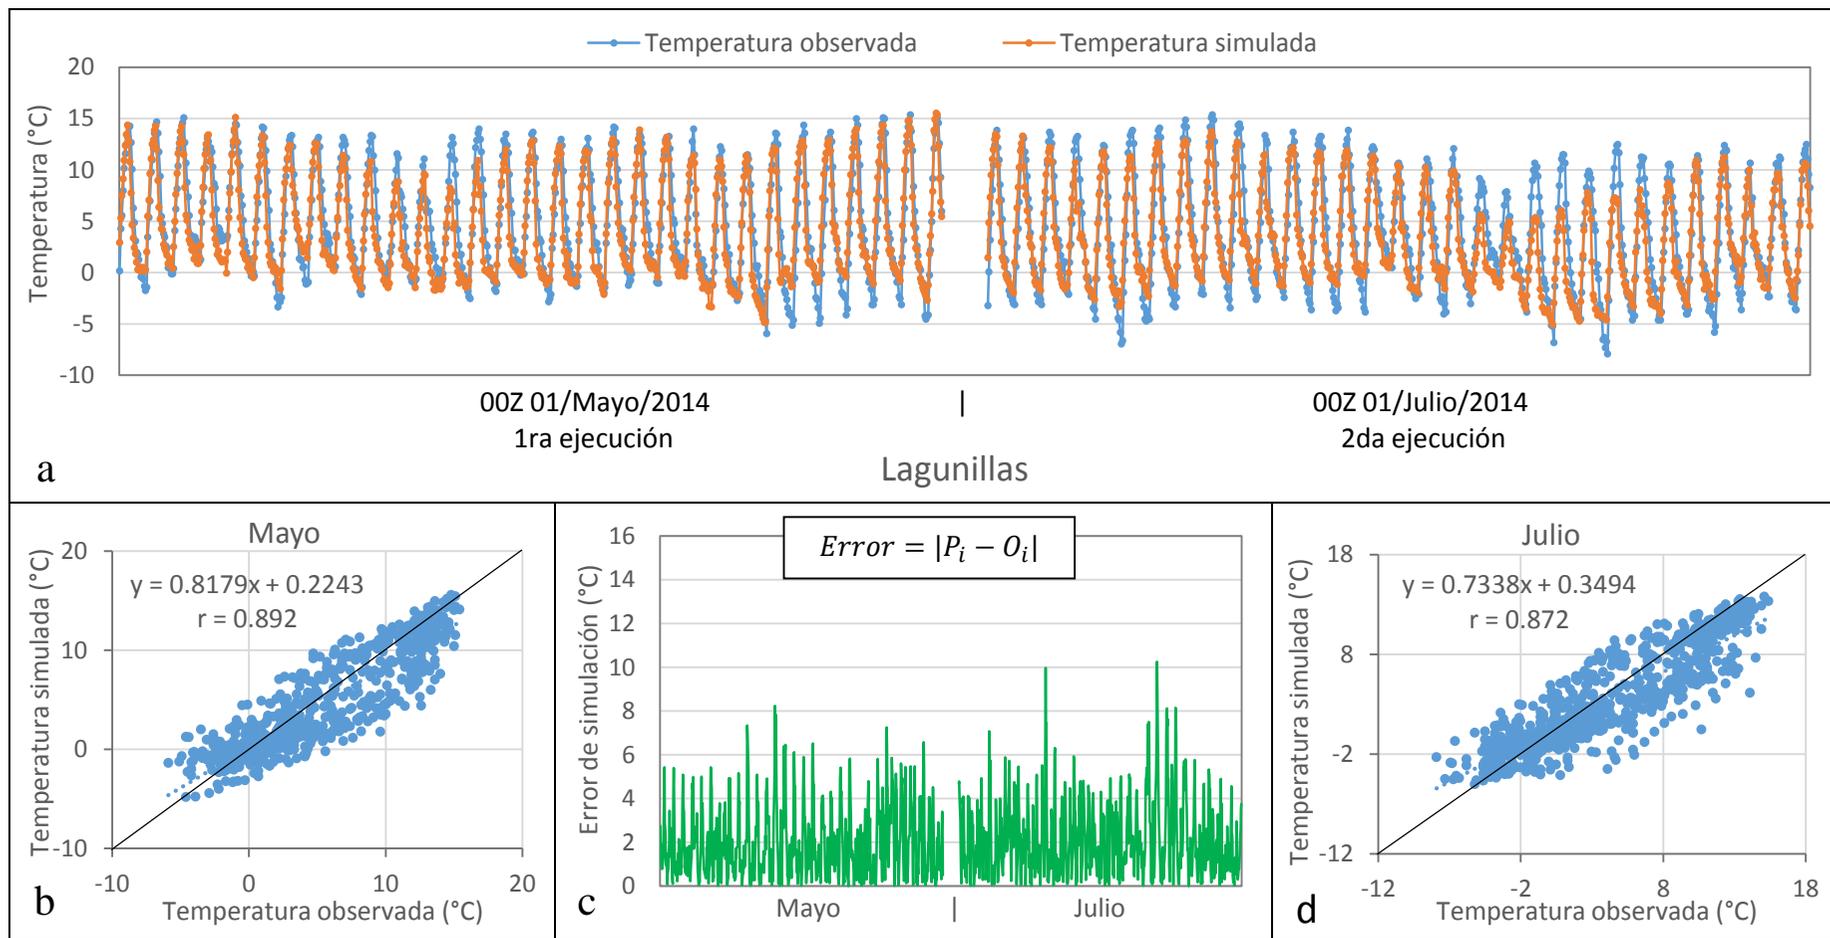


Figura 4.13. Comparación de temperaturas observadas y simuladas en la estación Lagunillas. (a) Serie temporal horaria de temperaturas a 2 metros de la superficie. Se muestra la serie temporal para cada mes con su respectiva hora de inicio de simulación. Las primeras 12 horas de simulación se obviaron por el efecto *spin-up*. (b) Dispersión y regresión lineal de temperaturas para el mes de mayo. (c) Serie temporal horaria del valor absoluto de los errores de simulación para los dos meses de simulación. (d) Dispersión y regresión lineal de temperaturas para el mes de julio.

