



UNIVERSIDAD DE CONCEPCIÓN  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE GEOFÍSICA

APLICACIÓN DE MOS A UN PRONÓSTICO ATMOSFÉRICO  
EN LA REGIÓN DE LOS LAGOS Y DE AYSÉN

Lucas Francisco Calbucura Zúñiga

Tesis presentada a la Facultad de Ciencias Físicas y Matemáticas de la  
Universidad de Concepción para optar al título profesional de Geofísico.

Profesor Guía: Dr. Andrés Sepúlveda  
Profesor Co-Guía: Dr. Osvaldo Artal

23 de marzo de 2023  
Concepción, Chile



UNIVERSIDAD DE CONCEPCIÓN  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE GEOFÍSICA

APLICACIÓN DE MOS A UN PRONÓSTICO ATMOSFÉRICO  
EN LA REGIÓN DE LOS LAGOS Y DE AYSÉN

Lucas Francisco Calbucura Zúñiga

Tesis presentada a la Facultad de Ciencias Físicas y Matemáticas de la  
Universidad de Concepción para optar al título profesional de Geofísico.

Comisión:

Dr. Andrés Sepúlveda

Dr. Osvaldo Artal

Mg. Ricardo Alcafuz

23 de marzo de 2023

Concepción, Chile

©2022 Lucas Francisco Calbucura Zúñiga

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

# AGRADECIMIENTOS

Agradezco a mi profesor guía Andrés Sepúlveda por darme la oportunidad de desarrollar este trabajo, por su constante apoyo y motivación. También quiero agradecer a Osvaldo Artal, a Oliver Venegas y al equipo de investigadores del Instituto de Fomento Pesquero (IFOP) de Putemún, Castro, por brindarme acceso a los datos del modelo atmosférico MOSA-WRF y de las estaciones meteorológicas, fundamentales para llevar a cabo esta tesis.

Se agradece el apoyo financiero del proyecto Fondecyt Regular 1211230. Las estaciones meteorológicas y las salidas de MOSA-WRF forman parte del convenio que se suscribe anualmente entre la Subsecretaría de Economía y Empresas de Menor Tamaño y el Instituto de Fomento Pesquero, como parte del marco legal establecido por la Ley de Pesca y Acuicultura N°20.657.

# Índice general

<b>Índice de figuras</b>	<b>IV</b>
<b>Índice de tablas</b>	<b>XVII</b>
<b>Resumen</b>	<b>XVIII</b>
<b>1. Introducción</b>	<b>1</b>
1.1. La Patagonia chilena . . . . .	1
1.2. Modelos de predicción meteorológica . . . . .	6
1.3. Modelo Operacional Sur-Austral (MOSA) . . . . .	9
1.4. Técnicas estadísticas de post-procesamiento . . . . .	13
<b>2. Objetivos</b>	<b>17</b>
2.1. Objetivo general . . . . .	17
2.2. Objetivos específicos . . . . .	17
<b>3. Metodología</b>	<b>18</b>
3.1. Datos . . . . .	18
3.1.1. Estaciones meteorológicas . . . . .	18
3.1.2. MOSA-WRF . . . . .	20
3.2. MOS (Model Output Statistics) . . . . .	21
3.2.1. Regresión lineal múltiple . . . . .	21
3.2.2. Forward selection . . . . .	23

---

3.2.3. Cross validation . . . . .	26
3.3. Estadísticos empleados para la validación . . . . .	28
3.3.1. Sesgo (BIAS): . . . . .	28
3.3.2. Raíz del error cuadrático medio (RMSE): . . . . .	28
3.3.3. Coeficiente de correlación (r): . . . . .	28
3.3.4. Coeficiente de determinación ( $R^2$ ): . . . . .	29
3.3.5. Cociente entre las desviaciones estándar: . . . . .	29
3.3.6. Significancia: . . . . .	29
3.3.7. Monte-Carlo: . . . . .	29
<b>4. Resultados</b>	<b>30</b>
4.1. Temperatura máxima histórica (MOSA-WRF) . . . . .	30
4.1.1. Distribución del error . . . . .	32
4.1.2. Variables predictoras que ajustan la temperatura máxima . . . . .	34
4.1.3. Temperatura máxima reconstruida (MOS) . . . . .	35
4.1.4. Simulación de Monte-Carlo . . . . .	38
4.1.5. Eventos extremos de temperatura máxima . . . . .	39
4.2. Temperatura mínima histórica (MOSA-WRF) . . . . .	40
4.2.1. Distribución del error . . . . .	42
4.2.2. Variables predictoras que ajustan la temperatura mínima . . . . .	44
4.2.3. Temperatura mínima reconstruida (MOS) . . . . .	45
4.2.4. Simulación de Monte-Carlo . . . . .	48
4.2.5. Eventos extremos de temperatura mínima . . . . .	49
4.3. Temperatura (MOS Operacional) . . . . .	50
4.3.1. Prueba de sensibilidad . . . . .	50
<b>5. Discusión</b>	<b>51</b>
5.0.1. MOS operacional . . . . .	53
<b>6. Conclusión</b>	<b>54</b>

---

<b>Referencias</b>	<b>57</b>
<b>Anexos</b>	<b>65</b>
A1. Física del modelo WRF . . . . .	65
A2. Rosa de los vientos simulada por MOSA-WRF . . . . .	67
A3. MOS Operacional . . . . .	69
A3.1. Pronóstico generado el 1 de octubre de 2020. . . . .	69
A3.2. Pronóstico generado el 1 de noviembre de 2020. . . . .	70
A3.3. Pronóstico generado el 1 de diciembre de 2020. . . . .	71
A3.4. Pronóstico generado el 1 de enero de 2021. . . . .	72
A3.5. Pronóstico generado el 1 de febrero de 2021. . . . .	73
A3.6. Pronóstico generado el 1 de marzo de 2021. . . . .	74
A3.7. Pronóstico generado el 1 de abril de 2021. . . . .	75
A3.8. Pronóstico generado el 1 de mayo de 2021. . . . .	76
A3.9. Pronóstico generado el 1 de junio de 2021. . . . .	77
A3.10. Pronóstico generado el 1 de julio de 2021. . . . .	78
A3.11. Pronóstico generado el 1 de agosto de 2021. . . . .	79
A3.12. Pronóstico generado el 1 de septiembre de 2021. . . . .	80
A3.13. Pronóstico generado el 1 de octubre de 2021. . . . .	82
A3.14. Pronóstico generado el 1 de noviembre de 2021. . . . .	83
A3.15. Pronóstico generado el 1 de diciembre de 2021. . . . .	85
A3.16. Pronóstico generado el 1 de enero de 2022. . . . .	87
A3.17. Pronóstico generado el 1 de febrero de 2022. . . . .	88
A3.18. Pronóstico generado el 1 de marzo de 2022. . . . .	89
A3.19. Pronóstico generado el 1 de abril de 2022. . . . .	90
A3.20. Pronóstico generado el 1 de mayo de 2022. . . . .	91
A3.21. Pronóstico generado el 1 de junio de 2022. . . . .	92
A3.22. Pronóstico generado el 1 de julio de 2022. . . . .	93
A3.23. Pronóstico generado el 1 de agosto de 2022. . . . .	94

# Índice de figuras

1.1.1. Patagonia Chilena y sus áreas protegidas. Figura extraída desde <a href="#">Sepúlveda (2020)</a> . . . . .	2
1.1.2. Fiordo Comau, Patagonia Chilena. Imagen que representa la accidentada topografía de la región. Fotografía: <a href="#">Jorge León Cabello</a> . . . . .	3
1.1.3. Aluvión en Villa Santa Lucía el 16 diciembre de 2017. Fue generado por intensas precipitaciones en el sector alto de la cordillera, saturando el suelo y arrastrando nieve, troncos y cenizas volcánicas, formando una gran masa que arrasó con el lugar. Fotografía: Diego Mautor. . . . .	4
1.1.4. Compuesto de altura geopotencial en 500 hPa (contornos blancos) y presión al nivel del mar (coloreado), del 29 de septiembre de 2020 a las 16:00 hora local (18:00 UTC). Fuente: NCAR-NCEP NOAA/ESRL y <a href="#">DMC</a> . . . . .	5
1.3.1. Modelo de elevación digital de MOSA-WRF. Posee un dominio anidado centrado en la región de Los Lagos y de Aysén. El primer domino tiene una resolución de 9 km mientras que el segundo una resolución de 3 km. . . . .	9

---

1.3.2. Rendimiento de MOSA-WRF desde que se implementó la resolución de 3 km (septiembre de 2020) hasta la actualidad (agosto de 2022), indicando en color azul si el pronóstico fue exitoso y con un espacio en blanco si el pronóstico presentó algún error en su ejecución. El color gris indica inexistencia de MOSA-WRF. Se observa que el modelo se ha mantenido estable en el tiempo, presentando un 99.86 % de efectividad. Figura tomada desde informe técnico IFOP (Artal et al., 2021). . . . .	10
1.3.3. Grilla Arakawa-C (Arakawa and Lamb, 1981) ocupada por el modelo WRF para resolver las ecuaciones que gobiernan la circulación de la atmósfera (Skamarock et al., 2008). . . . .	11
1.3.4. Coordenada vertical sigma $\sigma$ que sigue el contorno del terreno (Skamarock et al., 2008). . . . .	12
3.1.1. Modelo de elevación digital (DEM) del dominio interior (d02) junto con la ubicación de las estaciones meteorológicas. . . . .	20
3.2.1. Superficie de valores para la función de costo. . . . .	22
3.2.2. Diagrama de flujo de MOS (Model Output Statistics). . . . .	23
3.2.3. Matriz de correlación para los máximos diarios simulados por MOSA-WRF. Las variables son: temperatura del aire a 2 metros (T2), presión atmosférica (P), y la componente zonal (U10) y meridional del viento (V10). . . . .	24
3.2.4. Matriz de correlación para los mínimos diarios simulados por MOSA-WRF. Las variables son: temperatura del aire a 2 metros (T2), presión atmosférica (P), y la componente zonal (U10) y meridional del viento (V10). . . . .	24
3.2.5. Forward selection: método de selección de variables simuladas (predictores) para la regresión lineal múltiple. . . . .	25
3.2.6. Validación cruzada para MOS operacional. Se utilizan 720 datos horarios (88 % de los datos) para entrenar el modelo y luego se le aplican los coeficientes obtenidos a las 96 horas de pronóstico (12 % de datos restante). . . . .	27

---

4.1.1. Series de tiempo de la temperatura máxima observada (azul), pronosticada (amarillo) y su diferencia (rojo) en Cucao y Melinka. El periodo considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022. . . . .	31
4.1.2. Diagramas de dispersión para la temperatura máxima diaria (observada vs pronosticada) en Cucao y Melinka. La línea negra corresponde a una correlación positiva perfecta mientras que la roja a la línea ajustada. . . . .	31
4.1.3. Distribución del sesgo en Cucao separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura máxima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos. . . . .	32
4.1.4. Distribución del sesgo en Melinka separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura máxima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos. . . . .	33
4.1.5. Variables predictoras simuladas por MOSA-WRF que ajustan la temperatura máxima diaria (presión atmosférica y la componente zonal y meridional del viento). En verde los máximos diarios de Cucao y en magenta los máximos diarios de Melinka. . . . .	34
4.1.6. Máximos diarios de temperatura observada (azul), simulada (amarillo) y ajustada con MOS (rojo) en Cucao y Melinka. El periodo considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022 (N=699). . . . .	35
4.1.7. Diferencias de temperatura máxima entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 01/09/2020 hasta el 01/08/2022. (N=699). . . . .	36
4.1.8. QQ plot temperatura máxima Cucao y Melinka. . . . .	36

---

4.1.9. Diagrama de Taylor (izquierda) y diagrama BIAS vs RMSE (derecha) para la temperatura máxima histórica, simulada por MOSA (diamantes) y reconstruida con MOS (estrellas) para el periodo 01-09-2020 - 01-08-2022. El color azul corresponde a Cucao y el verde a Melinka. Los estadísticos fueron calculados con respecto a las mediciones de las estaciones meteorológicas (círculo rojo). . . . .	37
4.1.10. Simulación de RMSE con Monte-Carlo para la temperatura máxima corregida considerando 10.000 iteraciones. En verde se observa la distribución del RMSE obtenido para cada una de las iteraciones, con la línea verde segmentada se observa el promedio de los 10.000 RMSE y con la línea amarilla segmentada se muestra el RMSE obtenido con MOS originalmente, los cuales coinciden tanto en Cucao como en Melinka. . . . .	38
4.1.11. Eventos extremos de temperatura máxima ocurridos en Cucao y Melinka el 2021 y 2022 (percentil 99). En azul se tiene el pronóstico de temperatura máxima pronosticado con respecto a lo observado y en rojo se tiene el pronóstico de corregido con respecto a lo observado. El valor ideal es 100%. . . . .	39
4.2.1. Series de tiempo de la temperatura mínima observada (azul), pronosticada (amarillo) y su diferencia (rojo) en Cucao y Melinka. El periodo considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022. . . . .	40
4.2.2. Diagramas de dispersión para la temperatura mínima diaria (observada vs pronosticada) en Cucao y Melinka. La línea negra corresponde a una correlación positiva perfecta mientras que la roja a la línea ajustada. . . . .	41
4.2.3. Distribución del sesgo en Cucao separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura mínima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos. . . . .	42

---

4.2.4. Distribución del sesgo en Melinka separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura mínima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos. . . . .	43
4.2.5. Variables predictoras simuladas por MOSA-WRF que ajustan la temperatura mínima diaria (presión atmosférica y la componente zonal y meridional del viento). En verde los mínimos diarios de Cucao y en magenta los mínimos diarios de Melinka. . . . .	44
4.2.6. Mínimos diarios de temperatura observada (azul), simulada (amarillo) y ajustada con MOS (rojo) en Cucao y Melinka. El período considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022. (N=699). . . . .	45
4.2.7. Diferencias de temperatura mínima entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 01/09/2020 hasta el 01/08/2022. (N=699). . . . .	46
4.2.8. QQ plot temperatura mínima Cucao y Melinka. . . . .	46
4.2.9. Diagrama de Taylor (izquierda) y diagrama BIAS vs RMSE (derecha) para la temperatura mínima histórica, simulada por MOSA (diamantes) y reconstruida con MOS (estrellas) para el periodo 01-09-2020 - 01-08-2022. El color azul corresponde a Cucao y el verde a Melinka. Los estadísticos fueron calculados con respecto a las mediciones de las estaciones meteorológicas (círculo rojo). . . . .	47
4.2.10. Simulación de RMSE con Monte-Carlo para la temperatura mínima corregida considerando 10.000 iteraciones. En verde se observa la distribución del RMSE obtenido para cada una de las iteraciones, con la línea verde segmentada se observa el promedio de los 10.000 RMSE y con la línea amarilla segmentada se muestra el RMSE obtenido con MOS originalmente, los cuales coinciden tanto en Cucao como en Melinka. . . . .	48

---

4.2.11. Eventos extremos de temperatura mínima ocurridos en Cucao y Melinka el 2021 y 2022 (valores por debajo del percentil 1). En verde se tiene la temperatura mínima diaria observada, en azul se tiene el pronóstico y en rojo se tiene el pronóstico corregido. . . .	49
4.3.1. BIAS para la temperatura pronosticada (azul) y ajustada (rojo) con respecto a las observaciones. El periodo de evaluación considera desde octubre (2020) hasta agosto (2022). . . . .	50
A2.1. Rosa de vientos simulada por MOSA para la estación CUCAO. Se observan 16.776 datos horarios desde septiembre de 2020 hasta agosto de 2022. . . . .	67
A2.2. Rosa de vientos simulada por MOSA para la estación MELINKA. Se observan 16.776 datos horarios desde septiembre de 2020 hasta agosto de 2022. . . . .	68
A3.1. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de octubre de 2020 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	69
A3.2. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de octubre de 2020 hasta el 4 de octubre de 2020 (96 datos horarios). . . . .	69
A3.3. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de noviembre de 2020 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	70
A3.4. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de noviembre de 2020 hasta el 4 de noviembre de 2020 (96 datos horarios). . . . .	70

A3.5. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de diciembre de 2020 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	71
A3.6. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de diciembre de 2020 hasta el 4 de diciembre de 2020 (96 datos horarios). . . . .	71
A3.7. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de enero de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	72
A3.8. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de enero de 2021 hasta el 4 de enero de 2021 (96 datos horarios). . . . .	72
A3.9. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de febrero de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	73
A3.10. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de febrero de 2021 hasta el 4 de febrero de 2021 (96 datos horarios). . . . .	73
A3.11. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de marzo de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	74

---

A3.12. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de marzo de 2021 hasta el 4 de marzo de 2021 (96 datos horarios). . . . .	74
A3.13. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de abril de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	75
A3.14. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de abril de 2021 hasta el 4 de abril de 2021 (96 datos horarios). . . . .	75
A3.15. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de mayo de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	76
A3.16. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de mayo de 2021 hasta el 4 de mayo de 2021 (96 datos horarios). . . . .	76
A3.17. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de junio de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	77
A3.18. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de junio de 2021 hasta el 4 de junio de 2021 (96 datos horarios). . . . .	77

---

A3.19. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de julio de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	78
A3.20. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de julio de 2021 hasta el 4 de julio de 2021 (96 datos horarios). . . . .	78
A3.21. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de agosto de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	79
A3.22. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de agosto de 2021 hasta el 4 de agosto de 2021 (96 datos horarios). . . . .	79
A3.23. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de septiembre de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	80
A3.24. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de septiembre de 2021 hasta el 4 de septiembre de 2021 (96 datos horarios). . . . .	81
A3.25. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de octubre de 2021 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	82

---

A3.26. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de octubre de 2021 hasta el 4 de octubre de 2021 (96 datos horarios). . . . .	82
A3.27. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de noviembre de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	83
A3.28. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de noviembre de 2021 hasta el 4 de noviembre de 2021 (96 datos horarios). . . . .	84
A3.29. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de diciembre de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	85
A3.30. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de diciembre de 2021 hasta el 4 de diciembre de 2021 (96 datos horarios). . . . .	86
A3.31. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de enero de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	87
A3.32. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de enero de 2022 hasta el 4 de enero de 2022 (96 datos horarios). . . . .	87

---

A3.33. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de febrero de 2022 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	88
A3.34. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de febrero de 2022 hasta el 4 de febrero de 2022 (96 datos horarios). . . . .	88
A3.35. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de marzo de 2022 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	89
A3.36. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de marzo de 2022 hasta el 4 de marzo de 2022 (96 datos horarios). . . . .	89
A3.37. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de abril de 2022 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	90
A3.38. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de abril de 2022 hasta el 4 de abril de 2022 (96 datos horarios). . . . .	90
A3.39. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de mayo de 2022 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	91

---

A3.40. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de mayo de 2022 hasta el 4 de mayo de 2022 (96 datos horarios). . . . .	91
A3.41. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de junio de 2022 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	92
A3.42. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de junio de 2022 hasta el 4 de junio de 2022 (96 datos horarios). . . . .	92
A3.43. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de julio de 2022 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	93
A3.44. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de julio de 2022 hasta el 4 de julio de 2022 (96 datos horarios). . . . .	93
A3.45. Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de agosto de 2022 (96 datos horarios). En azul se muestra la temperatura la pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS. . . . .	94
A3.46. Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de agosto de 2022 hasta el 4 de agosto de 2022 (96 datos horarios). . . . .	94

## Índice de tablas

1.3.1. Principales características del dominio anidado de MOSA-WRF. . . . .	12
3.1.1. Estaciones meteorológicas utilizadas en este estudio. . . . .	18
3.1.2. Sensores de las estaciones meteorológicas instaladas en Cucao y Melinka por el IFOP. Ambas estaciones cuentan con un Datalogger HOBO RX3000. . . . .	19
3.1.3. Datos sospechosos o erróneos de las mediciones obtenidas en Cucao y Melinka. El periodo considera una serie de tiempo sin datos faltantes. . . . .	19
4.1.1. Coeficientes de regresión que ajustan la temperatura máxima pronosticada en Cucao y Melinka. . . . .	35
4.2.1. Coeficientes de regresión que ajustan la temperatura mínima pronosticada en Cucao y Melinka. . . . .	45

## Resumen

Producto de la naturaleza no lineal de los procesos atmosféricos, los pronósticos generados por modelos numéricos suelen tener errores sistemáticos (sesgos) que producen incertezas. En este trabajo se presenta el desarrollo e implementación de la técnica MOS (Model Output Statistics) utilizada para corregir el sesgo del pronóstico histórico (2020-2022) de temperatura máxima y mínima diaria generado por MOSA (Modelo Operacional Sur-Austral) en dos lugares del sur de Chile, Cucao y Melinka. En particular, se utiliza una regresión lineal múltiple combinando mediciones y múltiples variables simuladas por el modelo para obtener los coeficientes que mejor se ajusten a las observaciones. Al contar con datos de estaciones en tiempo real, MOS tiene un gran potencial para ser utilizado operacionalmente, y mediante una validación cruzada, se determina la cantidad de datos horarios para calibrar, de forma automatizada, el pronóstico de temperatura (de 96 horas) que se genera cada día. Los resultados muestran que MOS corrige el error sistemático de las series históricas (para la temperatura máxima, Cucao reduce el sesgo de  $-0.8$  a  $0$  °C y Melinka de  $-2.2$  a  $0$  °C mientras que para la temperatura mínima, Cucao reduce el sesgo de  $-0.7$  a  $0$  °C y Melinka de  $-1.5$  a  $0$  °C). Además, los resultados muestran mejoras significativas en el pronóstico que MOSA-WRF genera diariamente, concluyendo que sí es factible implementar MOS de forma operacional. Como trabajo futuro es posible calibrar un pronóstico de precipitación aunque es necesario contar con muchas más estaciones meteorológicas operativas.

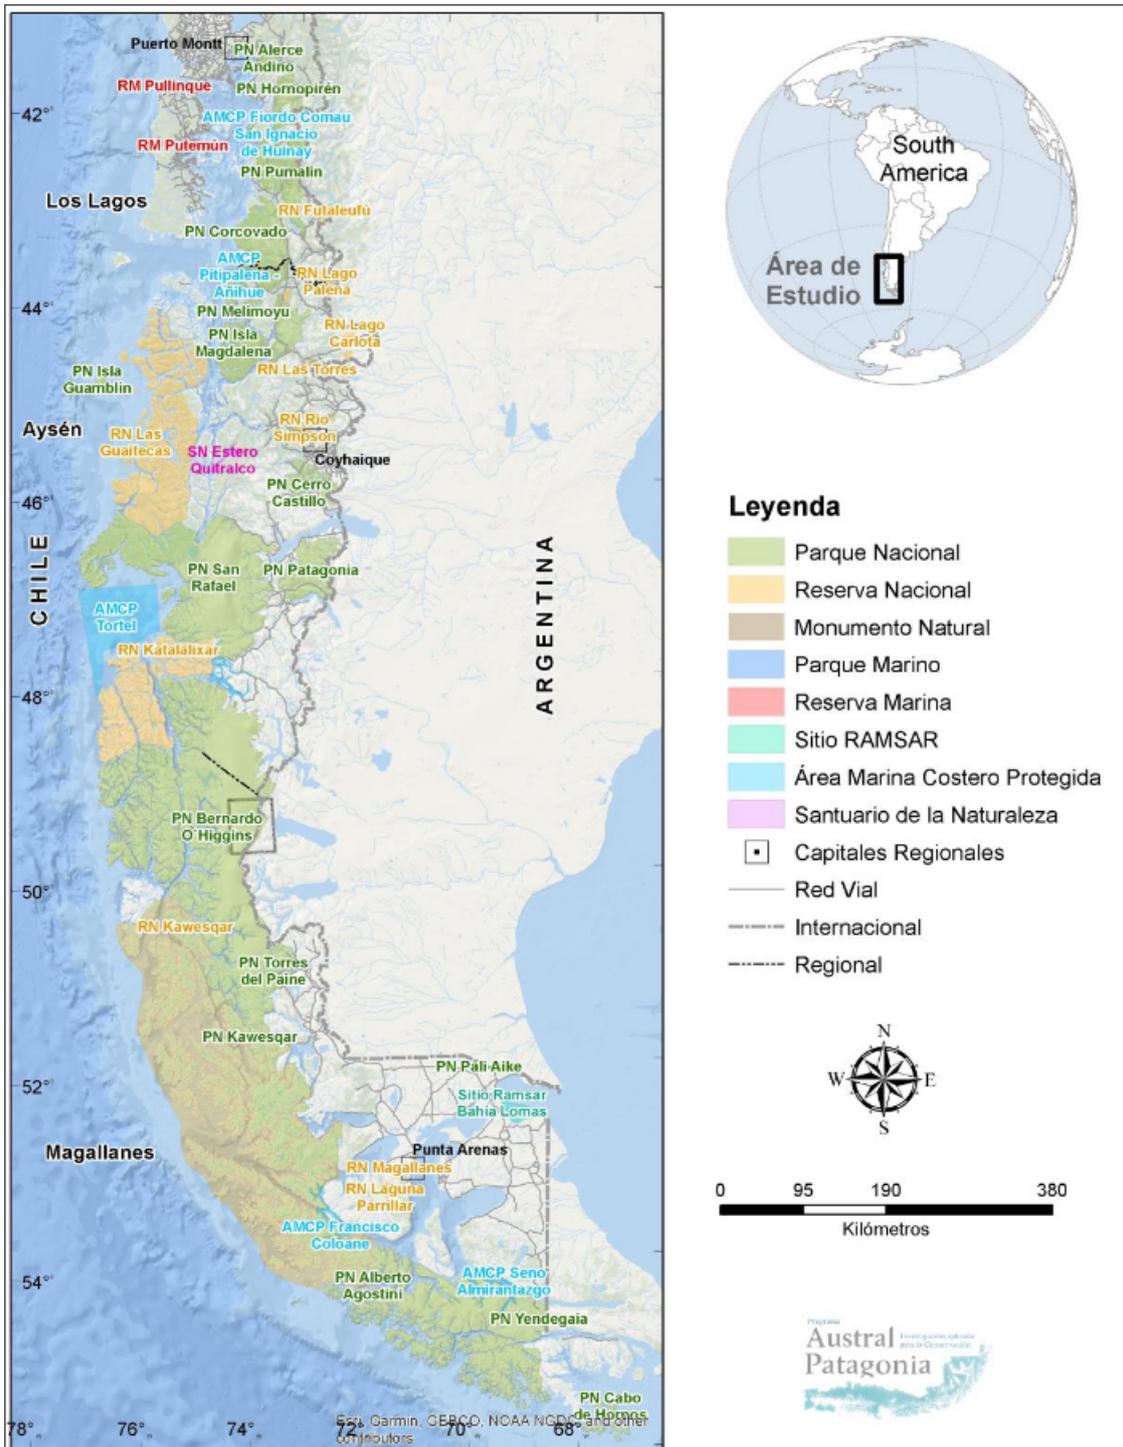
# Capítulo 1

## Introducción

### 1.1. La Patagonia chilena

La Patagonia chilena corresponde a la zona más austral de Chile. Comprende las regiones de Los Lagos, Aysén y Magallanes (**Figura 1.1.1**), extendiéndose desde el Seno de Reloncaví (41°S) hasta el Cabo de Hornos (56°S), cubriendo todo el territorio desde el océano Pacífico hasta el límite con Argentina, con una superficie de 240.000 km<sup>2</sup> (33,8% de la superficie nacional, [Pantoja et al., 2011](#)).

La patagonia se caracteriza por tener una de las mayores reservas de agua del planeta, con los campos de hielo norte (región de Aysén) y campos de hielo sur (región de Aysén, Magallanes y Antártica), que cuentan con una extensión de 4.000 y 13.000 km<sup>2</sup>, respectivamente. Más al sur, en Tierra del Fuego (región de Magallanes y Antártica), existe la cordillera de Darwin, con campos de hielo con una extensión de 2.500 km<sup>2</sup> ([Instituto Chileno de Campos de Hielos, 2022](#)).



**Figura 1.1.1:** Patagonia Chilena y sus áreas protegidas. Figura extraída desde Sepúlveda (2020).

La accidentada topografía de la Patagonia (**Figura 1.1.2**) juega un rol fundamental en la dinámica atmosférica de baja altura, permitiendo canalizar los vientos a lo largo de sus abundantes valles, fiordos, archipiélagos y canales, generando patrones de circulación a escala local (**Falvey and Garreaud, 2007**).



**Figura 1.1.2:** Fiordo Comau, Patagonia Chilena. Imagen que representa la accidentada topografía de la región. Fotografía: **Jorge León Cabello**.

Esta zona posee dos tipos de climas, uno oceánico lluvioso presente en los archipiélagos y fiordos, y otro más frío y seco a medida que se avanza hacia el oriente andino y hacia el sur. Esto se debe principalmente a que en la Patagonia chilena predominan vientos del oeste durante todo el año, los cuales transportan humedad desde el océano Pacífico hacia el interior (**Garreaud, 2013**). Sin embargo, al encontrarse con la cordillera de los Andes, el aire se eleva y se enfría hasta alcanzar su punto de rocío, momento en que se condensa y se generan precipitaciones, mientras que por el otro lado, el aire seco desciende por las laderas, generando escasa precipitación (**Viale and Garreaud, 2015**).

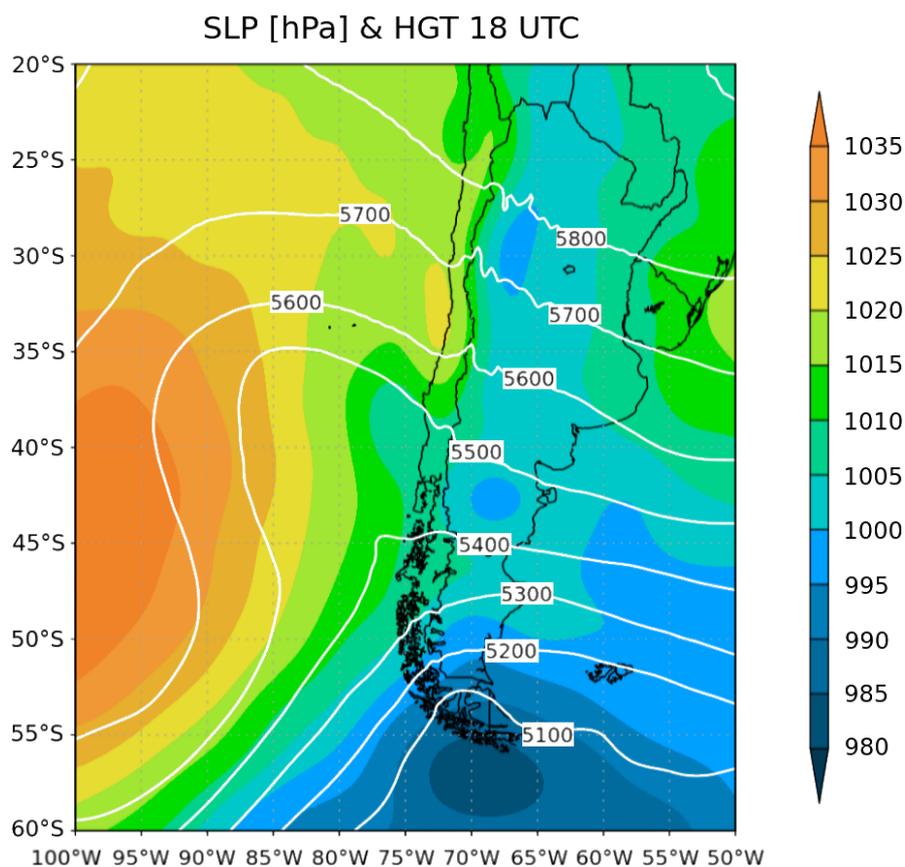
De tal forma, existe un gradiente de temperatura que disminuye de norte a sur y precipitaciones que se reducen de oeste a este. Esta mayor humedad en la parte occidental de la cordillera explica la existencia de los extensos bosques patagónicos mientras que más al interior se presenta una región semiárida denominada estepa patagónica (**Barros, 2022**).

Los Ríos Atmosféricos (RA) contribuyen con más del 60% de la precipitación anual en gran parte de Chile aportando a la formación del manto de nieve sobre la cordillera de Los Andes, que se derrite en verano y que alimenta los ríos terrestres (Viale et al., 2018). Sin embargo, pueden desencadenar eventos hidrometeorológicos extremos como el aluvión de Villa Santa Lucía en diciembre de 2017 (**Figura 1.1.3**), que fue producido por un RA que llegó a la costa de forma casi perpendicular, denominado Río Atmosférico Zonal (RAZ). Estos afectan con precipitaciones muy intensas en un rango de cientos de kilómetros en el eje norte-sur. Los RAZ poseen un desplazamiento lento y las precipitaciones se generan con temperaturas altas, lo que mantiene la altura de la isoterma 0 muy elevada (Garreaud, 2013), aumentando la precipitación líquida sobre la cordillera y también el caudal de los ríos. De esa forma, un período de lluvia cálida, prolongado e intenso es la combinación perfecta para generar inundaciones y en los casos más desastrosos, aluviones.



**Figura 1.1.3:** Aluvión en Villa Santa Lucía el 16 diciembre de 2017. Fue generado por intensas precipitaciones en el sector alto de la cordillera, saturando el suelo y arrastrando nieve, troncos y cenizas volcánicas, formando una gran masa que arrasó con el lugar. Fotografía: Diego Mautor.

En los últimos años también han ocurrido otros eventos meteorológicos extremos, como la inusual caída de nieve en primavera en la Isla Grande de Chiloé entre el 29 y 30 de septiembre de 2020. Esto se debió al paso de un sistema frontal frío, a la inestabilidad causada por una vaguada en altura (nivel medio de la tropósfera, 500 hPa) y un centro de baja presión en superficie (**Figura 1.1.4**).



**Figura 1.1.4:** Compuesto de altura geopotencial en 500 hPa (contornos blancos) y presión al nivel del mar (coloreado), del 29 de septiembre de 2020 a las 16:00 hora local (18:00 UTC). Fuente: NCAR-NCEP NOAA/ESRL y DMC.

En ese contexto, es fundamental contar con modelos numéricos operacionales y sistemas de alerta temprana que permitan monitorear las variables atmosféricas de los sistemas dinámicos en la Patagonia chilena. En consecuencia, un pronóstico preciso será cada vez más crucial para la prevención y mitigación de catástrofes ante la ocurrencia de eventos extremos (Hess and Boers, 2022).

Este estudio se enfoca en calibrar los pronósticos de temperatura máxima y mínima en dos lugares específicos del sur de Chile, las cuales poseen condiciones oceánicas con topografía abierta: Cucao, ubicada en la parte occidental de Chiloé (42.601°S) y Melinka, ubicada en las Guaitecas al sur de Chiloé (43.897°S).

## 1.2. Modelos de predicción meteorológica

Los modelos de predicción meteorológica son modelos numéricos que permiten estimar la evolución de la atmósfera en un futuro cercano basándose en su estado actual (condiciones iniciales y de borde), resolviendo, en computadoras de alto rendimiento, las ecuaciones dinámicas y termodinámicas de los procesos que gobiernan la atmósfera. Sin embargo, las ecuaciones que describen con mayor detalle la dinámica de fluidos son derivadas parciales no-lineales por lo que no tienen solución analítica (Calvo, 2018).

De esa forma, estas ecuaciones deben aproximarse numéricamente, existiendo distintos métodos que dan lugar a una gran variedad de modelos. Algunos modelos globales (con resolución horizontal de cientos de kilómetros) emplean métodos espectrales para las dimensiones horizontales y métodos de diferencias finitas para el plano vertical como el modelo ECMWF (Ritchie et al., 1995), el modelo GFS (NCEP, 2015) y el modelo francés ARPEGE (Déqué et al., 1994) mientras que los modelos regionales suelen usar métodos de diferencias finitas para las tres dimensiones (Pielke, 1984). Estos últimos permiten emplear grillas más reducidas para analizar fenómenos meteorológicos de pequeña escala, y se les denomina modelos numéricos de mesoescala.

Los primeros esfuerzos por hacer predicciones se remontan a 1920, cuando Lewis Fry Richardson propone la utilización de un modelo numérico para la predicción meteorológica. Sin embargo, el primer logro en este nuevo campo no fue hasta 1950 con la llegada de la computación, cuando un meteorólogo del MIT y un matemático de Princeton emplearon una forma simplificada de la dinámica atmosférica basada en la ecuación de vorticidad barotrópica (Charney et al., 1950). Esta fase primitiva redujo significativamente el tiempo de cálculo, de manera que pudiera ser utilizada con los recursos computacionales de la época.

Desde ese entonces, los modelos de predicción meteorológica han experimentado un desarrollo revolucionario, con grandes avances computacionales y nuevas técnicas de observación (satélites, radares). Así, los modelos posteriores comenzaron a emplear ecuaciones mucho más complejas para la dinámica y termodinámica de la atmósfera (Bauer et al., 2015). Actualmente, este tipo de modelación numérica es utilizada de manera operacional para realizar predicciones del tiempo en todo el mundo.

---

Con el avance de la tecnología, también ha sido posible aumentar la resolución de los modelos regionales hasta alcanzar resoluciones de unos pocos kilómetros. En estas resoluciones la aproximación hidrostática deja de ser válida y es necesario agregar al menos dos ecuaciones de pronóstico que consideren la velocidad vertical y la presión atmosférica (Klemp and Wilhelmson, 1978). También se incluyen procesos de microfísica de nubes que son mucho más complejos (Grabowski et al., 2019). Los efectos no hidrostáticos son importantes para representar las nubes convectivas, precipitaciones intensas y efectos orográficos.

Uno de los pioneros fue el modelo MM5 (Dudhia, 1993; Grell, 1994), un modelo numérico de predicción de mesoescala de 5ta generación desarrollado por la Universidad de Pensilvania en conjunto con el Centro Nacional de Investigación Atmosférica (NCAR). Puede configurarse como hidrostático o no-hidrostático. Es completamente compresible y utiliza coordenadas verticales sigma que siguen el contorno del terreno, resolviendo las ecuaciones de la atmósfera con diferencias finitas. Utiliza como forzante las salidas del pronóstico global GFS (NCEP, 2015) y posee la capacidad de trabajar con anidados, pudiéndose ocupar dos técnicas distintas, one way nesting (la simulación del dominio padre se genera de forma independiente y sus resultados se utilizan como forzante para el dominio interior) o two way nesting (las simulaciones de ambos dominios se ejecutan simultáneamente y se intercambian información cada cierto paso de tiempo).

La continuación de MM5, y actualmente uno de los más populares, es el modelo Weather Research and Forecasting (WRF, Skamarock et al., 2008), un modelo numérico de predicción meteorológica de mesoescala desarrollado por el Centro Nacional de Investigación Atmosférica (NCAR) en colaboración con otras organizaciones. Es una herramienta de simulación atmosférica eficaz, que también es capaz de realizar reconstrucciones pasadas de distintos parámetros, tales como temperatura, precipitación, viento, humedad, etc. Cuenta con dos núcleos que resuelven las ecuaciones de la atmósfera: el Advanced Research WRF (ARW) y el Nonhydrostatic Mesoscale Model (NMM).