d. CUARTO PUNTO DE VALIDACIÓN – ESTACIÓN PAMPAHUTA

Observando la figura 4.14c se puede ver que en Pampahuta existe una gran amplitud de los errores, llegando en algunos casos hasta 14°C. Sin lugar a duda los errores MAE y RMSE tanto en mayo (3.90 y 4.78°C) como en julio (4.35 y 5.27°C) son altos en comparación con los anteriores puntos de validación, además, viendo la tabla 4.9, el *bias* y la desviación estándar de las simulaciones (S_p) no logran estimar adecuadamente la media y la desviación estándar de las observaciones. Si se tuviera que elegir un mes en donde se logra mejores simulaciones sería mayo, primero porque los errores MAE y RMSE son considerablemente menores a los de julio, y en segundo lugar porque el índice de Willmott y la correlación logran mejores valores en mayo (0.770 y 0.693 respectivamente) que en julio (0.748 y 0.671).

En este punto de validación la variabilidad de las temperaturas reales es considerable y eso se refleja en los valores de la desviación estándar en mayo y en julio (6.14 y 6.79°C respectivamente). Era de esperarse que en julio la variabilidad de las temperaturas aumente, ya que con la llegada del invierno la figura 4.14 muestra que las temperaturas mínimas empiezan a disminuir y que las temperaturas máximas mantienen un comportamiento similar a las temperaturas máximas de mayo, aunque a partir del 11 de julio empiezan a disminuir gradualmente. La disminución de las temperaturas mínimas en julio también se refleja en los valores del intercepto y pendiente de la ecuación de regresión lineal obtenidos en julio (0.21 y 0.45 respectivamente), que son valores menos favorables a esos obtenidos en mayo (0.21 y 0.45), lo que indica que la mayor frecuencia de temperaturas extremas frías, que según Warner, T., 2011, p.308) son las temperaturas más difíciles de simular, puede ser la causa del aumento de los errores MAE y RMSE en julio.

En la figura 4.14a se puede notar que en Pampahuta, a finales de mayo, las temperaturas mínimas ya empezaban a disminuir desde más o menos el 25 de mayo, ocurriendo en estas fechas la primeras heladas otoñales y que son las que ocasionan, en muchos casos, los daños más perjudiciales (Atlas de heladas en el Perú. 2010, p.13), ya que generalmente ocurren de forma inesperada. En ese sentido, si bien los coeficientes de correlación mostrados en las figuras 4.14b y 4.14d indican que la variación conjunta horaria de las temperaturas en Pampahuta es de grado medio, el modelo no logra simular correctamente las temperaturas extremas frías que ocurren con la llegada del invierno según lo muestra los altos valores de

los errores de simulación MAE y RMSE comparado con los errores obtenidos en los anteriores puntos de validación.

Asimismo el índice de Willmott logra valores menores a 0.8 (0.770 en mayo y 0.748 en julio). Estos valores del índice de Willmott señalan baja precisión pero moderada correlación entre los datos. Tener en cuenta que el índice de Willmott varía entre 0 y 1, sin embargo la tabla 4.9 muestra valores aparentemente altos de 0.770 y 0.748, sin embargo el análisis de las demás medidas es lo que determina que exista baja precisión de las simulaciones en Pampahuta. El índice de Willmott, al parecer, es resistente a grandes cambios en sus valores, sobre todo cuando existen considerables errores como en Pampahuta.

Teniendo en cuenta el análisis de las medidas de precisión mostradas en la tabla 4.9, se concluye que en Pampahuta ocurren los mayores errores de simulación y por lo tanto las simulaciones de menor calidad que en los demás puntos de validación. Si bien, a pesar que la precisión de las simulaciones no es significativa, la variación conjunta entre las observaciones y simulaciones reflejadas en los valores del coeficiente de correlación obtenido en mayo (0.693) y julio (0.671) tienen un grado de significancia medio, según la figura 3.5. Esta última idea motiva a pensar que modificando las parametrizaciones en el modelo la precisión de las simulaciones podría mejorar en este punto.

Tabla 4.9. Resumen de las medidas de precisión en cada ejecución del modelo (o en cada simulación). Estación Pampahuta.

	Hora de Inicio	<i>bias</i>	S_o	S_p	a	b	MAE	RMSE	d	r
Mayo	00Z 01/05/2014	-1.79	6.14	4.01	0.21	0.45	3.90	4.78	0.770	0.693
Julio	00Z 01/07/2014	-1.48	6.79	3.99	0.35	0.39	4.35	5.27	0.748	0.671
Promedio		-1.64	6.47	4.00	0.28	0.42	4.13	5.03	0.759	0.682

¹Se obviaron las primeras 12 horas de simulación en cada ejecución debido al efecto *spin-up*.