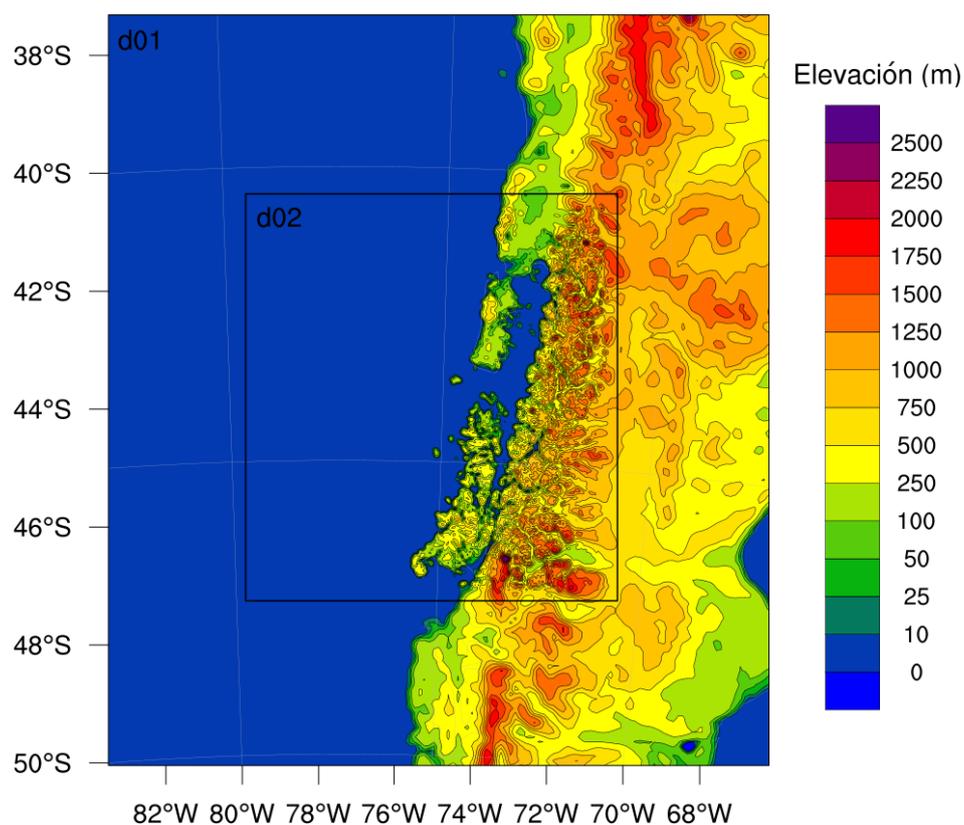
El más utilizado es el núcleo ARW, el cual es compresible, conservativo y no-hidrostático, esto último permite que la fuerza de gradiente de presión no esté en equilibrio con la fuerza de gravedad permitiendo el libre movimiento de las parcelas de aire en la componente vertical, posibilitando así la generación de convección y ascenso orográfico. De este modo, WRF-ARW es capaz de resolver las ecuaciones de la atmósfera implícitamente a través de un sistema de coordenadas euleriano, en donde el observador se encuentra en un punto fijo mirando el movimiento del fluido (Muñoz, 2015; Venegas, 2016).

El modelo incluye una coordenada vertical sigma que sigue el contorno del terreno; una grilla denominada Arakawa-C y un amplio menú de configuraciones y parametrizaciones. Específicamente, el uso de las parametrizaciones físicas se debe a que en la atmósfera existen procesos de pequeña escala como la microfísica de nubes, la radiación, la turbulencia y la convección que no pueden ser representados explícitamente (Skamarock et al., 2008). Por lo tanto, se requiere incluir parámetros físicos que permitan una representación adecuada de estos procesos. Para ello, el modelo WRF ofrece una amplia variedad de parametrizaciones físicas que permiten adaptar la simulación a las condiciones específicas de la zona de estudio y a los objetivos de la investigación.

La selección del forzante atmosférico depende del período temporal que se desee simular, pudiendo ser para el pasado (hindcast), en tiempo real (nowcast) o para el futuro (forecast). En el caso del pasado, se utilizan como condiciones iniciales las salidas de los reanálisis como ERA5 (Hersbach et al., 2020) o FNL (NCEP, 2015). Por otro lado, para los pronósticos se emplean como forzantes las salidas de los modelos globales de predicción, tales como GFS (NCEP, 2015), ECMWF (Ritchie et al., 1995), CFS (Saha et al., 2010), entre otros.

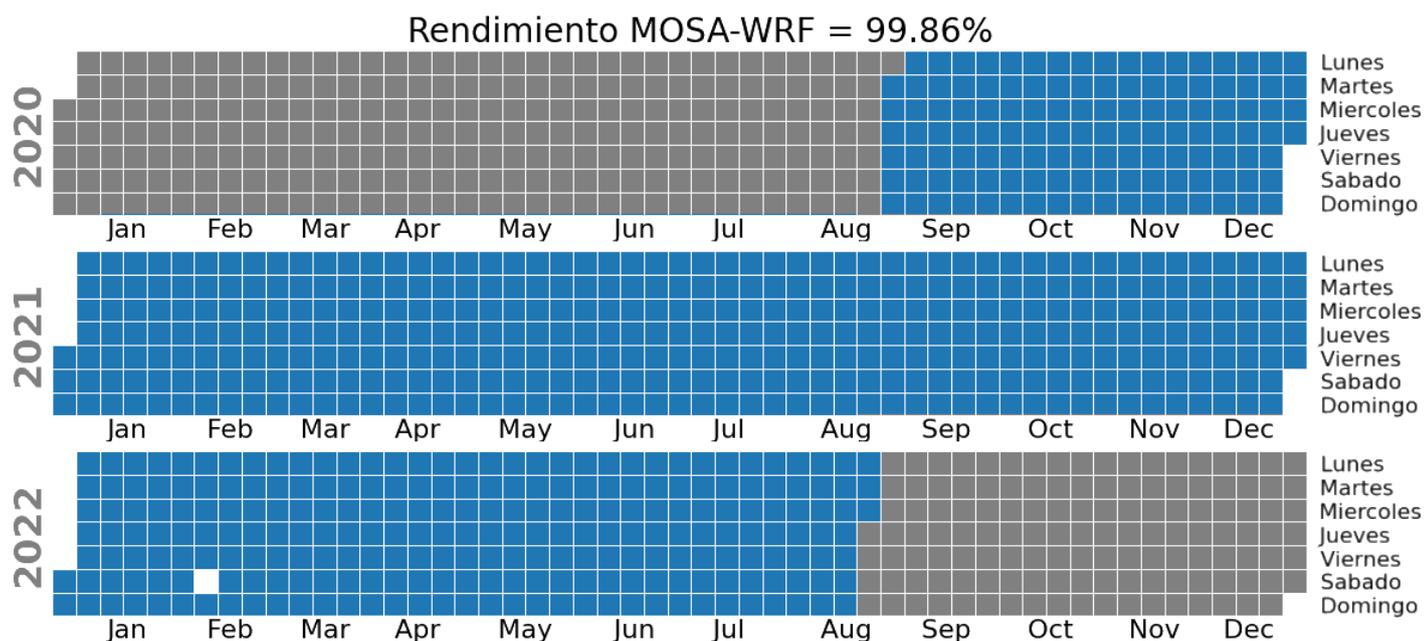
### 1.3. Modelo Operacional Sur-Austral (MOSA)

El Instituto de Fomento Pesquero de Castro ha desarrollado e implementado un modelo operacional de la zona Sur-Austral de Chile denominado MOSA, que cuenta con un sistema de información oceanográfica basado en el modelo CROCO (MOSA-CROCO, Ruiz et al., 2021) y un sistema de información atmosférica basado en el modelo WRF (MOSA-WRF, Artal et al., 2021), permitiendo gestionar la planificación del territorio y el manejo oportuno ante contingencias ambientales. Específicamente, MOSA-WRF es un sistema de pronóstico operacional que está basado en el modelo WRF-ARW V3.9.1 y que entrega proyecciones sinópticas de variables atmosféricas a +96 horas. Posee un dominio anidado centrado en los mares de la región de Los Lagos y de Aysén (**Figura 1.3.1**). Además, se utiliza como forzante para MOSA-CROCO, contribuyendo así con información atmosférica y oceanográfica para los fiordos y canales de la Patagonia chilena.



**Figura 1.3.1:** Modelo de elevación digital de MOSA-WRF. Posee un dominio anidado centrado en la región de Los Lagos y de Aysén. El primer dominio tiene una resolución de 9 km mientras que el segundo una resolución de 3 km.

MOSA-WRF fue implementado el 1 de agosto de 2018 con una resolución de 5 km, que luego de 2 años, el 1 de septiembre de 2020, fue reemplazada y mejorada por una de 3 km, que sigue generando pronósticos hasta la actualidad (**Figura 1.3.2**), observando un alto rendimiento y estabilidad (99.86 %).

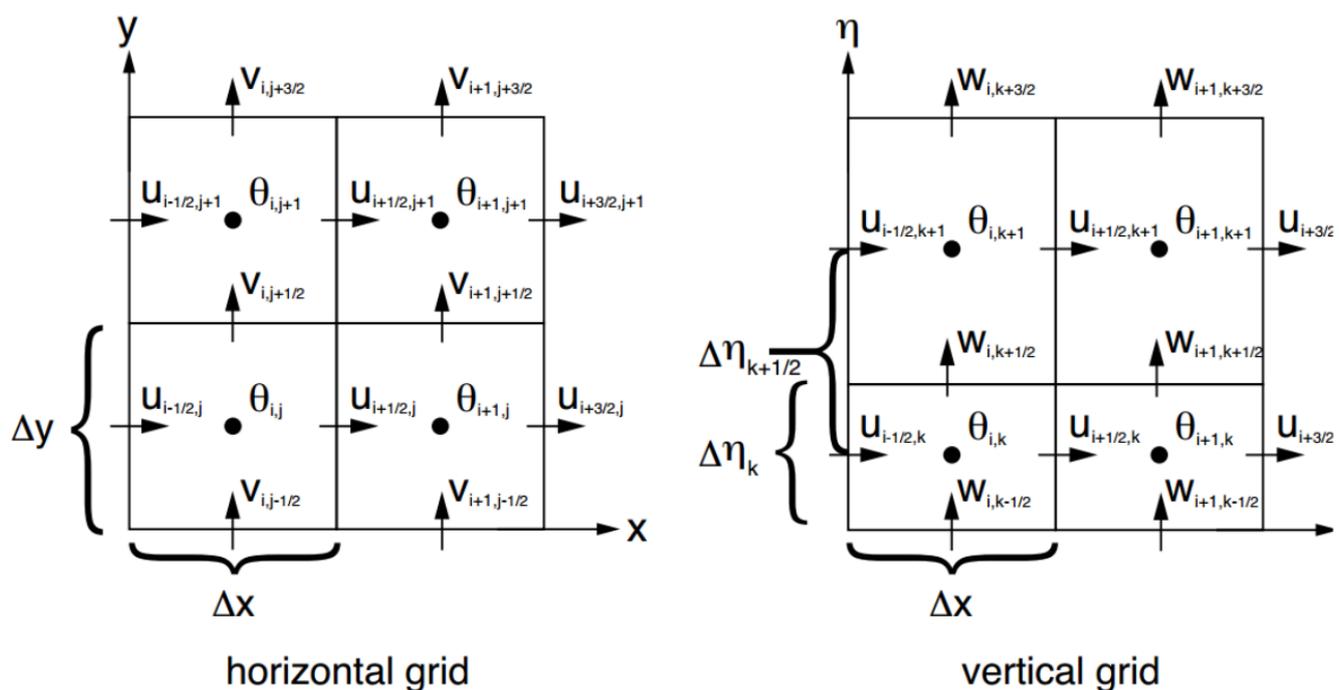


**Figura 1.3.2:** Rendimiento de MOSA-WRF desde que se implementó la resolución de 3 km (septiembre de 2020) hasta la actualidad (agosto de 2022), indicando en color azul si el pronóstico fue exitoso y con un espacio en blanco si el pronóstico presentó algún error en su ejecución. El color gris indica inexistencia de MOSA-WRF. Se observa que el modelo se ha mantenido estable en el tiempo, presentando un 99.86% de efectividad. Figura tomada desde informe técnico IFOP ([Artal et al., 2021](#)).

Para generar los archivos que definen las características geográficas de la zona simulada son necesarios archivos externos como los datos de topografía y uso de suelos (condiciones estáticas), con una resolución de 30" para ambos (900 m). En cuanto a las condiciones iniciales y de borde se utilizan como forzantes el pronóstico del modelo global GFS con una resolución de  $0.25^\circ \times 0.25^\circ$  ( $\sim 25$  km).

Las parametrizaciones físicas utilizadas incluyen el esquema Thompson (Thompson et al., 2008) para la microfísica, el esquema Kain-Fritsch (Kain, 2004) para cumulus\*, el esquema Quasi-normal Scale Elimination (Sukoriansky et al., 2005) para la simulación de turbulencia en la capa límite planetaria, el esquema 5-layer Thermal Diffusion (Dudhia, 1996) para la superficie del terreno, el esquema Dudhia Shortwave (Dudhia, 1989) para la radiación de onda corta y el esquema RRTM Longwave (Mlawer et al., 1997) para la radiación de onda larga. El esquema para cumulus sólo se utiliza en el primer dominio, ya que para dominios menores o iguales a 3 km (como el dominio interior), las nubes convectivas se definen explícitamente\*.

Al momento de resolver las ecuaciones de la atmósfera, el modelo utiliza una grilla denominada Arakawa-C (Arakawa and Lamb, 1981), la cual ubica las componentes de la velocidad horizontal (U y V) y vertical (W) en el punto medio de cada arista que tiene la cuadrícula (Figura 1.3.3) dejando en el centro las variables termodinámicas, de masa y escalares, representadas por  $\theta$ .

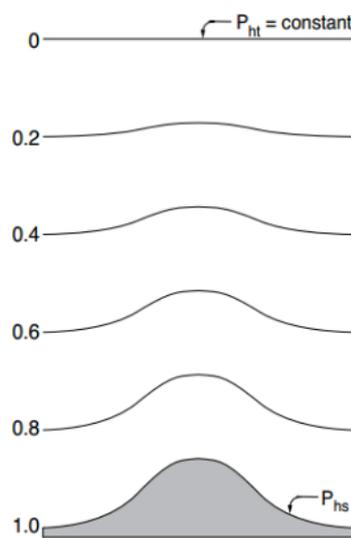


**Figura 1.3.3:** Grilla Arakawa-C (Arakawa and Lamb, 1981) ocupada por el modelo WRF para resolver las ecuaciones que gobiernan la circulación de la atmósfera (Skamarock et al., 2008).

Además, el modelo posee coordenadas verticales denominadas sigma (Skamarock et al., 2008) que siguen el contorno del terreno y que está delimitada en la vertical por una presión constante en el tope de la atmósfera (Figura 1.3.4). El parámetro  $\sigma$  toma valores desde 1 en la superficie hasta 0 en el límite superior del dominio del modelo.

$$\sigma = \frac{P_h - P_{ht}}{P_{hs} - P_{ht}} \in [0, 1] \quad (1.3.1)$$

Donde  $P_{ht}$  corresponde a la presión en el tope de la atmósfera ( $\sim 50$  hPa),  $P_h$  a la presión en cada nivel vertical y  $P_{hs}$  a la presión a nivel del mar (1013,15 hPa).



**Figura 1.3.4:** Coordenada vertical sigma  $\sigma$  que sigue el contorno del terreno (Skamarock et al., 2008).

Las principales características de MOSA-WRF se encuentran resumidas en la Tabla 1.3.1.

Característica	Especificación
Modelo	WRF-ARW V3.9.1
Dimensión (xy)	140x160 <b>D1</b> , 235x259 <b>D2</b>
Resolución horizontal	9 km <b>D1</b> , 3 km <b>D2</b>
Resolución vertical	30 niveles verticales
Resolución topográfica	30 s <b>D1</b> , 30 s <b>D2</b>
Condiciones iniciales y de borde	GFS 0.25° x 0.25°
Paso de tiempo	50 s
Frecuencia de salida	12 h <b>D1</b> , 1 h <b>D2</b>
Proyección	Lambert

**Tabla 1.3.1:** Principales características del dominio anidado de MOSA-WRF.

## 1.4. Técnicas estadísticas de post-procesamiento

La atmósfera es un sistema dinámico no lineal, donde interactúan simultáneamente procesos de distinta escala temporal y espacial, por lo que una pequeña perturbación en las condiciones iniciales puede llevar a grandes diferencias en el estado final (Lorenz, 1963). De esa forma, los modelos atmosféricos se caracterizan principalmente por la sensibilidad a las condiciones iniciales y por la limitación en la predecibilidad del comportamiento futuro. En consecuencia, los pronósticos siempre están sujetos a errores sistemáticos, capaces de ser reducidos en mayor o menor medida, pero inevitables por naturaleza (Misra, 2017).

El error sistemático se puede generar por la incerteza en las condiciones iniciales y/o de borde, es decir, que los datos que inicializan el modelo no logran representar la condición exacta de la atmósfera y/o de la topografía (Paegle et al., 1997; Mass et al., 2002; Hart et al., 2004). También puede ser producido por las parametrizaciones físicas o por las limitaciones de la resolución horizontal, que impiden que determinados procesos de pequeña escala sean representados explícitamente (Palmer and Hagedorn, 2006). Por lo tanto, a lo largo del tiempo se han implementado diversas técnicas para corregir el sesgo de las simulaciones, las cuales se basan en establecer relaciones empíricas entre la variable observada y el pronóstico numérico para un lugar en específico.

MOS (Model Output Statistics) se define como un conjunto de técnicas estadísticas de post-procesamiento utilizadas para mejorar la capacidad de predicción de los modelos numéricos (Glahn and Lowry, 1972; Carter et al., 1989). En este caso, se trata de una regresión lineal múltiple que corrige el sesgo de los pronósticos en un lugar específico en base a observaciones obtenidas de estaciones meteorológicas (Kalnay, 2003; Dennstaedt, 2008). Esta regresión múltiple se resuelve con el método de mínimos cuadrados ordinarios (OLS) y asume que los residuos/errores son independientes, con varianza constante (homocedastidad) y con distribución normal. Cuando el modelo de regresión lineal múltiple cumple los supuestos, se estiman coeficientes insesgados, que tienden a estar relativamente cerca de los valores observados, minimizando así la varianza.

En la práctica, estas condiciones no se cumplen siempre, lo que hace necesario disponer de métodos de ajuste alternativos. Algunos de ellos son: mínimos cuadrados ponderados, mínimos cuadrados generalizados y regresión robusta.

### **Mínimos cuadrados ponderados**

La regresión por mínimos cuadrados ponderados (Liao et al., 2021) es un tipo de regresión lineal que se utiliza cuando la varianza de los residuos no es constante (heteroscedasticidad), en donde a cada residuo se le asigna un peso proporcional al recíproco de su varianza. De esa forma, las ponderaciones se utilizan para que al momento de determinar los coeficientes de regresión, se le de más importancia a los datos con menor varianza y menos importancia a los datos con mayor varianza, obteniendo así estimaciones más precisas y eficientes.

### **Mínimos cuadrados generalizados**

La regresión por mínimos cuadrados generalizados (Söderström, 1974) es un tipo de regresión lineal que se utiliza cuando existe correlación entre los residuos. Esto ocurre con frecuencia en series temporales. En esta regresión se asume que los residuos siguen una distribución normal multivariada para describir la correlación entre los términos del error. Permite hacer ponderaciones de forma similar a la regresión por mínimos cuadrados ponderados, y no sólo ajustar la varianza de los residuos sino que también la estructura de correlación. Este método es de utilidad cuando se trabajan con estructuras de datos complejas o longitudinales, donde se suele tener correlación entre los residuos o varianza no constante.

### **Regresión robusta**

La regresión robusta es un tipo de regresión lineal que está diseñada para ser menos sensible a los valores extremos (Herzog and Vogel, 2012), ya que cuando los residuos no siguen una distribución normal, los resultados obtenidos por mínimos cuadrados se ven afectados. Una solución simple es eliminar los valores atípicos (outliers). Sin embargo, de confirmarse que no son errores de lectura, el modelo debería incluirlos puesto que son parte del fenómeno que se quiere estudiar. Los dos tipos de regresión robusta más empleados son M-estimation y mínimos cuadrados recortados.

---

El M-estimation (Yang et al., 2018) es un tipo de estimación de máxima verosimilitud que define una función de costo para determinar los coeficientes de regresión, y se obtiene de la diferencia entre los valores observados y los valores predichos por la variable respuesta. Esta función lineal está diseñada para ser menos sensible a los valores atípicos que la función de error cuadrático utilizada en la regresión lineal estándar.

Una función comúnmente utilizada es la función de costo de Huber (Huber, 1981), que combina el error cuadrático de los residuos pequeños con una función lineal para residuos grandes. Esta función asigna menos peso a los valores atípicos que la función de error cuadrático, lo que la hace más robusta a los valores extremos. Otro estimador comúnmente utilizado para la regresión robusta es la función de costo de Tukey (Huber, 1981), que asigna un peso cero a los residuos que superan un determinado umbral y utiliza una función cuadrática para los residuos dentro del umbral.

Por su parte, la regresión por mínimos cuadrados recortados (Rousseeuw, 1984) identifica un subconjunto de datos que se ajustan mejor a las observaciones y calcula los coeficientes de regresión a partir de ese subconjunto. Al recortar los valores extremos, se logra reducir la influencia de los valores atípicos y otras fuentes de no normalidad en los datos. De esa forma, existe una gran variedad de métodos estadísticos, donde lo más importante es balancear adecuadamente entre simplicidad del modelo, costo computacional y que las condiciones para la regresión se cumplan dependiendo del modelo a utilizar, para que los coeficientes obtenidos sean los más apropiados.

Diversos estudios han demostrado el beneficio de aplicar MOS, mostrando mejoras significativas en los pronósticos de energía eólica (Lazić et al., 2014), de energía solar (Diagne et al., 2014; Pierro et al., 2015) e incluso en pronósticos de calidad de aire (Petetin et al., 2021; Sánchez et al., 2018). Además, existe una extensión denominada Gridded MOS (Ruth et al., 2009; Shin, 2019) que se forma a partir de una red de estaciones meteorológicas y su propósito es obtener un pronóstico grillado para una región extensa. Mientras más estaciones operativas se utilicen, mejor será el rendimiento de GMOS. Esta técnica se ha ocupado en pronósticos de radiación (Oosthuizen et al., 2020), de precipitación (Charba, 2011) y de intensidad del viento (Scheuerer and Möller, 2015; Che et al., 2016).

---

La desventaja de MOS es que cualquier inestabilidad en el modelo (versión, resolución o parametrizaciones físicas) puede provocar efectos adversos, como fue en el caso del sistema de pronóstico RAFS (Regional Analysis and Forecast System) desarrollado por el Centro Meteorológico Nacional (NMC) (Hoke et al., 1998), al cual se le aplicó un MOS y no tuvo el rendimiento esperado ya que por la inestabilidad generó un pronóstico menos preciso (Erickson et al., 1991). Por lo tanto, para que MOS funcione de forma óptima es importante que el modelo se mantenga estable en el tiempo (Kalnay, 2003).

El método ensamble permite determinar la incertidumbre de las predicciones a través de la comparación de un conjunto de simulaciones las cuales se configuran con diferentes parametrizaciones físicas por lo que esta técnica requiere de muchos recursos computacionales (Matsueda et al., 2007; Rixen et al., 2009; Zhao et al., 2016; Pistoia et al., 2016; Schaake et al., 2007; Wu et al., 2011). Sin embargo, sigue vigente y de hecho se ha combinado con MOS, permitiendo así calibrar de mejor forma los pronósticos (Wilks and Hamill, 2007; Veenhuis, 2013).

Otra limitación de MOS es la necesidad de contar con datos por un periodo extenso de tiempo. No obstante, existen otros métodos con el mismo propósito que no requieren de datos históricos, como es el caso del Filtro de Kalman (Kalman, 1960; Kalman and Bucy, 1961) que utiliza mediciones para obtener nuevas y mejoradas condiciones iniciales, logrando así un estado inicial de la atmósfera más exacto y preciso (Courtier et al., 1998; Sugimoto et al., 2009), contribuyendo a un mejor pronóstico a corto plazo. Esta rama de las ciencias se denomina *asimilación de datos* (Huang et al., 2009; Barker et al., 2004).

# Capítulo 2

## Objetivos

### 2.1. Objetivo general

El objetivo general es implementar una técnica estadística (MOS) para mejorar las predicciones de temperatura superficial del pronóstico operacional MOSA-WRF.

### 2.2. Objetivos específicos

Los objetivos específicos son:

1. Corregir el sesgo del pronóstico histórico (con resolución de 3 km) de temperatura máxima y mínima en Cucao y Melinka, utilizando una regresión lineal múltiple y mediciones de estaciones meteorológicas.
2. Analizar el desempeño de MOS para los eventos extremos de temperatura.
3. Evaluar la factibilidad de implementar el método de forma operacional y realizar una prueba de sensibilidad para el entrenamiento.

## Capítulo 3

# Metodología

### 3.1. Datos

#### 3.1.1. Estaciones meteorológicas

Para poder calibrar el pronóstico de temperatura en un lugar específico es fundamental tener una serie de tiempo observada lo suficientemente extensa. Las mediciones fueron obtenidas de estaciones meteorológicas implementadas por el IFOP, instaladas en Cucao y Melinka (Tabla 3.1.3).

Estación	Longitud [° O]	Latitud [° S]	Elevación [m.s.n.m.]	Fuente
CUCAO	74.123	42.601	7	IFOP
MELINKA	73.746	43.897	7	IFOP

**Tabla 3.1.1:** Estaciones meteorológicas utilizadas en este estudio.

Los datos observados se pueden obtener desde la herramienta web REDMET (<http://chonos.ifop.cl/redmet/>), disponible en el sistema de información oceanográfica CHONOS (Reche et al., 2021) de donde también se pueden exportar otras variables como presión atmosférica, dirección e intensidad del viento, precipitación, humedad relativa y radiación solar, en estas y otras estaciones meteorológicas (Faro Corona, Isla Apiao, Isla Tranqui).

Los sensores utilizados en las estaciones meteorológicas se especifican en la Tabla 3.1.2.

Variable	Sensores
Temperatura	S-THB-M002
Presión atmosférica	S-BPB-CM50
Viento	Veleta YOUNG 05106
Humedad Relativa	S-THB-M008
Precipitación	Pluviómetro HOBO S-RGB-M006
Radiación solar	S-LIB-M003 Solar Radiation (Silicon Pyranometer)
Luz PAR	S-LIA-M003 Photosynthetic Light

**Tabla 3.1.2:** Sensores de las estaciones meteorológicas instaladas en Cucao y Melinka por el IFOP. Ambas estaciones cuentan con un Datalogger HOBO RX3000.

REDMET permite seleccionar una resolución temporal diaria, horaria o con un intervalo de 10 minutos, y calcular diferentes estadísticos. En este caso se utilizaron datos diarios de temperatura máxima y mínima desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022 (n=699 datos diarios) para poder corregir el pronóstico simulado en los 2 sitios de interés.

Con respecto al control de calidad de los datos, se visualiza si existen valores escapados (outliers) y datos erróneos o sospechosos, y se verifica que las fechas estén correctas.

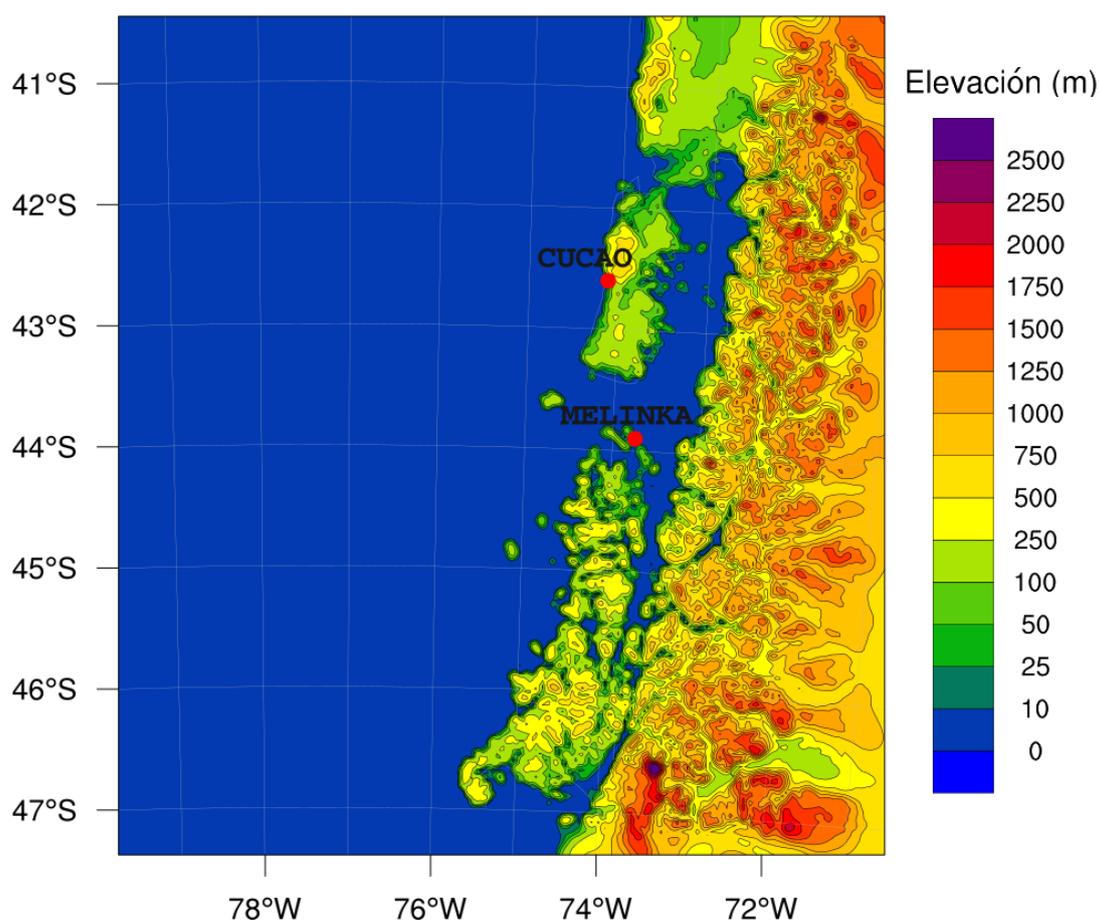
Estación	N° datos sospechosos	N° datos erróneos	Periodo
CUCAO	0	0	01-09-2020 - 01-08-2022
MELINKA	0	0	01-09-2020 - 01-08-2022

**Tabla 3.1.3:** Datos sospechosos o erróneos de las mediciones obtenidas en Cucao y Melinka. El periodo considera una serie de tiempo sin datos faltantes.

El periodo de evaluación se cortó a inicios de agosto de 2022 para que de esa manera se trabaje con una serie de tiempo sin datos faltantes, ya que el 17 de agosto de 2022 las estaciones meteorológicas dejaron de hacer mediciones debido a problemas técnicos.

### 3.1.2. MOSA-WRF

Los datos de temperatura simulados se obtienen del sistema de pronóstico operacional MOSA-WRF (<http://chonos.ifop.cl/mosa/>). Las series de tiempo para Cucao y Melinka (**Figura 3.1.1**) se construyen desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022 considerando las primeras 24 horas de pronóstico de cada día y luego se calcula la máxima y mínima diaria (n=699).



**Figura 3.1.1:** Modelo de elevación digital (DEM) del dominio interior (d02) junto con la ubicación de las estaciones meteorológicas.

Además de temperatura pronosticada, se utilizan los máximos y mínimos diarios de otras variables simuladas (válidas para el mismo tiempo), como presión atmosférica y la componente zonal y meridional del viento, que contribuirán como variables auxiliares para corregir el sesgo del pronóstico.

## 3.2. MOS (Model Output Statistics)

Este método consiste en utilizar una regresión lineal múltiple para obtener coeficientes que ajusten el pronóstico meteorológico de MOSA-WRF. En las siguientes secciones se plantea el formalismo matemático que permite construir la regresión lineal múltiple y resolverla matricialmente como un problema inverso.

### 3.2.1. Regresión lineal múltiple

La regresión lineal simple permite estimar una variable dependiente y a partir de la variable independiente  $x$  a través de la ecuación  $y = ax + b$ . En la regresión lineal múltiple, al igual que en el caso de la regresión lineal simple, existe una variable dependiente. Sin embargo, existe más de una variable independiente (predictores) (Wilks, 1995) por lo que los valores de la variable dependiente se generan a partir de una combinación lineal de múltiples variables independientes. Entonces, siendo  $j$  el número de variables independientes, la ecuación de regresión lineal múltiple se define como:

$$y_n = b_0 + b_1x_{n1} + b_2x_{n2} + \dots + b_jx_{nj} \quad (3.2.1)$$

Donde los predictores  $x_{nj}$  son las variables simuladas por el modelo (temperatura, presión, viento, etc.) para un punto en específico y válidas para un tiempo  $t_n$ , mientras que  $y_n$  son las observaciones de la variable que se quiere calibrar, válida para el mismo tiempo  $t_n$ . Por último,  $b_0, b_1, \dots, b_j$  son los coeficientes de regresión.

$$y_n = y(t_n) \quad n = 1, \dots, N \quad (3.2.2)$$

$$x_{nj} = x_j(t_n) \quad n = 1, \dots, N; j = 1, \dots, J \quad (3.2.3)$$

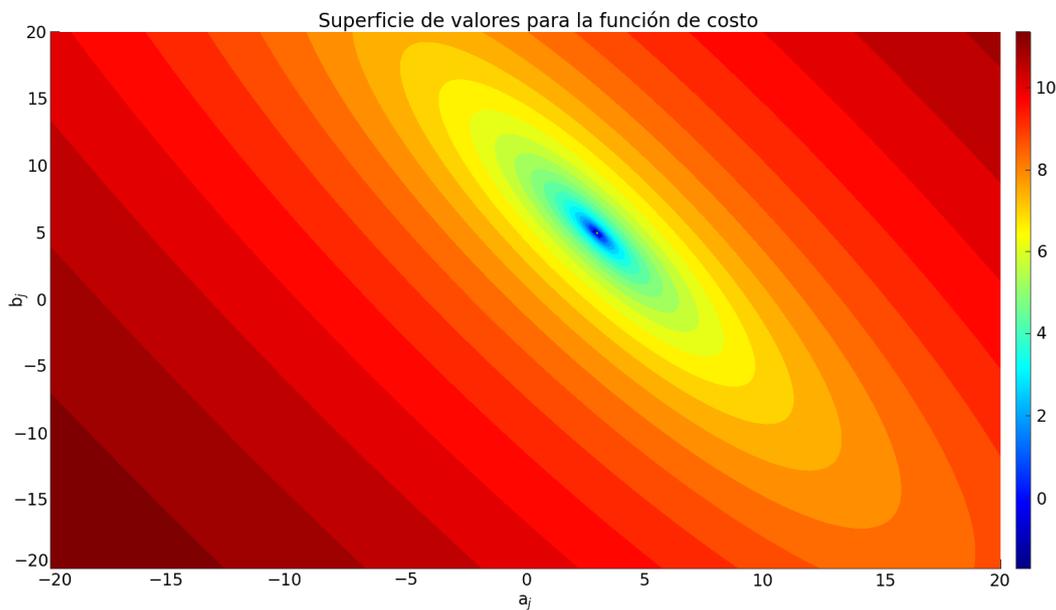
Es importante mencionar que en una regresión lineal los coeficientes de regresión  $b_j$  se determinan con el método de mínimos cuadrados, es decir, minimizando la suma de los residuos al cuadrado ( $SSE$ ) durante el periodo de entrenamiento (Wilks, 1995).

$$SSE = \sum_{n=1}^N (y_n - \hat{y}_n)^2 \quad (3.2.4)$$

También se conoce como función de costo (**Figura 3.2.1**), donde se deriva  $SSE$  con respecto a  $b_j$  y se iguala a 0, minimizando así la varianza.

$$\frac{\delta SSE}{\delta b_j} = 0 \implies \sum_{n=1}^N (y_n - \sum_{j=0}^J b_j x_{nj}) x_{nj} = 0 \quad j = 0, 1, \dots, J \quad (3.2.5)$$

$$\implies \sum_{n=1}^N \left[ x_{jn}^T y_n - x_{jn}^T \sum_{j=0}^J x_{nj} b_j \right] = 0 \quad x_{jn}^T = x_{nj} \quad (3.2.6)$$



**Figura 3.2.1:** Superficie de valores para la función de costo.

Las ecuaciones obtenidas en (3.2.6) son las ecuaciones de una regresión lineal múltiple que determinan los coeficientes de regresión  $b_j$ , con  $j = 0, 1, \dots, J$  a través del método de mínimos cuadrados. Computacionalmente, obtener los coeficientes de forma matricial es más eficiente, y se puede escribir como:

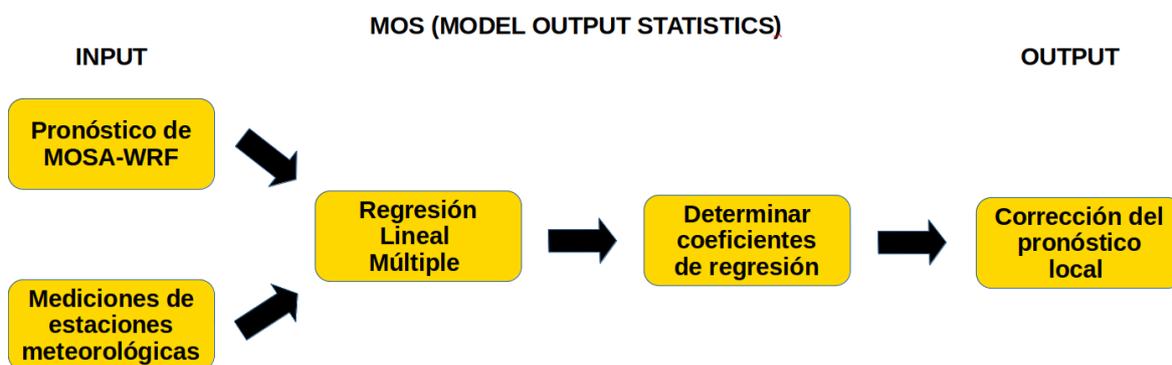
$$\mathbf{X}^T \mathbf{X} \mathbf{b} = \mathbf{X}^T \mathbf{y} \quad (3.2.7)$$

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & \dots & x_{1J} \\ 1 & x_{21} & \dots & x_{2J} \\ \vdots & \vdots & x_{nj} & x_{3J} \\ 1 & x_{N1} & \dots & x_{NJ} \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_J \end{bmatrix} \quad (3.2.8)$$

Donde  $X$  es la matriz de predictores (variables simuladas por MOSA),  $y$  son las mediciones (estaciones meteorológicas) y  $b$  son los coeficientes de regresión, siendo estos últimos los que se deben determinar multiplicando por la matriz inversa  $(X^T X)^{-1}$ , de la siguiente forma:

$$b = (X^T X)^{-1} X^T y \quad (3.2.9)$$

Logrando así obtener los coeficientes de regresión que corrigen el pronóstico local. De esa forma, obtenemos la definición matricial para el pronóstico ajustado como  $\hat{y} = Xb$  y para el error del ajuste como  $\epsilon = y - \hat{y}$ . En la **Figura 3.2.2** se muestra un diagrama de flujo de MOS.