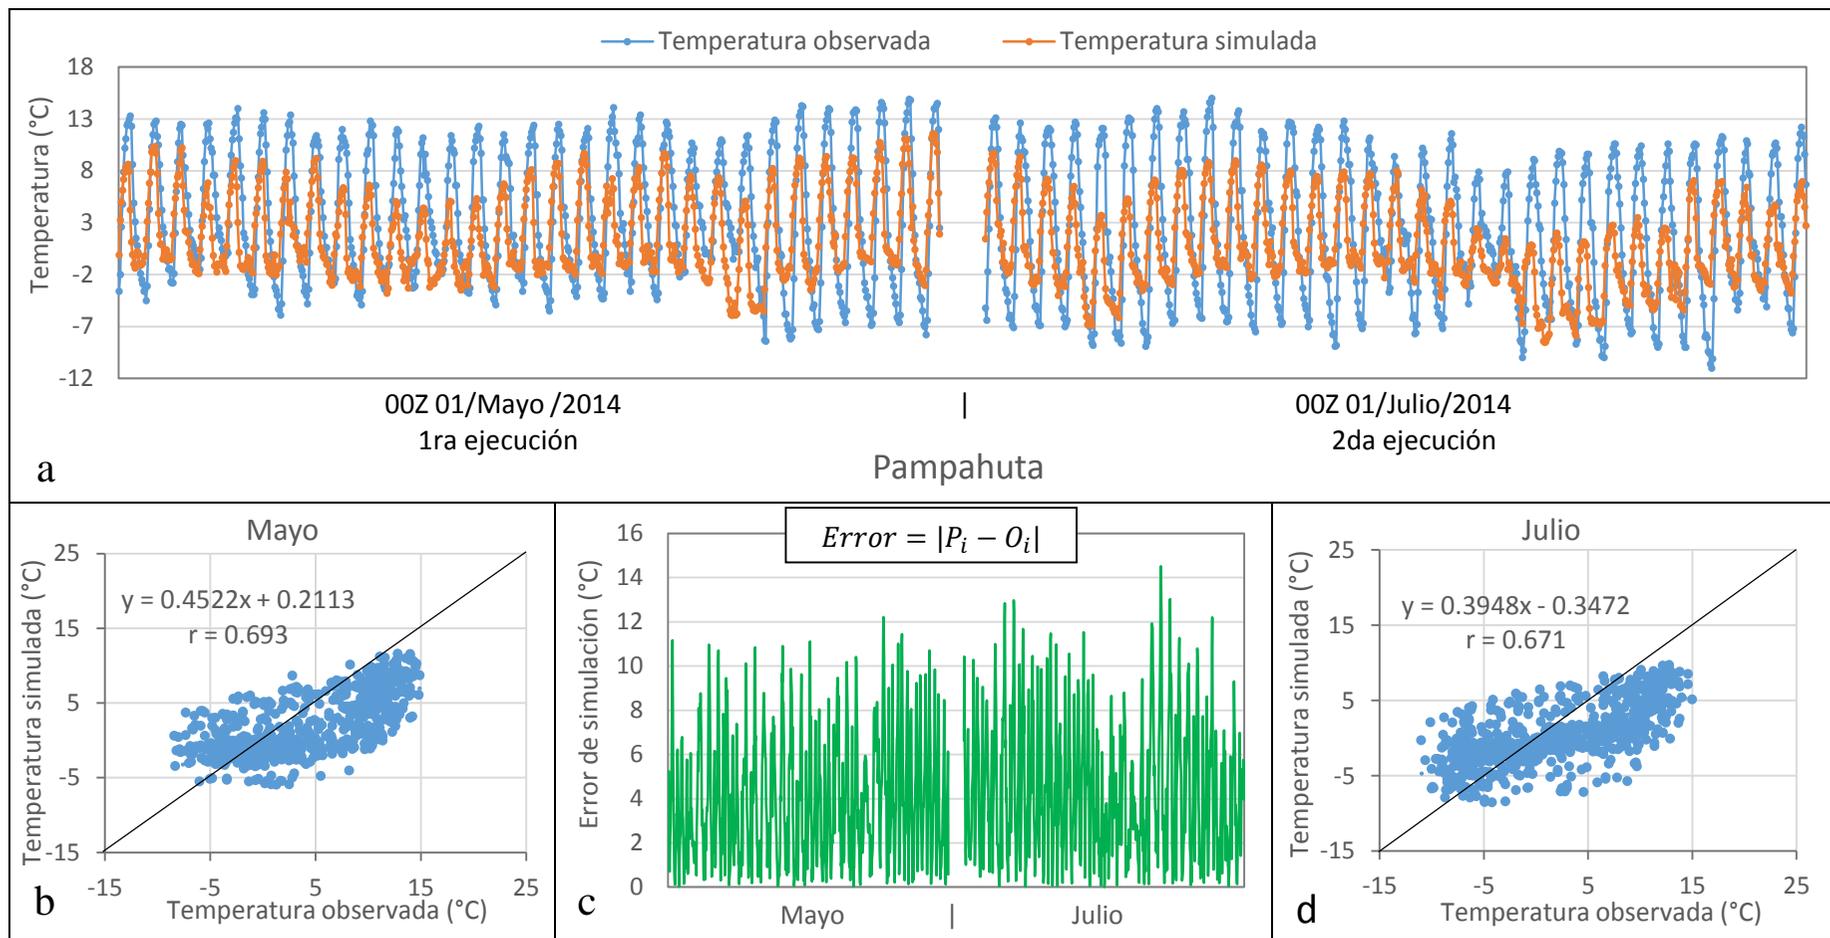


Figura 4.14. Comparación de temperaturas observadas y simuladas en la estación Pampahuta. (a) Serie temporal horaria de temperaturas a 2 metros de la superficie. Se muestra la serie temporal para cada mes con su respectiva hora de inicio de simulación. Las primeras 12 horas de simulación se obviaron por el efecto *spin-up*. (b) Dispersión y regresión lineal de temperaturas para el mes de mayo. (c) Serie temporal horaria del valor absoluto de los errores de simulación para los dos meses de simulación. (d) Dispersión y regresión lineal de temperaturas para el mes de julio.

4.2.2. ANÁLISIS COMPARANDO LOS CUATRO PUNTOS DE VALIDACIÓN

El error RMSE en la figura 4.15 muestra que se logran menos errores de simulación en Lagunillas, ya que tanto en mayo (2.52°C) como en julio (2.77) el RMSE es menor a comparación de los demás puntos de validación. Si bien el *bias* en Lagunillas (-0.68°C) no es el mejor valor de todos los puntos de validación, el valor promedio que se alcanza en este punto es menor al *bias* de Chivay (-1.05°C) y Pampahuta (-1.64°C). En el caso de la correlación, la mejor correlación de todas las estaciones ocurre en Chivay (0.943), sin embargo en Lagunillas, donde ocurren los menores errores, se obtiene un valor significativo (0.882): un claro ejemplo que los más altos grados de correlación no necesariamente significan los menores errores de simulación. La tabla 4.10 muestra también que la variabilidad de las observaciones (S_o) es mejor simulada en Lagunillas (4.77 sobre 5.43), ya que la diferencia de las desviaciones estándar ($S_o - S_p$) es menor en este punto que en los demás puntos. El intercepto (a) y la pendiente (b) de la ecuación de regresión lineal en Lagunillas (0.29 y 0.78 respectivamente) también son valores más favorables en este punto que en los demás puntos de validación.

Observando el gráfico 4.19 se puede notar que el RMSE promedio en Chivay (2.89°C) no es tan bajo como en Lagunillas (2.65°C), sin embargo en estos dos puntos es donde ocurren los menores RSME's que en los demás puntos. Asimismo, ya que en Chivay y Lagunillas los coeficientes de correlación son de grado alto en todos los meses, y que el índice de Willmott logran los mayores valores, se puede afirmar que en Lagunillas y Chivay ocurren las simulaciones de mayor precisión. De ese modo, el análisis de todas las medidas de precisión es lo que conlleva a determinar que en Chivay y Lagunillas se producen las mejores simulaciones de temperaturas a dos metros de la superficie, en comparación con los demás puntos de validación.

En La Angostura los errores MAE y RMSE no son tan altos como los valores obtenidos en Pampahuta. De hecho, en La Angostura existe un RMSE promedio de 3.05°C y una correlación fuerte de 0.904 , menores al RMSE e índice de correlación de Pampahuta, lo que motiva a pensar que con otra elección de las parametrizaciones en el modelo los errores de simulación en La Angostura podrían ser menores. Aunque en Pampahuta el RMSE promedio es mayor que en los demás puntos de validación, los coeficientes de correlación y los valores

del índice de Willmott motivan a pensar que los errores simulación en este punto podrían también ser reducidos con otras parametrizaciones elegidas.

Tabla 4.10. Resumen de las medidas de precisión obtenidas en los cuatro puntos de validación

	Periodo	<i>bias</i>	S_o	S_p	a	b	MAE	RMSE	d	r
Chivay	Mayo	-0.48	6.24	4.19	2.77	0.64	2.22	2.60	0.937	0.955
	Julio	-1.64	5.99	4.02	1.75	0.62	2.63	3.16	0.901	0.930
	Promedio	-1.05	6.12	4.11	2.26	0.63	2.44	2.89	0.919	0.943
La Angostura	Mayo	0.44	6.26	4.82	1.68	0.70	2.13	2.72	0.938	0.915
	Julio	-0.33	6.63	4.38	0.80	0.59	2.75	3.37	0.902	0.893
	Promedio	0.05	6.45	4.60	1.24	0.62	2.44	3.05	0.920	0.904
Lagunillas	Mayo	-0.70	5.35	4.91	0.22	0.82	1.95	2.52	0.937	0.892
	Julio	-0.65	5.50	4.63	0.35	0.73	2.16	2.77	0.922	0.872
	Promedio	-0.68	5.43	4.77	0.29	0.78	2.06	2.65	0.930	0.882
Pampahuta	Mayo	-1.79	6.14	4.01	0.21	0.45	3.90	4.78	0.770	0.693
	Julio	-1.48	6.79	3.99	0.35	0.39	4.35	5.27	0.748	0.671
	Promedio	-1.64	6.47	4.00	0.28	0.42	4.13	5.03	0.759	0.682

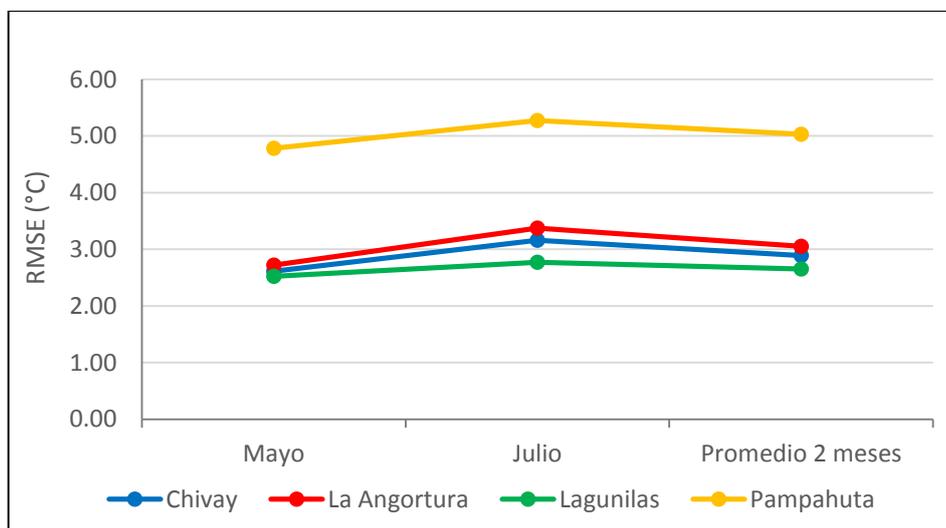


Figura 4.15. Variación del RMSE promedio en los cuatro puntos de validación

Algo en común que sucede en todos los puntos de validación es que el error de simulación no se incrementa desmesuradamente después de los 2 a 3 días de simulación, que es la predictibilidad estimada en modelos de mesoescala, ¿cuál sería la razón que los errores de

simulación en todos los puntos de validación no aumenten desmedidamente después de 2 a 3 días de simulación? Lo lógico que hubiese ocurrido es que los errores aumentaran apreciablemente más allá de 2 a 3 días simulación, sin embargo como se ingresaron *datos de análisis* como condiciones de frontera, el mayor grado de precisión de estos datos podría ser la causa de que los errores no se incrementen considerablemente más allá de esa predictibilidad estimada en modelos de mesoescala, ya que según (Kalnay, E. 2003) la precisión de las simulaciones depende mucho de la precisión de las condiciones iniciales y de frontera. Los *datos de análisis* tienen la característica de poseer mayor precisión que los *datos de pronóstico* por ser datos sofisticadamente procesados provenientes de observaciones reales medidas *in situ*.