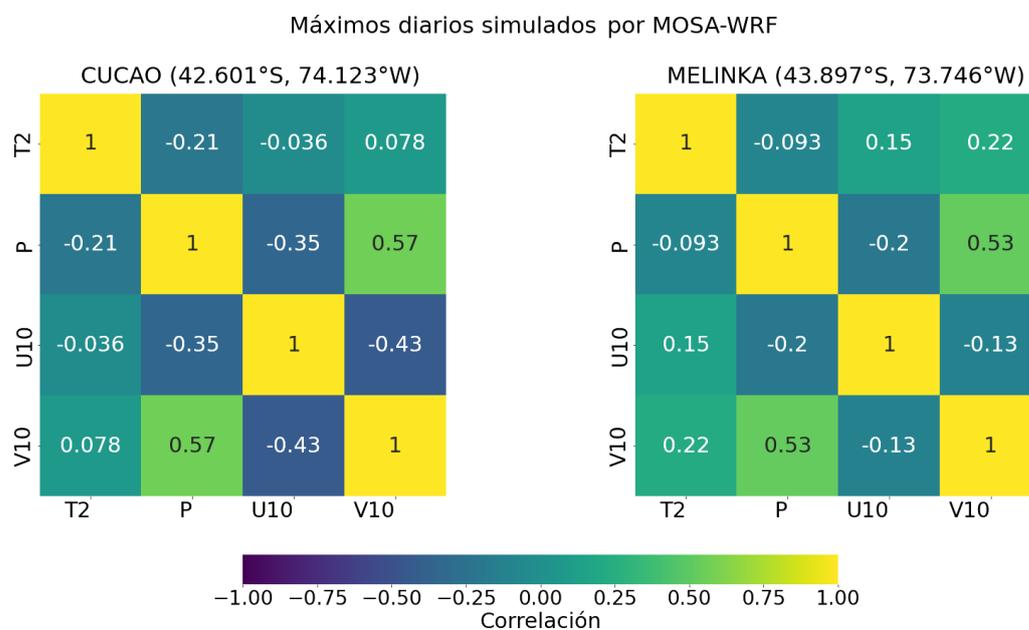
**Figura 3.2.2:** Diagrama de flujo de MOS (Model Output Statistics).

### 3.2.2. Forward selection

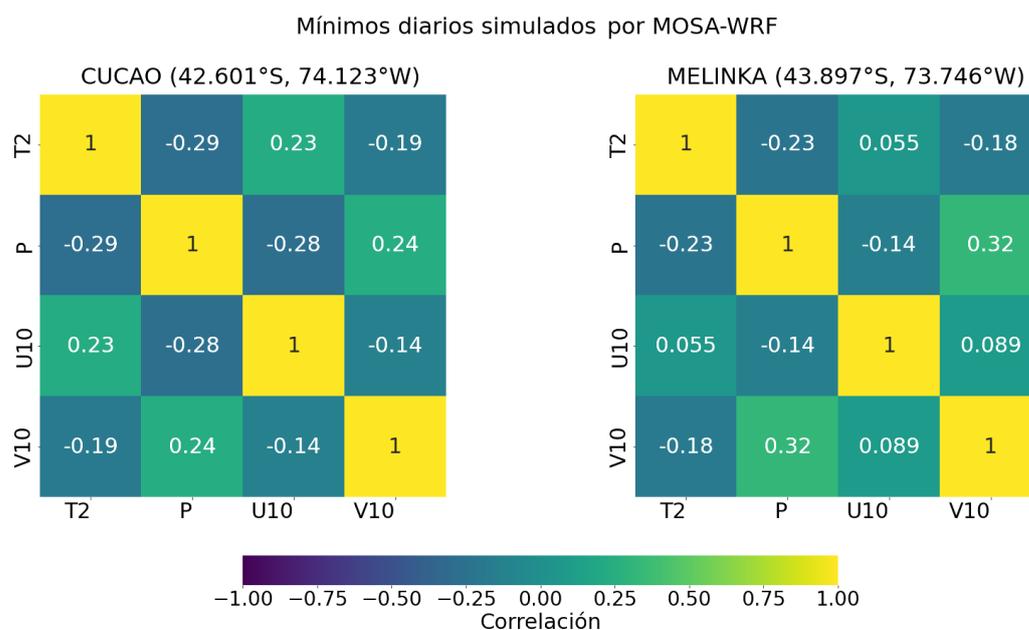
Generalmente, existen más variables independientes de las que pueden ser utilizadas en un método de predicción estadístico. Además, el proceso de selección de las variables adecuadas no es trivial. En el caso de MOS, los predictores se eligen a través de un procedimiento conocido como forward selection (Wilks, 1995).

En este punto, se asume que se cuenta con un conjunto de variables independientes (predictores) para generar una regresión lineal múltiple. Dicho conjunto incluye solamente variables con relevancia física y a través de una matriz de correlación descartamos las variables independientes que están altamente correlacionadas ( $r \geq 0.6$ ) para evitar información redundante.

En la **Figura 3.2.3** y **Figura 3.2.4** se muestran los mapas de correlación de los máximos y mínimos diarios simulados por MOSA-WRF. Todas las potenciales variables cumplen con la condición de no linealidad entre predictores ( $r < 0.6$ ).



**Figura 3.2.3:** Matriz de correlación para los máximos diarios simulados por MOSA-WRF. Las variables son: temperatura del aire a 2 metros (T2), presión atmosférica (P), y la componente zonal (U10) y meridional del viento (V10).



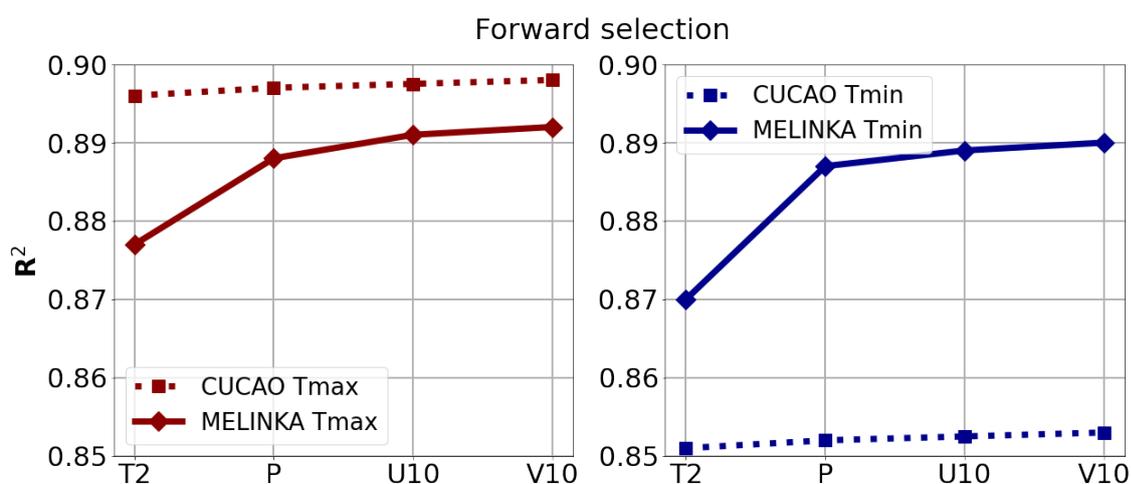
**Figura 3.2.4:** Matriz de correlación para los mínimos diarios simulados por MOSA-WRF. Las variables son: temperatura del aire a 2 metros (T2), presión atmosférica (P), y la componente zonal (U10) y meridional del viento (V10).

Un ejemplo del método forward selection es:

1. Sean  $J$  variables independientes. El procedimiento de selección se inicia suponiendo  $j = 0$ , es decir  $y = b_0$ .
2. Sea  $j = 1$ . Esto significa que  $y = b_0 + b_1x_1$ . El uso del subíndice  $j$  en la variable independiente quiere decir que se deberá realizar el análisis de ajuste lineal simple con cada una de las variables independientes; aquella que presente el mejor ajuste es seleccionada.
3. Sea  $j = 2$ . Esto significa que  $y = b_0 + b_1x_1 + b_2x_2$ ; igual que el paso anterior, se determina la mejor curva de ajuste.
4. Repetir el paso anterior.

Un método alternativo se denomina backward selection, el cual es análogo al forward selection pero en orden inverso.

De las potenciales variables predictoras que se tienen: temperatura del aire a 2 metros (T2), presión superficial (P), y la componente zonal (U10) y meridional (V10) del viento, se decide seleccionar las 4, ya que haciendo el Forward selection, todas cumplen con que cada vez que se agrega una variable predictor, el coeficiente de determinación aumenta (**Figura 3.2.5**), aunque es más evidente en Melinka que en Cucao.



**Figura 3.2.5:** Forward selection: método de selección de variables simuladas (predictores) para la regresión lineal múltiple.

De esa forma, la regresión lineal múltiple que se utiliza es:

$$T2_{OBS} = b_0 + b_1 \cdot T2_{WRF} + b_2 \cdot P_{WRF} + b_3 \cdot U10_{WRF} + b_4 \cdot V10_{WRF} \quad (3.2.10)$$

Donde las últimas 3 variables predictoras ajustarán, junto con las mediciones, el pronóstico de temperatura ( $T2_{WRF}$ ).

Finalmente, sólo queda determinar  $b_0$ ,  $b_1$ ,  $b_2$ ,  $b_3$  y  $b_4$ .

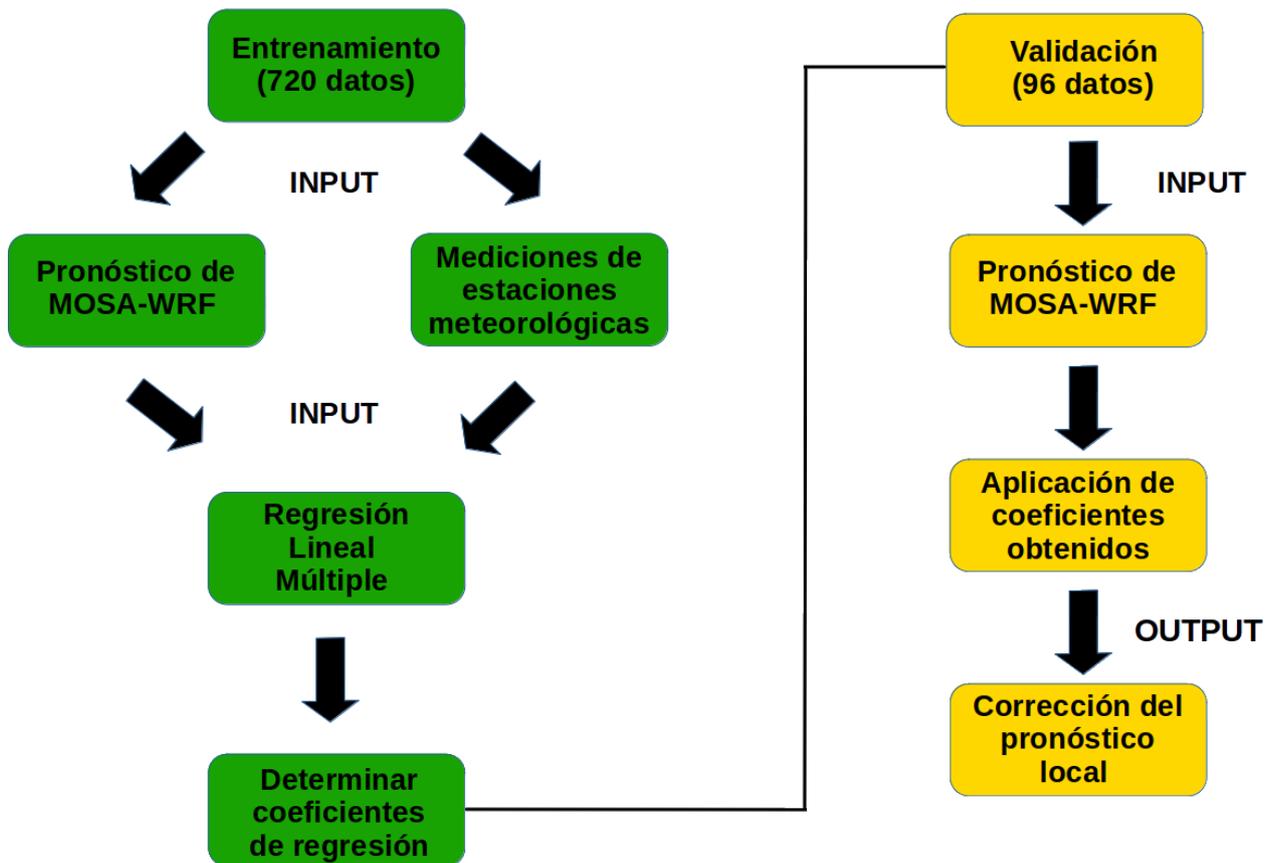
### 3.2.3. Cross validation

En el caso de que se quieran aplicar los coeficientes de regresión obtenidos a nuevos datos simulados, la mejor forma de evaluar MOS es realizando una validación cruzada, es decir, entrenando el modelo con una parte de los datos, obteniendo así los coeficientes, y luego aplicándolos a nuevas predicciones.

Aquí, como en cualquier regresión estadística, mientras más datos se utilicen para el entrenamiento, mejor van a ser los resultados, aunque se debe tener cuidado con sobreajustar el modelo (overfitting).

Se realizó una prueba de sensibilidad considerando los respectivos últimos 30 días como entrenamiento (720 datos horarios), y los coeficientes fueron aplicados en el pronóstico de temperatura de 96 horas que MOSA-WRF genera cada día. De esa forma, el porcentaje de la validación cruzada se divide en 88% de los datos para el entrenamiento y 12% de los datos para la evaluación (**Figura 3.2.6**).

## Validación cruzada para MOS operacional



**Figura 3.2.6:** Validación cruzada para MOS operacional. Se utilizan 720 datos horarios (88% de los datos) para entrenar el modelo y luego se le aplican los coeficientes obtenidos a las 96 horas de pronóstico (12% de datos restante).

### 3.3. Estadísticos empleados para la validación

En primer lugar se hace una comparación entre el pronóstico de MOSA y los datos observados, para luego, en base a esto, poder hacer una evaluación cuantitativa del desempeño de MOS. Los estadísticos utilizados fueron los siguientes:

#### 3.3.1. Sesgo (BIAS):

Entrega el error sistemático entre lo pronosticado ( $P$ ) y lo observado ( $O$ ), es decir, mide la fiabilidad del modelo. Si el sesgo es positivo, las simulaciones sobreestiman las observaciones y si el sesgo es negativo, la subestiman. El valor ideal es 0 (Pielke, 1984).

$$BIAS = \frac{1}{n} \sum_{i=1}^n (P - O) \quad (3.3.1)$$

#### 3.3.2. Raíz del error cuadrático medio (RMSE):

Entrega el error total (absoluto) entre lo pronosticado ( $P$ ) y lo observado ( $O$ ). Mientras menor sea el RMSE, mejor será el ajuste. Sin embargo, la presencia de valores extremos (outliers) puede dar como resultado un mayor RMSE (Willmott and Matsuura, 2005).

$$RMSE = \left[ \frac{1}{n} \sum_{i=1}^n (P - O)^2 \right]^{1/2} \quad (3.3.2)$$

#### 3.3.3. Coeficiente de correlación (r):

Es una medida que indica el grado de relación que tienen dos variables. Entrega la fase que existe entre ellos. Se define como el cociente entre la covarianza de lo simulado ( $P$ ) y lo observado ( $O$ ) y el producto de las desviaciones estándar de cada variable. El valor ideal es 1 (100%).

$$r = \frac{\text{cov}(P, O)}{\text{std}(P) \cdot \text{std}(O)} = \frac{\sum_{i=1}^n (P - \bar{P})(O - \bar{O})}{\sum_{i=1}^n (P - \bar{P}) \sum_{i=1}^n (O - \bar{O})} \quad (3.3.3)$$

### 3.3.4. Coeficiente de determinación ( $R^2$ ):

Indica qué tan bien las variables independientes explican la varianza de la variable dependiente. Se puede calcular como el cuadrado del coeficiente de correlación de Pearson. El valor ideal es 1 (100%).

$$R^2 = \left( \frac{\text{cov}(P, O)}{\text{std}(P) \cdot \text{std}(O)} \right)^2 = \left( \frac{\sum_{i=1}^n (P - \bar{P})(O - \bar{O})}{\sum_{i=1}^n (P - \bar{P}) \sum_{i=1}^n (O - \bar{O})} \right)^2 \quad (3.3.4)$$

### 3.3.5. Cociente entre las desviaciones estándar:

Indica si el modelo está sobreestimando o subestimando la amplitud de las mediciones. Se calcula como el cociente entre la desviación estándar de los datos simulados y la desviación estándar de los datos observados. Si el valor está entre 0 y 1 hay una subestimación, si el valor es  $> 1$  hay una sobreestimación, y si el valor es  $= 1$ , la amplitud de los datos simulados es igual a la de los datos observados.

$$\frac{\text{desviación estándar (P)}}{\text{desviación estándar (O)}} = \frac{\sum_{i=1}^n (P - \bar{P})}{\sum_{i=1}^n (O - \bar{O})} \quad (3.3.5)$$

### 3.3.6. Significancia:

Uno de los primeros resultados que hay que evaluar al ajustar un modelo es la significancia. Se emplea un test de hipótesis con intervalo de confianza al 95% para obtener los p-value del modelo y de cada uno de los predictores. Si los valores obtenidos son  $< 0.05$ , las variables independientes son significativas en explicar la varianza de la variable dependiente. Estos resultados se obtienen al generar la regresión lineal múltiple con statsmodels ([Seabold and Perktold, 2010](#)).

### 3.3.7. Monte-Carlo:

El método de Monte-Carlo ([Mooney, 1997](#)) es un procedimiento donde se generan 10000 iteraciones para remuestrear datos al azar, pudiendo almacenar el resultado de los estadísticos de cada iteración y graficar la distribución de lo simulado.