Si bien en el presente estudio se ha analizado el comportamiento del modelo solo para dos meses del año (mayo para otoño y julio para invierno), los resultados del presente estudio motivan a pensar se podrían obtener iguales o mejores resultados para las demás estaciones del año, ya que según (Warner, T. 2011, p.308), los errores de pronóstico tienden a ser mayores en los meses fríos del año, de modo que en verano y primavera se esperarían menores errores y por lo tanto mejores pronósticos. Sin embargo, se tienen que hacer los estudios correspondientes para comprobar esas suposiciones.

V. CONCLUSIONES

1. Al hacer pronósticos hasta con 120 horas de anticipación, el análisis estadístico de las medidas de precisión realizado en los cuatro puntos de validación muestran que el modelo logra reproducir significativamente el comportamiento horario de las temperaturas a dos metros de la superficie en los puntos de validación Chivay y Lagunillas. Por lo tanto se justifica la validez del modelo WRF para el análisis de esta variable meteorológica hasta varios kilómetros alrededor de estos puntos.
2. Al hacer simulaciones de temperaturas horarias para un periodo de un mes, el análisis estadístico de las medidas de precisión realizado en los cuatro puntos de validación muestran que el modelo logra reproducir significativamente el comportamiento horario de las temperaturas a dos metros de la superficie solo en dos puntos de validación: Chivay y Lagunillas. Aunque en los otros dos puntos (La Angostura y Pampahuta) no se obtiene una alta precisión en las simulaciones, el grado de correlación entre simulaciones y valores reales es altamente significativo.
3. Se justifica el uso de los datos utilizados como condiciones iniciales y de frontera en todos los puntos de validación evaluados, ya que las simulaciones de temperaturas a dos metros de la superficie obtenidas en estos puntos son estadísticamente representativas en zonas altoandinas de Puno y Arequipa.
4. Según el análisis estadístico de las medidas de precisión en los cuatro puntos de validación, el error de pronóstico tiende a aumentar en la estación de invierno, por lo tanto el modelo reproduce mejor el patrón de las temperaturas en otoño que en invierno.
5. Según el análisis estadístico de las medidas de precisión realizado en los cuatro puntos de validación, el modelo WRF resuelve significativamente los procesos físicos de la atmósfera que predominan en zonas altoandinas de Puno y Arequipa, lo que justifica la utilidad del modelo para obtener valores de variables meteorológicas en estas zonas donde no se cuente con estaciones meteorológicas para la medición de estas variables.

VI. RECOMENDACIONES

1. Si se pretendiera establecer un pronóstico operacional en la zona se tendrían que realizar adicionales estudios no solo para encontrar las parametrizaciones adecuadas que representen mejor las condiciones meteorológicas predominantes en la zona, sino también para usar una adecuada técnica de validación. Según (Dudhia, J, 2014) un error de pronóstico promedio menor a 1°C sería el adecuado si se pretende utilizar el modelo para fines operacionales.
2. En (Warner, T. T., 2011, p.3) se recomienda que antes de operar un modelo de predicción numérica se debe conocer primero las condiciones meteorológicas predominantes de la zona de estudio, se debe saber qué tipo de sistema de modelamiento tiene el modelo a utilizarse, y más aún, se debe tener claro los conceptos teóricos en predicción numérica del tiempo. Mientras más se obvien estas recomendaciones más se demorará en culminar el estudio.
3. Si bien el RMSE es la medida de precisión más usada, el RMSE es una medida que puede traer consigo interpretaciones confusas. Un ejemplo claro sucede en el punto de validación Lagunillas, donde no necesariamente un RMSE menor significa una mejor correlación entre los pronósticos y las observaciones. Si bien el RMSE es una buena medida de precisión, siempre se recomienda hacer el análisis de esta medida conjuntamente con otras medidas de precisión (Willmott, C. J., 1982).
4. En el presente estudio se hubieran podido obtener malos resultados con grandes errores y bajas correlaciones entre los valores simulados y las observaciones, sin embargo el análisis de los resultados en los cuatro puntos de validación demuestra que existe un comportamiento estadísticamente significativo del modelo en zonas altoandinas de Puno y Arequipa. Estos resultados motivan a creer que los pronósticos podrían llegar a ser aún más representativos si se realizara estudios adicionales.

VII. REFERENCIAS BIBLIOGRÁFICAS

1. BOWERMAN, BRUCE L.; OCONNELL, RICHARD T.; KOEHLER, ANNE B. 2007. Pronósticos, Series de Tiempo y Regresión. Cuarta edición. Cengage Learning Ediciones. México.
2. BRAMER, MAX. 2007. Principles of Data Mining. Primera Edición. Springer-Verlag Ediciones. Londres, Reino Unido.
3. CARVALHO, DAVID; ROCHA, ALFREDO; GÓMEZ GESTEIRA, MONCHO; SANTOS, CARLOS. 2012. A sensitivity study of the WRF model in wind simulation for an area of high wind energy. Environmental Modelling & Software 33(2012) 23-34.
4. CENEPRED, PRESIDENCIA DEL CONSEJO DE MINISTROS et al. 2012. Plan Multisectorial ante Heladas y Friajes. Perú. Extraído desde:
<http://www.pcm.gob.pe/wp-content/uploads/2014/05/PLAN-MULTISECTORIAL-ANTE-HELADAS-y-FRIAJE-2014.pdf>
(Última fecha de revisión de *link*: 24/082014)
5. CHAMBI HOLGUÍN, H. 2008. Heladas y Friajes. CENPRED. Extraído desde:
<http://cenpredperu.blogspot.com/2008/03/helada-vs-friaje.html>
(Última fecha de revisión de *link*: 24/082014)
6. COIFFIER, JEAN. 2011. Fundamentals of Numerical Weather Prediction. Primera edición. Cambridge University Press, New York. Estados Unidos de América.
7. CONVENIO DE COOPERACIÓN TÉCNICA INTERINSTITUCIONAL SENAMHI-FAO. 2010. ATLAS DE HELADAS DEL PERÚ. Lima, Perú.