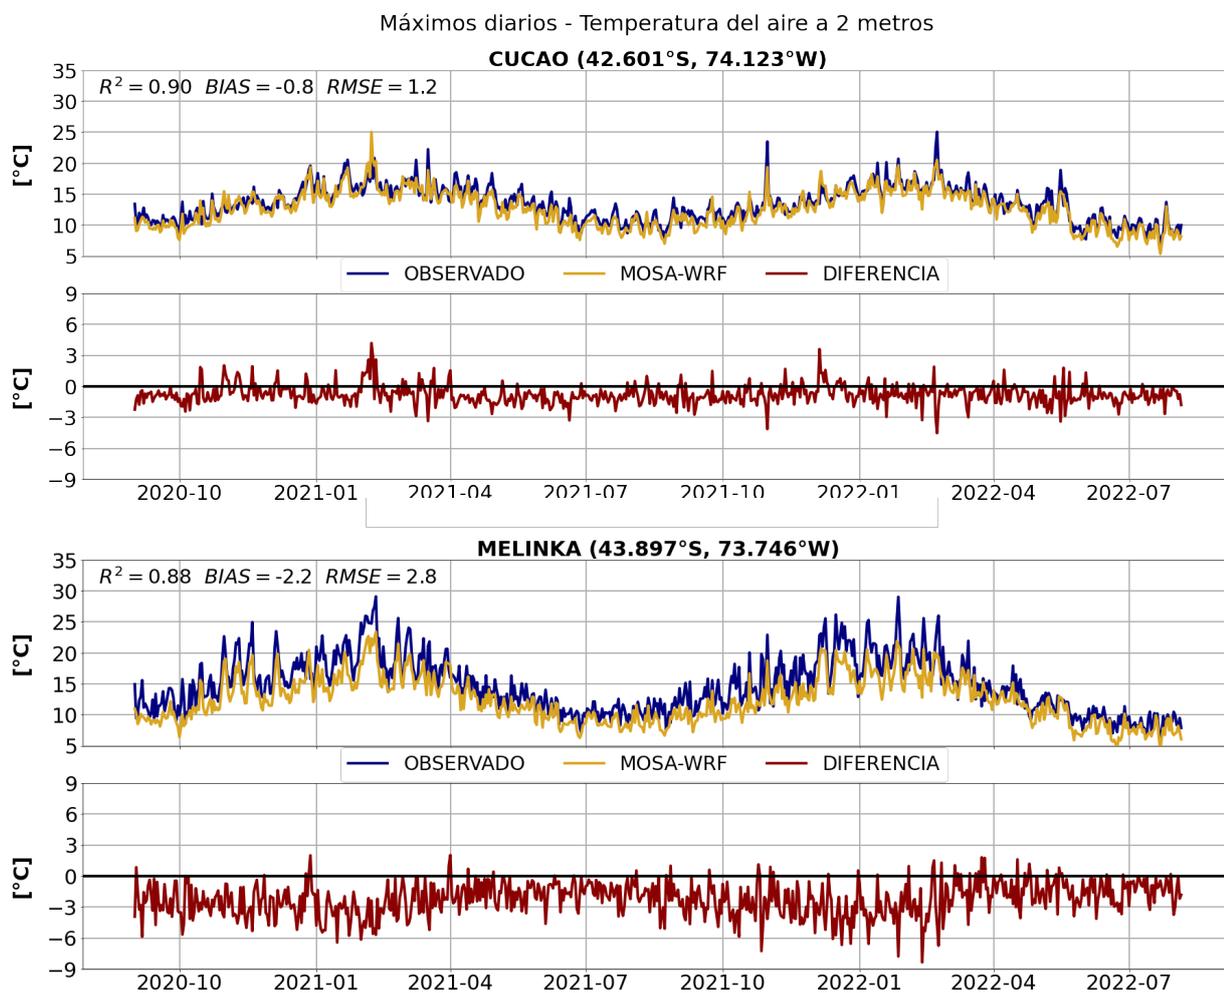
## Capítulo 4

### Resultados

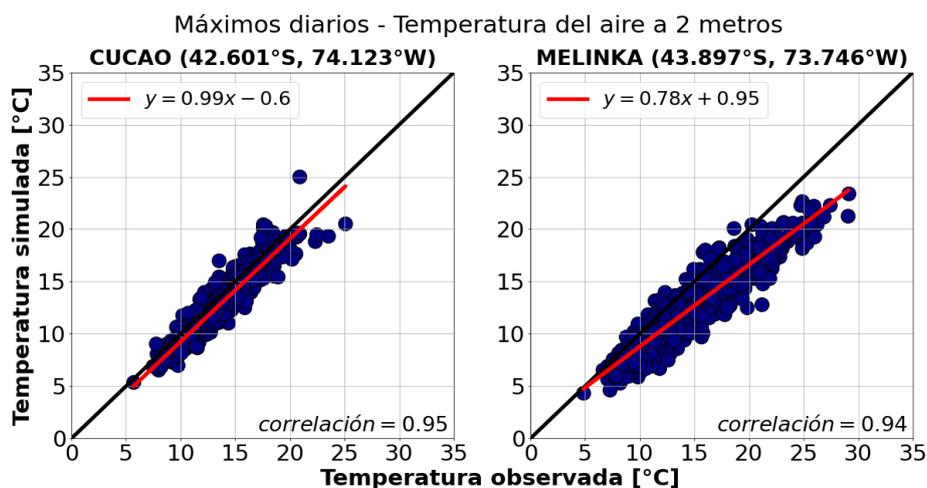
#### 4.1. Temperatura máxima histórica (MOSA-WRF)

En primer lugar, se realiza una comparación estadística del pronóstico de temperatura máxima (diaria) generado por MOSA-WRF con respecto a las observaciones, considerando las series temporales desde septiembre de 2020 hasta agosto de 2022. Se logra apreciar un buen ajuste en Cucao y Melinka, con coeficientes de determinación ( $R^2$ ) que alcanzan valores de 0.90 y 0.88, respectivamente. Además, en ambas estaciones se observa una subestimación sistemática de la temperatura máxima, la cual es más intensa y persistente en Melinka, alcanzando diferencias de hasta  $-8\text{ }^{\circ}\text{C}$  en la época de verano, mientras que en Cucao el error no supera los  $-5\text{ }^{\circ}\text{C}$  y en general, se mantiene por debajo de los  $3\text{ }^{\circ}\text{C}$  de diferencia (**Figura 4.1.1**).

Por otro lado, la representación gráfica más útil para describir el comportamiento conjunto de dos variables es el diagrama de dispersión. En este caso, se busca analizar si existe relación entre la temperatura máxima observada y pronosticada en los 2 lugares de interés. Para Cucao la curva ajustada a los datos corresponde a  $y=0.99x-0.6$  y para Melinka corresponde a  $y=0.78x+0.95$ , mostrando una correlación positiva muy alta, de 95 % y 94 %, respectivamente (**Figura 4.1.2**).



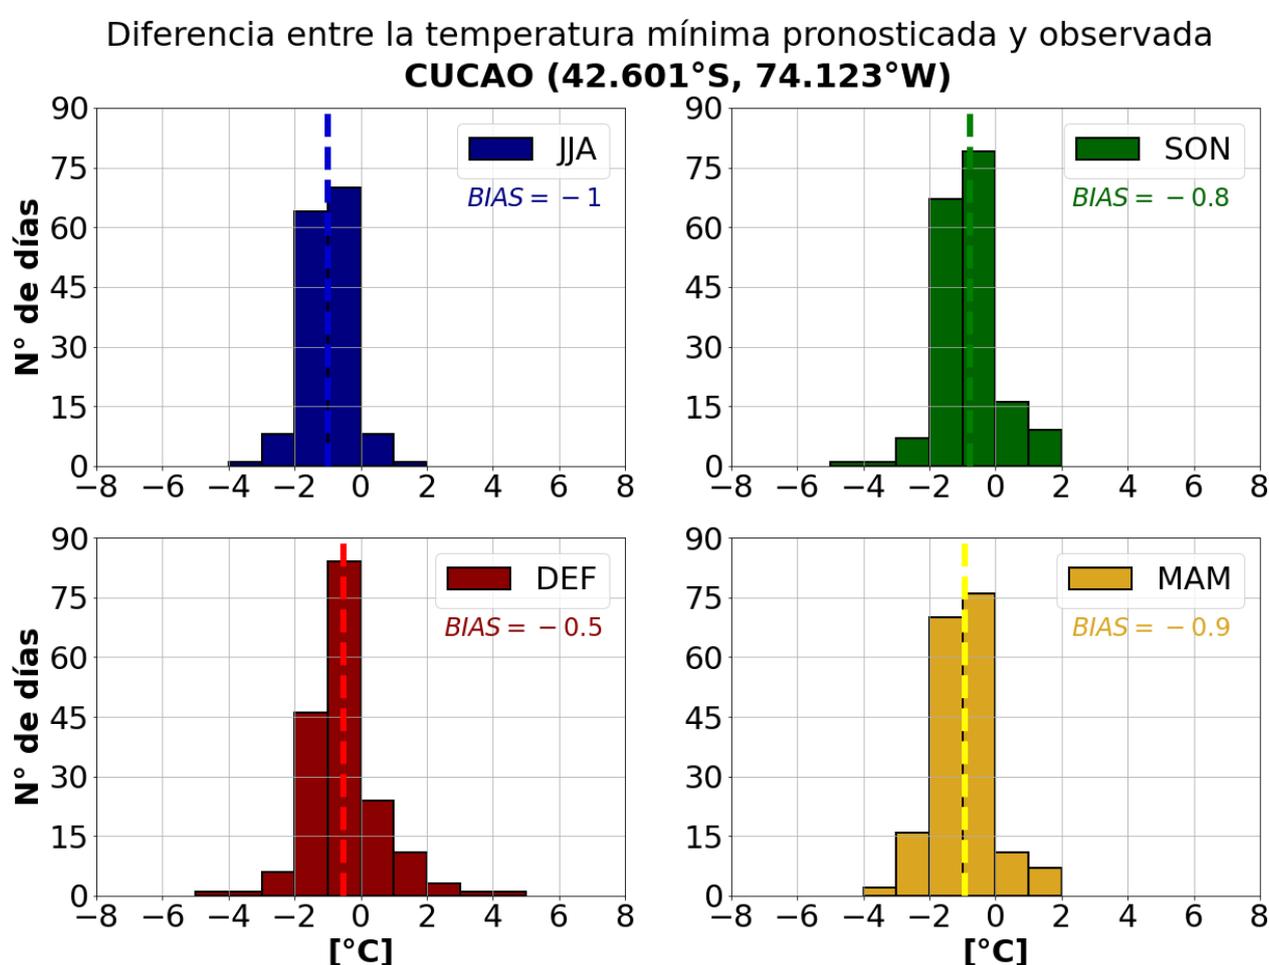
**Figura 4.1.1:** Series de tiempo de la temperatura máxima observada (azul), pronosticada (amarillo) y su diferencia (rojo) en Cucao y Melinka. El periodo considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022.



**Figura 4.1.2:** Diagramas de dispersión para la temperatura máxima diaria (observada vs pronosticada) en Cucao y Melinka. La línea negra corresponde a una correlación positiva perfecta mientras que la roja a la línea ajustada.

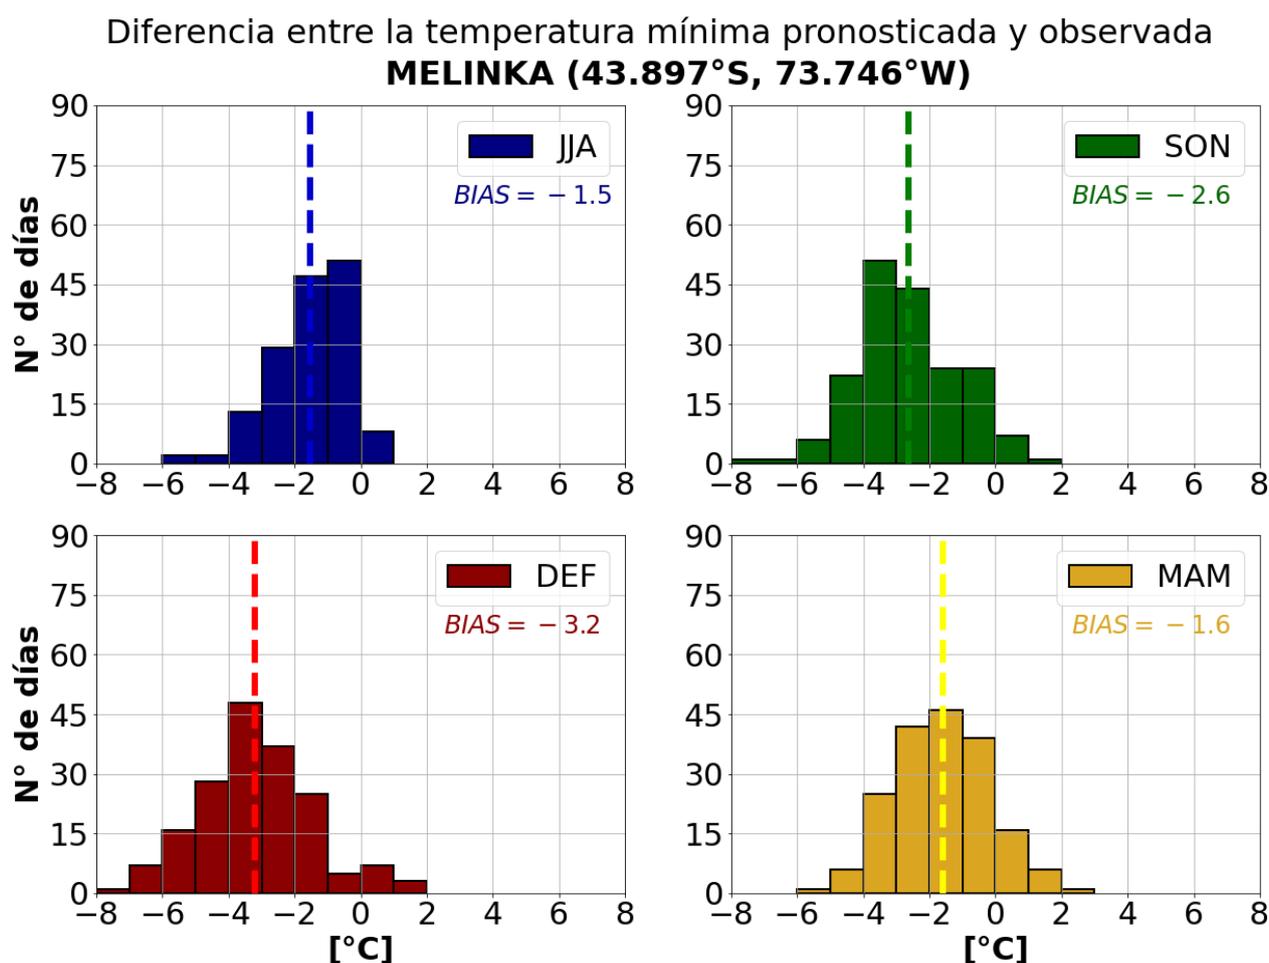
### 4.1.1. Distribución del error

Con el propósito de analizar la distribución del sesgo y observar en qué época del año se produce mayor error, se generan histogramas. Así, se logra apreciar que para el caso de Cucao, los histogramas muestran que la mayor subestimación se produce en la época de primavera y verano, alcanzando diferencias de aproximadamente 5 °C entre la temperatura máxima pronosticada y observada. Luego, sigue el otoño y el invierno con errores máximos de hasta 4 °C. Por otra parte, la subestimación promedio de los datos (líneas discontinuas) es máxima en invierno (-1 °C) y mínima en verano (-0.5 °C) (Figura 4.1.3).



**Figura 4.1.3:** Distribución del sesgo en Cucao separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura máxima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos.

En relación a Melinka, podemos notar que se sigue el mismo patrón ya que los histogramas muestran, nuevamente, que la mayor subestimación ocurre en primavera y verano, alcanzando diferencias de 8 °C entre la temperatura máxima observada y pronosticada, seguido por otoño e invierno con errores máximos de 6 °C. Por otro lado, la subestimación promedio de los datos (líneas discontinuas) es máxima en verano (-3.2 °C) y mínima en invierno (-1.5 °C) (**Figura 4.1.4**).

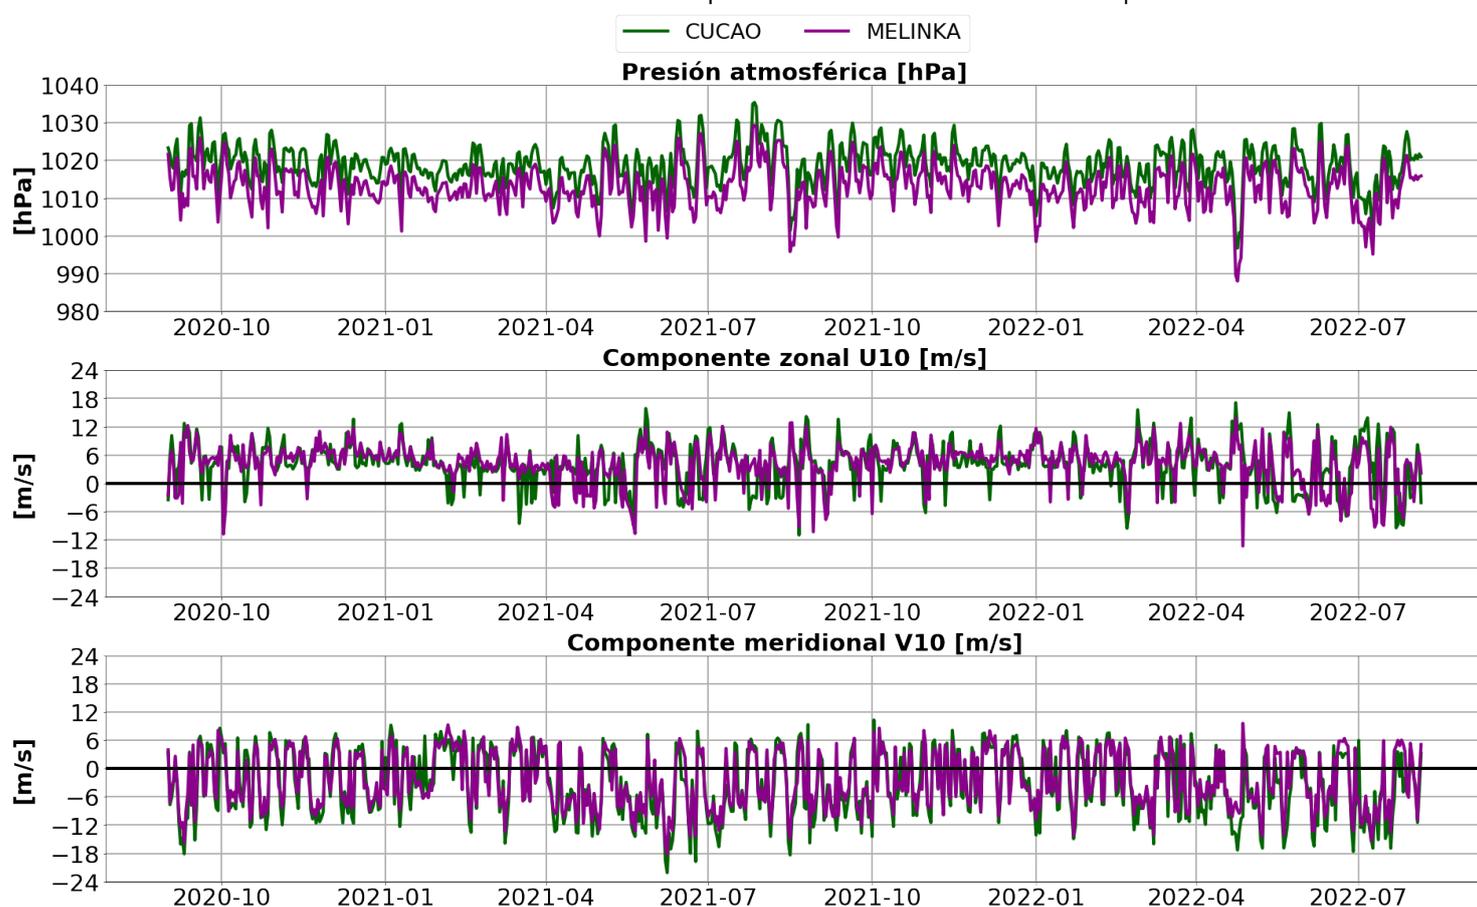


**Figura 4.1.4:** Distribución del sesgo en Melinka separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura máxima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos.

#### 4.1.2. Variables predictoras que ajustan la temperatura máxima

En la **Figura 4.1.5** se observan las variables predictoras simuladas por MOSA para los puntos correspondientes a las estaciones meteorológicas instaladas en Cucao y Melinka, que contribuyen como variables auxiliares para ajustar la temperatura máxima diaria simulada. Se consideran los máximos diarios de la presión atmosférica (hPa), y las componentes zonal (U10) y meridional (V10) del viento (m/s) para el mismo periodo de tiempo (01/09/2020 - 01/08/2022).

Máximos diarios de las variables predictoras auxiliares simuladas por MOSA-WRF



**Figura 4.1.5:** Variables predictoras simuladas por MOSA-WRF que ajustan la temperatura máxima diaria (presión atmosférica y la componente zonal y meridional del viento). En verde los máximos diarios de Cucao y en magenta los máximos diarios de Melinka.

### 4.1.3. Temperatura máxima reconstruida (MOS)

La temperatura máxima reconstruida (MOS) para cada lugar correspondiente se obtiene como:

$$T2_{MOS} = b_0 + b_1 \cdot T2_{WRF} + b_2 \cdot P_{WRF} + b_3 \cdot U10_{WRF} + b_4 \cdot V10_{WRF} \quad (4.1.1)$$

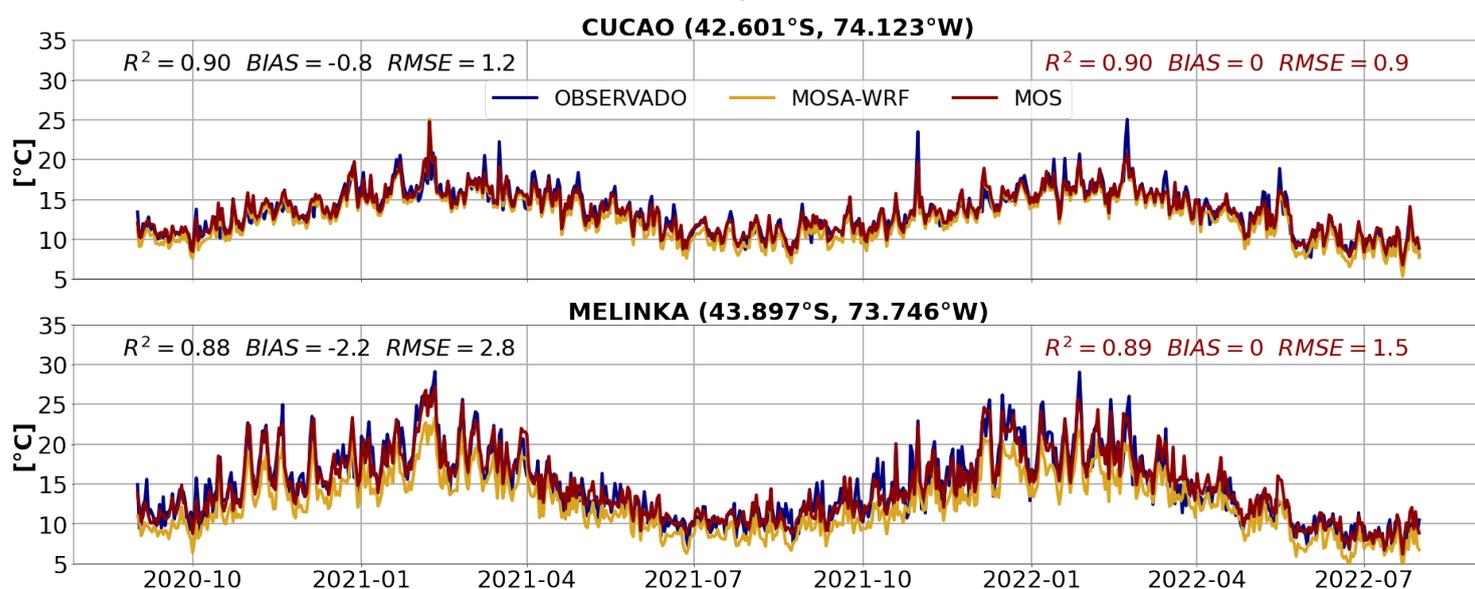
De tal forma, los coeficientes de regresión, que fueron obtenidos a través del método de mínimos cuadrados ordinarios (OLS) y que ajustan la serie de tiempo histórica de la temperatura máxima pronosticada en base a mediciones se resumen en la Tabla 4.1.1:

Estación	$b_0$	$b_1$	$b_2$	$b_3$	$b_4$
CUCAO	-7.0654	0.9173	0.0087	-0.0186	-0.0313
MELINKA	-34.2833	1.1000	0.0350	0.0041	0.0737

**Tabla 4.1.1:** Coeficientes de regresión que ajustan la temperatura máxima pronosticada en Cucao y Melinka.

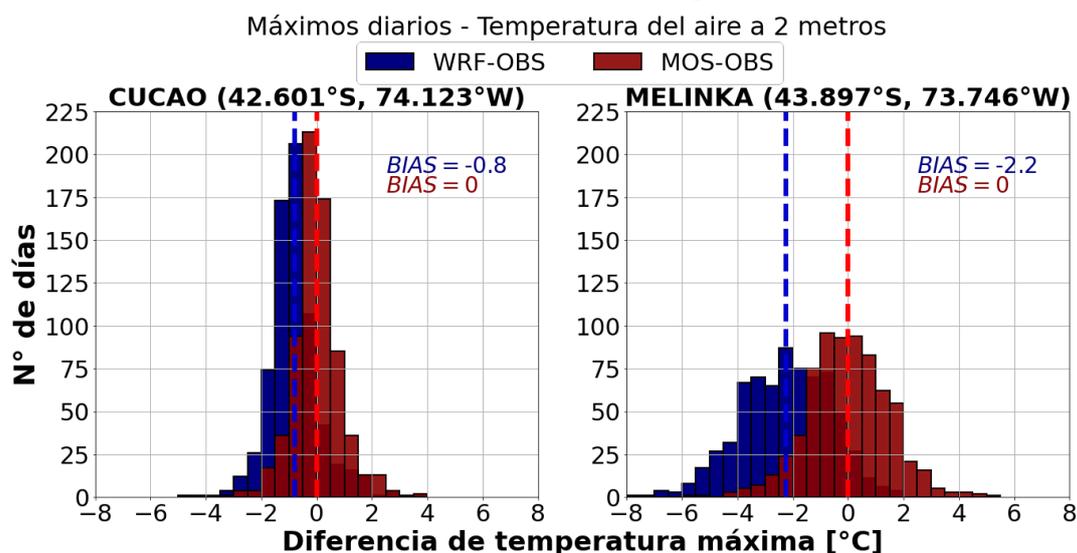
Al aplicar MOS, se observa una mejora en las series temporales de la temperatura máxima diaria en todo el período, manteniendo el coeficiente de determinación en 0.9 en Cucao y aumentando de 0.88 a 0.89 en Melinka. Además, se reduce el RMSE de 1.2 a 0.9 °C y de 2.8 a 1.5 °C, respectivamente (**Figura 4.1.6**).

Máximos diarios - Temperatura del aire a 2 metros



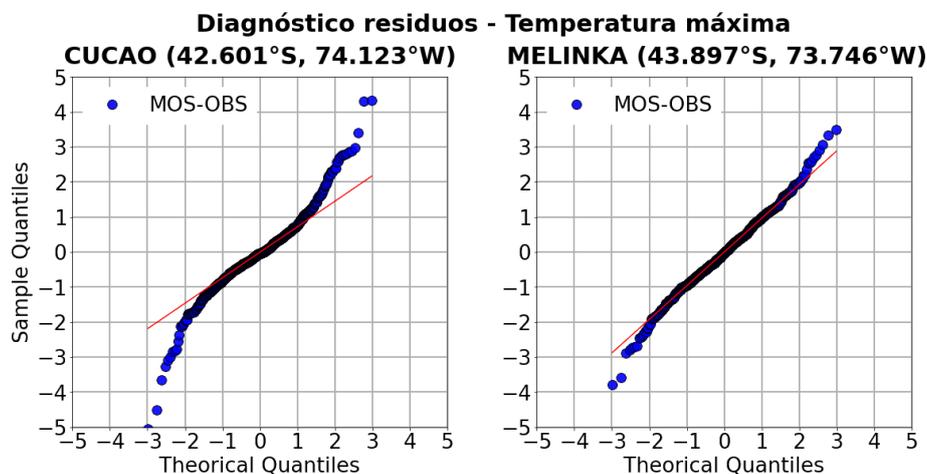
**Figura 4.1.6:** Máximos diarios de temperatura observada (azul), simulada (amarillo) y ajustada con MOS (rojo) en Cucao y Melinka. El periodo considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022 (N=699).

Con respecto a las diferencias de temperatura máxima entre lo simulado y lo observado, se distingue que en ambas estaciones se subestima la temperatura máxima, con un sesgo de  $-0.8$  y  $-2.2$  °C en Cucao y Melinka, respectivamente. Luego de aplicar MOS, el sesgo se corrige en ambos lugares (se centra en 0) y la distribución del error mantiene la misma forma (**Figura 4.1.7**).



**Figura 4.1.7:** Diferencias de temperatura máxima entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 01/09/2020 hasta el 01/08/2022. (N=699).

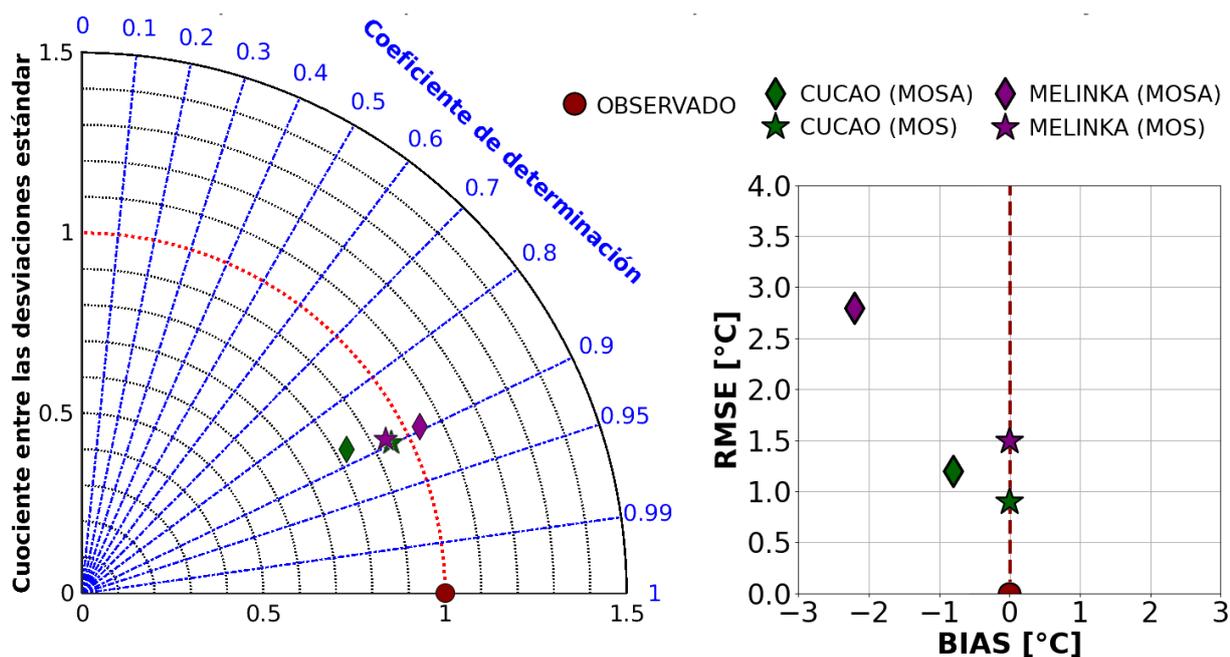
Los residuos siguen una distribución normal en ambos casos, es decir que la mayoría de los datos se concentran simétricamente en torno al promedio y los valores extremos son poco frecuentes. Además, se hace un diagnóstico de los residuos de forma gráfica mediante un QQ plot (**Figura 4.1.8**), donde se observa que las líneas se ajustan a un ángulo de  $45^\circ$ , verificando así la distribución normal.



**Figura 4.1.8:** QQ plot temperatura máxima Cucao y Melinka.

Finalmente, los resultados de los estadísticos para la temperatura máxima simulada (MOSA) y la temperatura máxima corregida (MOS) con respecto a lo observado (estaciones meteorológicas) se muestran en el diagrama de Taylor y en el diagrama BIAS vs RMSE (**Figura 4.1.9**).

Estadísticos para la temperatura máxima pronosticada y reconstruida



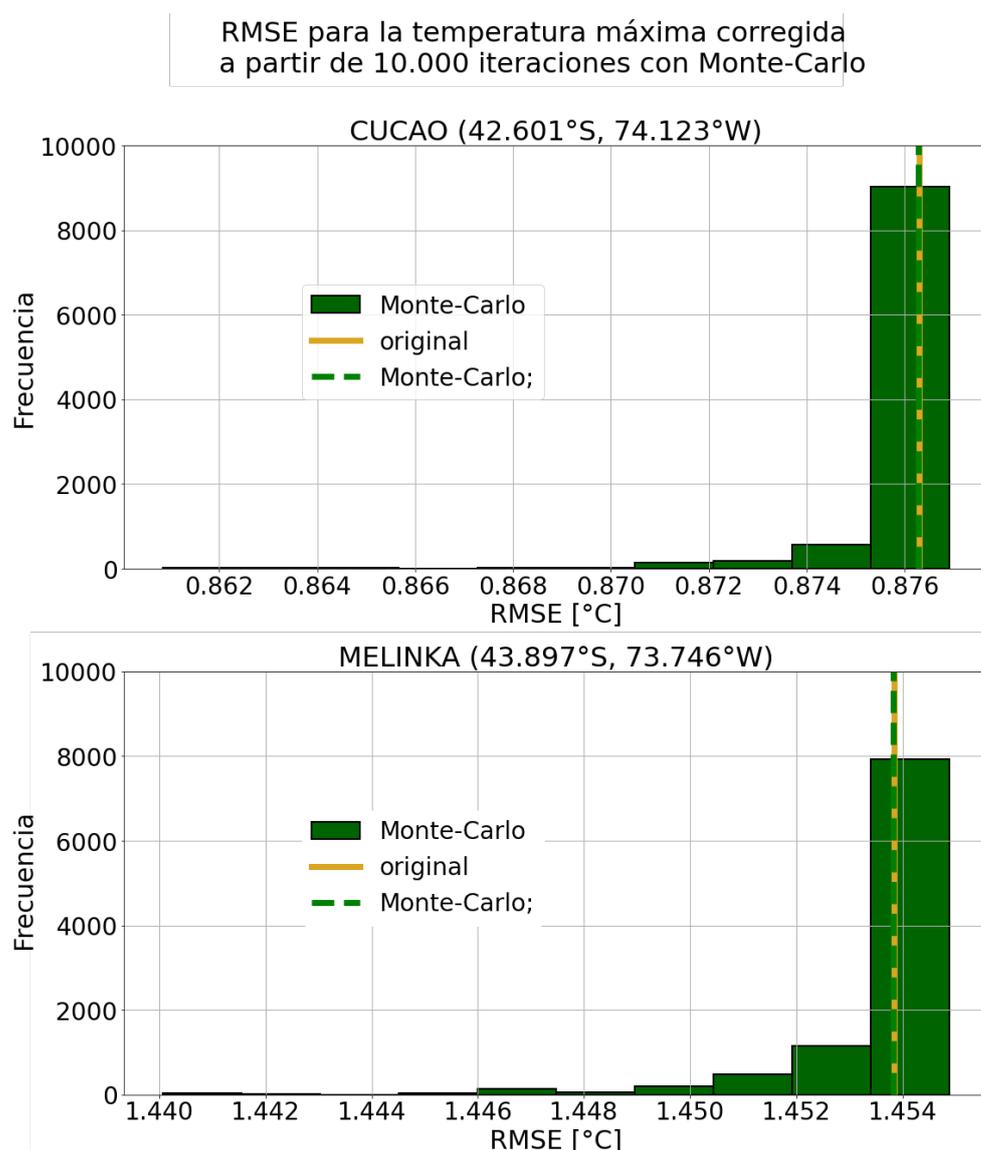
**Figura 4.1.9:** Diagrama de Taylor (izquierda) y diagrama BIAS vs RMSE (derecha) para la temperatura máxima histórica, simulada por MOSA (diamantes) y reconstruida con MOS (estrellas) para el periodo 01-09-2020 - 01-08-2022. El color azul corresponde a Cucao y el verde a Melinka. Los estadísticos fueron calculados con respecto a las mediciones de las estaciones meteorológicas (círculo rojo).

La figura anterior se resume a continuación:

1. Coeficiente de determinación ( $R^2$ ): En Cucao el ajuste se mantiene en 0.90 y en Melinka mejora de 0.88 a 0.89.
2. Cuociente entre las desviaciones estándar: En Cucao la amplitud disminuye de 1.04 a 0.95 mientras que en Melinka aumenta de 0.83 a 0.94, manteniéndose cerca de 1 que es el valor ideal.
3. Raíz del error cuadrático medio (RMSE): El RMSE se reduce en ambas estaciones, de 1.2 a 0.9 °C en Cucao y de 2.8 a 1.5 °C en Melinka.
4. Sesgo (BIAS): El sesgo se elimina en ambas estaciones, de -0.8 a 0 °C en Cucao y de -2.2 a 0 °C en Melinka.

#### 4.1.4. Simulación de Monte-Carlo

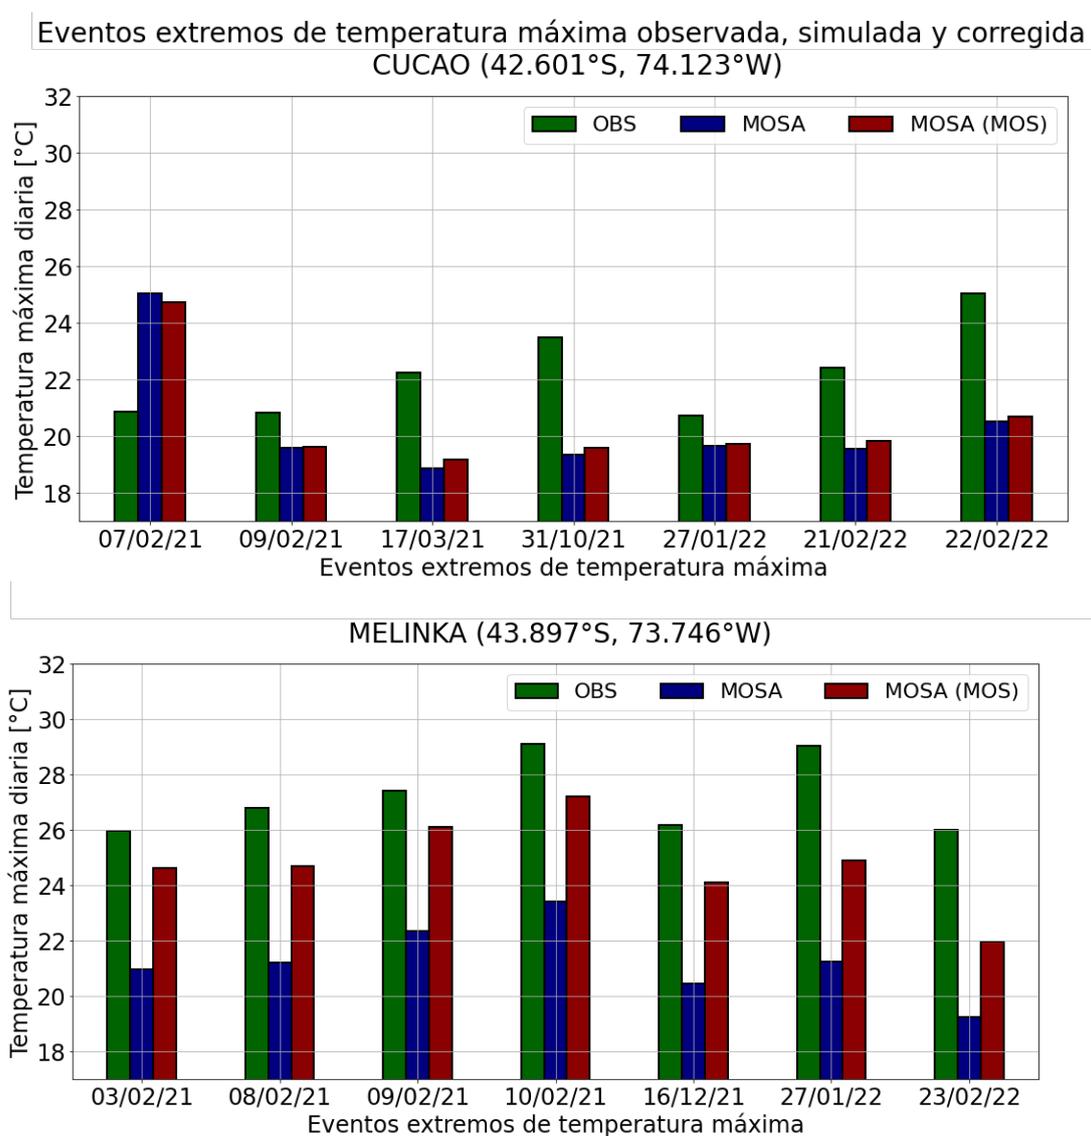
Distribución de RMSE para la temperatura máxima corregida considerando 10.000 iteraciones donde la serie calibrada con MOS se remuestra aleatoriamente y luego se calcula el estadístico para cada una de las iteraciones (**Figura 4.1.10**). El RMSE promedio de las 10.000 iteraciones coincide con el RMSE obtenido con MOS originalmente (0.9 [°C] para Cucao y 1.5 [°C] para Melinka).