8. DEBBABI, MOURAD; et al. 2010. Verification and Validation in Systems Engineering. Primera Edición. Springer-Verlag Ediciones. Berlin, Heidelberg, Alemania.
9. DUDHIA, JIMY. 2014. WRF Modeling System Overview. WRF-ARW tutorials. Mesoscale and Microscale Meteorology Division. NCAR. Extraído desde: <http://www2.mmm.ucar.edu/wrf/users/supports/tutorial.html>
(Última fecha de revisión de *link*: 24/082014)
10. DUDHIA, JIMY. 2014. A History of mesoscale model development. Extraído de: <http://staff.ucar.edu/browse/people/7309/OSGC-000-000-020-352>
(Última fecha de revisión de *link*: 24/082014)
11. GAVIDIA CALDERÓN, MARIO. 2012. Simulación de las variables meteorológicas en la ciudad de Lima para el verano e invierno de 2009 con el modelo *Weather Research and Forecasting* (WRF). (Tesis de pregrado para obtener el título de Ingeniero Ambiental). Lima. Universidad Nacional Agraria La Molina.
12. GONZÁLEZ MINGUEZA, CARLOS; MUÑOZ GUTIÉRREZ, FRANCISCO. 2012. Wind prediction using Weather Research Forecasting model (WRF): A case study in Peru. *Energy Conversion and Management* 81 (2014) 363–373.
13. GRUPO PERÚ COP 20. 2013. Programa de Gestión de Riesgos y Adaptación al Cambio Climático de Soluciones Prácticas, organismo integrante del Grupo Perú COP 20. Cambio Climático, Heladas y Friajes. Artículo. Diario: La Primera. Lima, 25/10/2013. Extraído desde: <http://www.observatoriocambioclimatico.org/node/4709>
(Última fecha de revisión de *link*: 24/082014)
14. HAND, DAVID; MANNILA, HEIKKI; SMYTH, PADHRAIC. 2001. Principles of Data Mining. Primera Edición. Massachusetts Institute of Technology Ediciones. Estados Unidos.

15. JACOBSON, MARK Z. 2005. *Fundamentals of atmospheric modeling*. Primera edición. Cambridge University Press, New York. Estados Unidos de América.
16. JOLLIFFE, IAN T.; STEPHENSON, DAVID V. 2003. *Forecast Verification, A Practitioner's Guide in Atmospheric Science*. Primera Edición. Editorial John Wiley & Sons Ltd. Impreso en Gran Bretaña, Inglaterra por Antony Rowe Ltd.
17. KALNAY, EUGENIA. 2003. *Atmospheric modeling, Data Assimilation and Predictability*. Primera edición. Cambridge University Press, New York. Estados Unidos de América.
18. LARA FANEGO, V.; RUIZ-ARIAS, J.A.; POZO-VÁZQUEZ, D.; SANTOS ALAMILLOS, F.J.; TOVAR PESCADOR, J. 2012. Evaluation of the WRF model solar irradiance forecasts in Andalusia (southern Spain). *Solar Energy* 86 (2012) 2200–2217.
19. LEDESMA JIMENO, MANUEL. 2011. *Principios de Meteorología y Climatología*. Primera edición. Ediciones Paraninfo. España.
20. MINAM et al. 2010. *El Perú y el Cambio Climático. Segunda Comunicación Nacional del Perú a la Convención Marco de las Naciones Unidas sobre Cambio Climático* Fondo Editorial del Ministerio del Ambiente. Lima, Perú. Extraído desde: <http://cdam.minam.gob.pe/novedades/peruycambioclimatico.pdf> (Última fecha de revisión de *link*: 24/082014)
21. NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION (NOAA), et al. 2008. *Funcionamiento de los Modelos de Mesoescala. Meteorology Education and Training (MetEd)*. Extraído de: https://www.meted.ucar.edu/training_module.php?id=58#.VkeIYFUvfIV (Última fecha de revisión de *link*: 24/082014)
22. NEELIN, J. DAVID. 2011. *Climate Change and Climate Modeling*. Publicado en Estados Unidos por Cambridge University Press, New York.

23. PECK, ROXY; OLSEN, CHRIS; DEVORE, JAY L. 2012. Introduction to Statistics and Data Analysis. Cuarta Edición. Editorial Brook/Cole, Cengage Learning. Boston, Estados Unidos.
24. PIELKE, ROGER A. 2002. Mesoscale Meteorological Modeling. Segunda Edición. Editorial Academic Press. San Diego, Colorado, Estados Unidos.
25. RAMACHANDRAN, KANDETHODY M.; TSOKOS, CHRIS P. 2009. Mathematical Statistics with Applications. Primera Edición. Elsevier Inc. Elsevier Academic Press. California, Estados Unidos.
26. SÁNCHEZ CCOYLLO, ODÓN. CHAVEZ BARTUREN, JOSÉ. DÍAS DE FREITAS, EDMILSON. 2011. Validación del modelo de calidad del aire BRAMS/TEB en el área metropolitana de Lima. Revista Peruana Geo-Atmosférica RPGA (3), 125-133 (2011).
27. SKAMAROCK, WILLIAM C. et al. 2008. A Description of the Advanced Research WRF model, Version 3. NCAR. E.E.U.U.
28. TOMA INAFUKO, JORGE; RUBIO DONET, JORGE. 2011. Estadística Aplicada. Segunda Parte. Primera Edición. Centro de Investigación de la Universidad del Pacífico. Lima, Perú.
29. WANG, WEI. Julio, 2014. Considerations for designing a numerical experiment in WRF-ARW model. WRF-ARW tutorials. Mesoscale and Microscale Meteorology Division. NCAR. Extraído desde:
<http://www2.mmm.ucar.edu/wrf/users/supports/tutorial.html>
 (Última fecha de revisión de *link*: 24/082014)
30. WANG, WEI.; et al. Julio, 2012. Advanced Research WRF (ARW) User Guide. Mesoscale and Microscale Meteorology Division. NCAR. Version 3.4. Estados Unidos.
31. WARNER, THOMAS T. 2011. Numerical Weather and Climate Prediction. Primera edición. Cambridge University Press. New York, Estados Unidos de América.

32. WILKS, DANIEL S. 2006. Statistical Methods in the Atmospheric Sciences. Segunda Edición. Editorial Elsevier Inc. Estados Unidos.
33. WILLMOTT, CORT J. 1981. On the Validation of Models. Physical Geography, 1981, 2, 2, pp. 184-194. V. H. Winston & Sons. Extraído desde:
http://climate.geog.udel.edu/~climate/publication_html/Pdf/W_Phys_Geog_1981.pdf
(Última fecha de revisión de *link*: 24/082014)
34. WILLMOTT, CORT J. 1982. Some comments on the Evaluation of Model Performance. Bulletin American Meteorological Society. 1982. Extraído desde:
http://climate.geog.udel.edu/~climate/publication_html/Pdf/W_BAMS_82.pdf
(Última fecha de revisión de *link*: 24/082014)
35. WILLMOTT, CORT J., et al. 1985. Statistics for the Evaluation and Comparison of Models. Journal of Geophysical Research. Vol. 90, NO. C5, pp. 8995-9005, September 20, 1985. Extraído desde:
http://climate.geog.udel.edu/~climate/publication_html/Pdf/WADFKLO_JGROceans_85.pdf (Última fecha de revisión de *link*: 24/082014)
36. WONNACOTT, THOMAS H.; WONNACOTT, RONALD J. 2010. Introducción a la Estadística. Quinta Edición. Editorial Limusa S.A. Versión autorizada en español. Impreso en México.

VIII. ANEXOS

ANEXO 1: Configuración elegida en el preprocesador (WPS)

namelist.wps

```
&share
wrf_core = 'ARW',
max_dom = 3,
start_date = '2014-05-01_00:00:00', '2014-05-01_00:00:00', '2014-05-01_00:00:00',
end_date   = '2014-05-06_00:00:00', '2014-05-06_00:00:00', '2014-05-06_00:00:00',
interval_seconds = 21600
io_form_geogrid = 2,
/

&geogrid
parent_id      = 0, 1, 2,
parent_grid_ratio = 1, 3, 3,
i_parent_start = 1, 26, 26,
j_parent_start = 1, 26, 26,
e_we          = 76, 76, 76,
e_sn          = 76, 76, 76,
geog_data_res = '10m', '2m', '30s',
dx = 27000,
dy = 27000,
map_proj = 'mercator',
ref_lat  = -15.49,
ref_lon  = -71.12,
truelat1 = -15.4,
truelat2 = -15.4,
stand_lon = -71.2,
geog_data_path = '/home/modwrf/TARS_GEOG'
/

&ungrib
out_format = 'WPS',
prefix = 'FILE',
/

&metgrid
fg_name = 'FILE'
io_form_metgrid = 2,
```

Este es un archivo de texto para configurar el preprocesador del modelo WRF. En este caso se presenta la fecha de inicio y fin del primer pronóstico. Los demás pronósticos tuvieron la misma configuración que se puede apreciar en este archivo, la única variación será en la fecha de inicio y fin de los pronósticos.

ANEXO 2: Configuración elegida en el procesador (WRF-ARW)

namelist.input

```
&time_control
  run_days           = 5,
  run_hours          = 00,
  run_minutes        = 0,
  run_seconds        = 0,
  start_year         = 2014, 2014, 2014,
  start_month        = 05, 05, 05,
  start_day          = 01, 01, 01,
  start_hour         = 00, 00, 00,
  start_minute       = 00, 00, 00,
  start_second       = 00, 00, 00,
  end_year           = 2014, 2014, 2014,
  end_month          = 05, 05, 05,
  end_day            = 06, 06, 06,
  end_hour           = 00, 00, 00,
  end_minute         = 00, 00, 00,
  end_second         = 00, 00, 00,
  interval_seconds   = 21600
  input_from_file    = .true.,.true.,.true.,
  history_interval   = 60, 60, 60,
  frames_per_outfile = 1000, 1000, 1000,
  restart            = .false.,
  restart_interval   = 0,
  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            = 3,
  e_we               = 76, 76, 76,
  e_sn               = 76, 76, 76,
  e_vert             = 41, 41, 41,
  p_top_requested    = 5000,
  num_metgrid_levels = 27,
  num_metgrid_soil_levels = 4,
  dx                 = 27000, 9000, 3000,
  dy                 = 27000, 9000, 3000,
  grid_id            = 1, 2, 3,
  parent_id          = 0, 1, 2,
  i_parent_start     = 1, 26, 26,
  j_parent_start     = 1, 26, 26,
  parent_grid_ratio   = 1, 3, 3,
  parent_time_step_ratio = 1, 2, 3,
  feedback           = 1,
  smooth_option      = 0
/
```

```

&physics
mp_physics           = 4,      4,      4,
ra_lw_physics        = 4,      4,      4,
ra_sw_physics        = 2,      2,      2,
radt                 = 10,     10,     10,
sf_sfclay_physics    = 2,      2,      2,
sf_surface_physics   = 2,      2,      2,
bl_pbl_physics       = 2,      2,      2,
bldt                 = 0,      0,      0,
cu_physics           = 1,      1,      0,
cudt                 = 5,      5,      5,
isfflx               = 1,
ifsnw                 = 1,
icloud               = 1,
surface_input_source = 1,
num_soil_layers       = 4,
sf_urban_physics     = 0,      0,      0,
/

&fdda
/

&dynamics
w_damping             = 0,
diff_opt              = 1,
km_opt                = 4,
diff_6th_opt         = 0,      0,      0,
diff_6th_factor      = 0.12,  0.12,  0.12,
base_temp             = 290.
damp_opt              = 0,
zdamp                 = 5000., 5000., 5000.,
dampcoef              = 0.2,   0.2,   0.2,
khdif                 = 0,      0,      0,
kvdif                 = 0,      0,      0,
non_hydrostatic      = .true., .true., .true.,
moist_adv_opt         = 1,      1,      1,
scalar_adv_opt        = 1,      1,      1,
/

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

&grib2
/

&namelist_quilt
nio_tasks_per_group = 0,
nio_groups = 1,
/

```

Este es el archivo de texto para configurar el procesador del modelo, en donde se eligen las opciones de física y dinámica para ejecutar los pronósticos. La configuración de este archivo es la misma para todas las ejecuciones del modelo, con la única variación en las fechas de inicio y fin de los pronósticos. En este caso se muestra la fecha de inicio y fin del primer pronóstico. En este mismo archivo de texto se configura el dominio padre y los anidamientos.

ANEXO 3: Configuración elegida en el postprocesador (ARWpost)

namelist.ARWpost

```
&datetime
  start_date = '2014-05-01_00:00:00',
  end_date   = '2014-05-06_00:00:00',
  interval_seconds = 3600,
  tacc = 0,
  debug_level = 0,
/

&io
  input_root_name = '/WRF/WRFV3/run/wrfout_d03_2014-05-01_00:00:00'
  output_root_name = './tercer_dominio'
  plot = 'all_list'
  fields = 'height,pressure,tk,tc'
  mercator_defs = .true.
/

  split_output = .false.
  frames_per_outfile = 2

  plot = 'all'
  plot = 'list'
  plot = 'all_list'
! Below is a list of all available diagnostics
  fields =
'height,geopt,theta,tc,tk,td,td2,rh,rh2,umet,vmet,pressure,u10m,v10m,w
dir,wspd,wd10,ws10,slp,mcape,mcin,lcl,lf,cape,cin,dbz,max_dbz,clfr'

&interp
  interp_method = 0,
  interp_levels =
1000.,950.,900.,850.,800.,750.,700.,650.,600.,550.,500.,450.,400.,350.
,300.,250.,200.,150.,100.,
/
  extrapolate = .true.

  interp_method = 0,      ! 0 is model levels, -1 is nice height
levels, 1 is user specified pressure/height

  interp_levels =
1000.,950.,900.,850.,800.,750.,700.,650.,600.,550.,500.,450.,400.,350.
,300.,250.,200.,150.,100.,
  interp_levels = 0.25, 0.50, 0.75, 1.00, 2.00, 3.00, 4.00, 5.00, 6.00,
7.00, 8.00, 9.00, 10.0, 11.0, 12.0, 13.0, 14.0, 15.0, 16.0, 17.0,
18.0, 19.0, 20.0,
```

El archivo de texto *namelist.ARWpost* se modifica para configurar el postprocesador del modelo: ARWpost. El ARWpost se ejecuta una vez para cada dominio. En el presente estudio se ejecutó el ARWpost solo para el último anidamiento porque en éste se enfoca la zona de simulación de interés. La configuración del ARWpost es la misma para pronósticos o simulaciones, solo varía las fechas de inicio y fin y el nombre de salida del archivo. En este caso se muestra la fecha de inicio y fin del primer pronóstico de la sección 3.2.1.

ANEXO 4: Script utilizado para extraer los datos del modelo WRF

Script_WRF.gs

```
'reinit'  
'open Chivay_mayo_2014.ct1'  
  
*****  
'set lat -15.6336'  
'set lon 288.3997'  
'set xlopts 1 1 0.14'  
*'set z 1'  
*set t last'  
  
tt=1  
while ( tt<= 121 )  
'set t 'tt  
'q dims'  
lin = sublin(result,4)  
t = subwrdr (lin,9)  
lin = sublin(result,4)  
t= subwrdr(lin,6)  
  
*'set Time 'Time  
*****  
'd t2'  
t2=subwrdr(result,4)  
  
*****  
*'d U'  
*U=subwrdr(result,4)  
  
*****  
*'d V'  
*V=subwrdr(result,4)  
  
*****  
*'d QVAPOR'  
*QVAPOR=subwrdr(result,4)  
  
*****  
dummy=write('Chivay_salida_Mayo_2014.txt', " "t2 " " tc " " ,append)  
tt=tt+1  
endwhile  
  
'quit'
```

Este *script* escrito en lenguaje de programación GRADS muestra el algoritmo utilizado para extraer solo los datos de temperaturas a dos metros, pronosticados con 120 horas de anticipación de la primera ejecución del modelo. Las horas extraídas de cada pronóstico, como se aprecia en la línea 12 del *script*, fueron de 121 horas, de las cuales las 12 primeras horas no entraron en la validación debido al efecto *spin-off*. Un mismo tipo de este *script* se utilizó para extraer las horas pronosticadas y/o simulados de las demás ejecuciones del modelo, cambiando solo los nombres de los archivos de entrada y salida.