**Figura 4.1.10:** Simulación de RMSE con Monte-Carlo para la temperatura máxima corregida considerando 10.000 iteraciones. En verde se observa la distribución del RMSE obtenido para cada una de las iteraciones, con la línea verde segmentada se observa el promedio de los 10.000 RMSE y con la línea amarilla segmentada se muestra el RMSE obtenido con MOS originalmente, los cuales coinciden tanto en Cucao como en Melinka.

#### 4.1.5. Eventos extremos de temperatura máxima

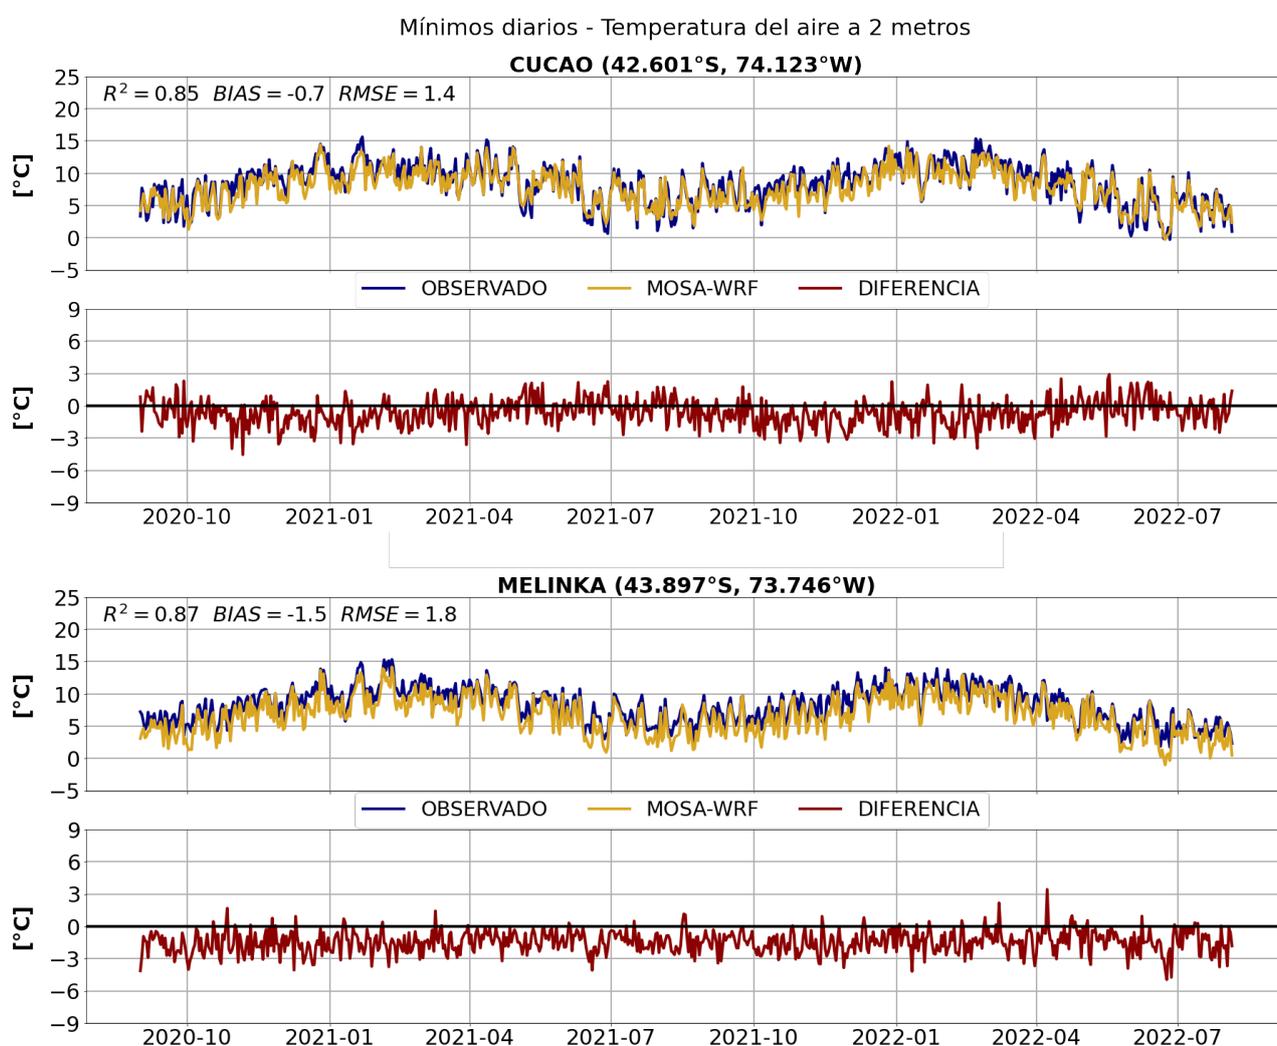
En la **Figura 4.1.11** se observan los eventos extremos de temperatura máxima observada, pronosticada y corregida en Cucao y Melinka. Se define evento extremo de temperatura máxima como los valores que están por sobre el percentil 99 de los datos observados, donde se obtienen 7 eventos extremos ocurridos en cada lugar en los veranos del 2021 y 2022 (sólo un evento ocurre en primavera, el 31 de octubre de 2021).



**Figura 4.1.11:** Eventos extremos de temperatura máxima ocurridos en Cucao y Melinka el 2021 y 2022 (percentil 99). En azul se tiene el pronóstico de temperatura máxima pronosticado con respecto a lo observado y en rojo se tiene el pronóstico de corregido con respecto a lo observado. El valor ideal es 100 %.

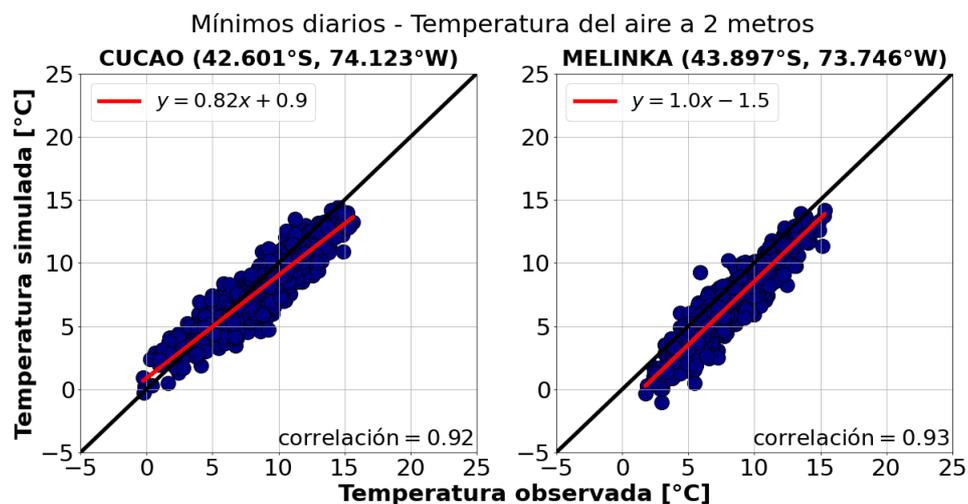
## 4.2. Temperatura mínima histórica (MOSA-WRF)

Análogamente a lo anterior, se realiza una comparación del pronóstico de temperatura mínima diaria con respecto a las observaciones, considerando las series temporales desde septiembre de 2020 hasta agosto de 2022, donde se puede apreciar que Cucao y Melinka presentan un buen ajuste, con coeficientes de determinación ( $R^2$ ) de 0.85 y 0.87, respectivamente. Además, se observa una subestimación sistemática de la temperatura mínima en Cucao y Melinka, con errores máximos de aproximadamente 5 °C, pero que en general, se mantienen dentro de los 3 °C de diferencia (Figura 4.2.1).



**Figura 4.2.1:** Series de tiempo de la temperatura mínima observada (azul), pronosticada (amarillo) y su diferencia (rojo) en Cucao y Melinka. El periodo considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022.

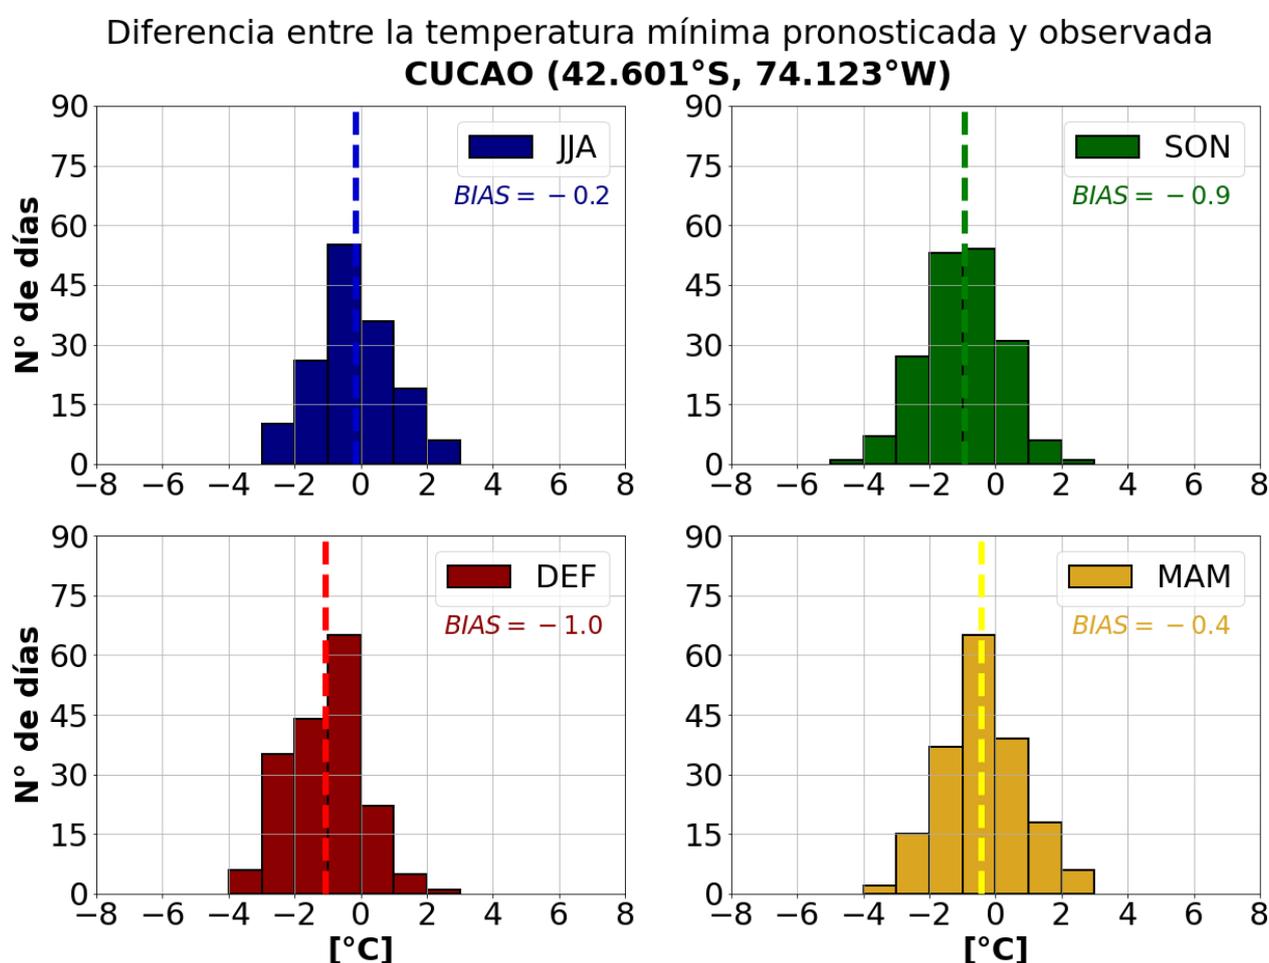
Como se mencionó anteriormente, la representación gráfica más útil para describir el comportamiento conjunto de dos variables es el diagrama de dispersión. En este caso, se busca analizar si existe relación entre la temperatura mínima observada y pronosticada en los 2 lugares de interés. Para Cucao, la curva ajustada a los datos corresponde a  $y=0.82x+0.9$  y para Melinka, corresponde a  $y=1.0x-1.5$ , mostrando una correlación positiva muy alta de 92 % y 93 %, respectivamente (**Figura 4.2.2**).



**Figura 4.2.2:** Diagramas de dispersión para la temperatura mínima diaria (observada vs pronosticada) en Cucao y Melinka. La línea negra corresponde a una correlación positiva perfecta mientras que la roja a la línea ajustada.

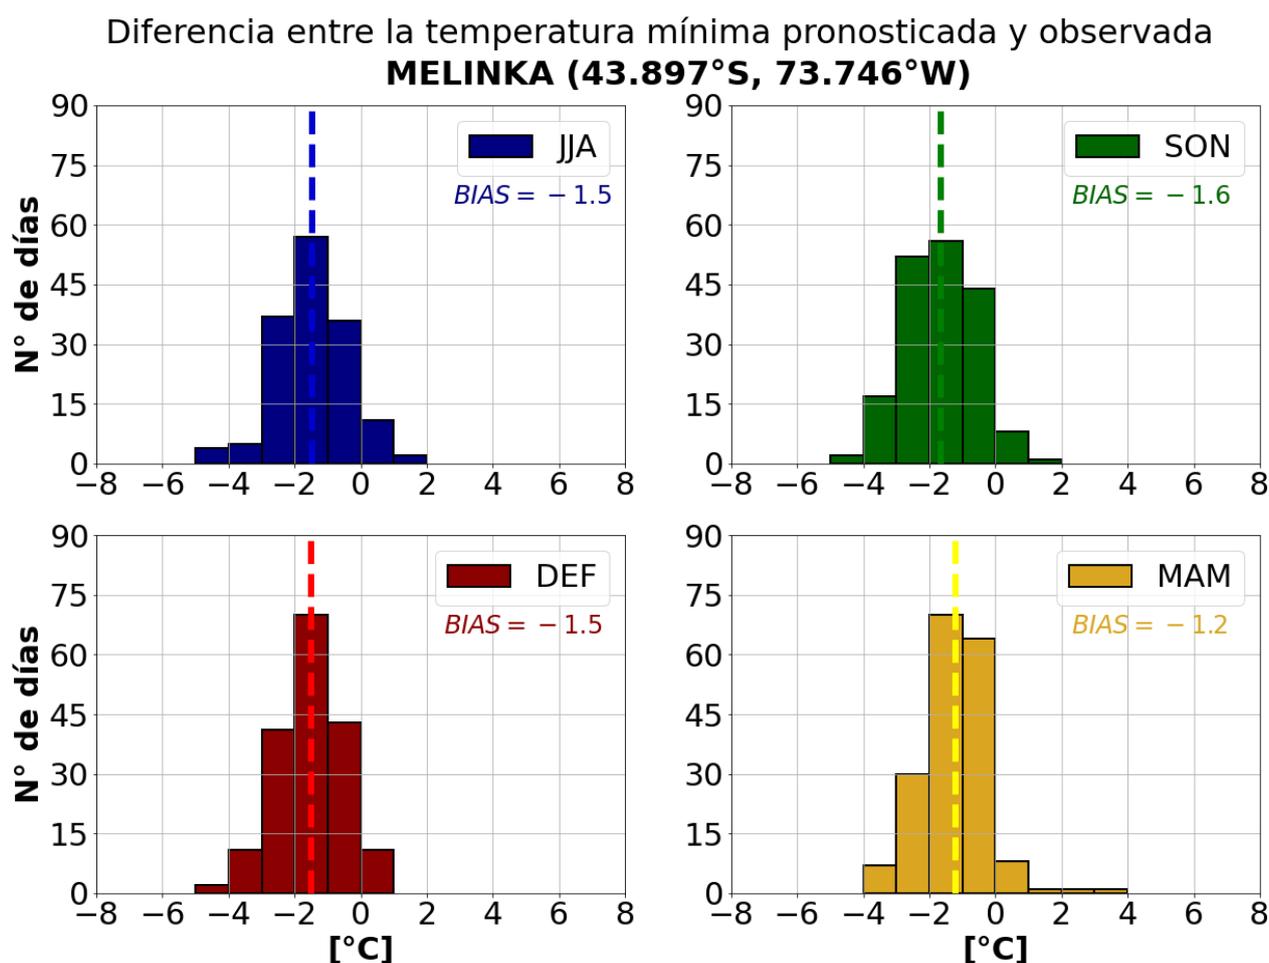
### 4.2.1. Distribución del error

Para poder analizar la distribución del sesgo y observar en qué época del año se produce mayor error, se generan histogramas. Así, se logra apreciar que para Cucao la mayor subestimación se produce en primavera, alcanzando valores de hasta 5 °C de diferencia entre la temperatura mínima pronosticada y observada, seguido por verano y otoño con un error máximo de 4 °C y finalmente invierno que alcanza hasta 3 °C de diferencia. Además, en la distribución se aprecia que el sesgo promedio (líneas discontinuas) es máximo en verano (-1 °C) y mínimo en invierno (-0.2 °C) (Figura 4.2.3).



**Figura 4.2.3:** Distribución del sesgo en Cucao separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura mínima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos.

Por último, para el caso de Melinka, la mayor subestimación se produce en invierno, primavera y verano, alcanzando hasta 5 °C de diferencia entre la temperatura mínima pronosticada y observada, seguido por otoño, que alcanza un error máximo de 4 °C. Por otro lado, en la distribución se puede observar que la subestimación promedio (líneas discontinuas) es máxima en primavera (-1.6 °C) y mínima en otoño (-1.2 °C) (**Figura 4.2.4**).

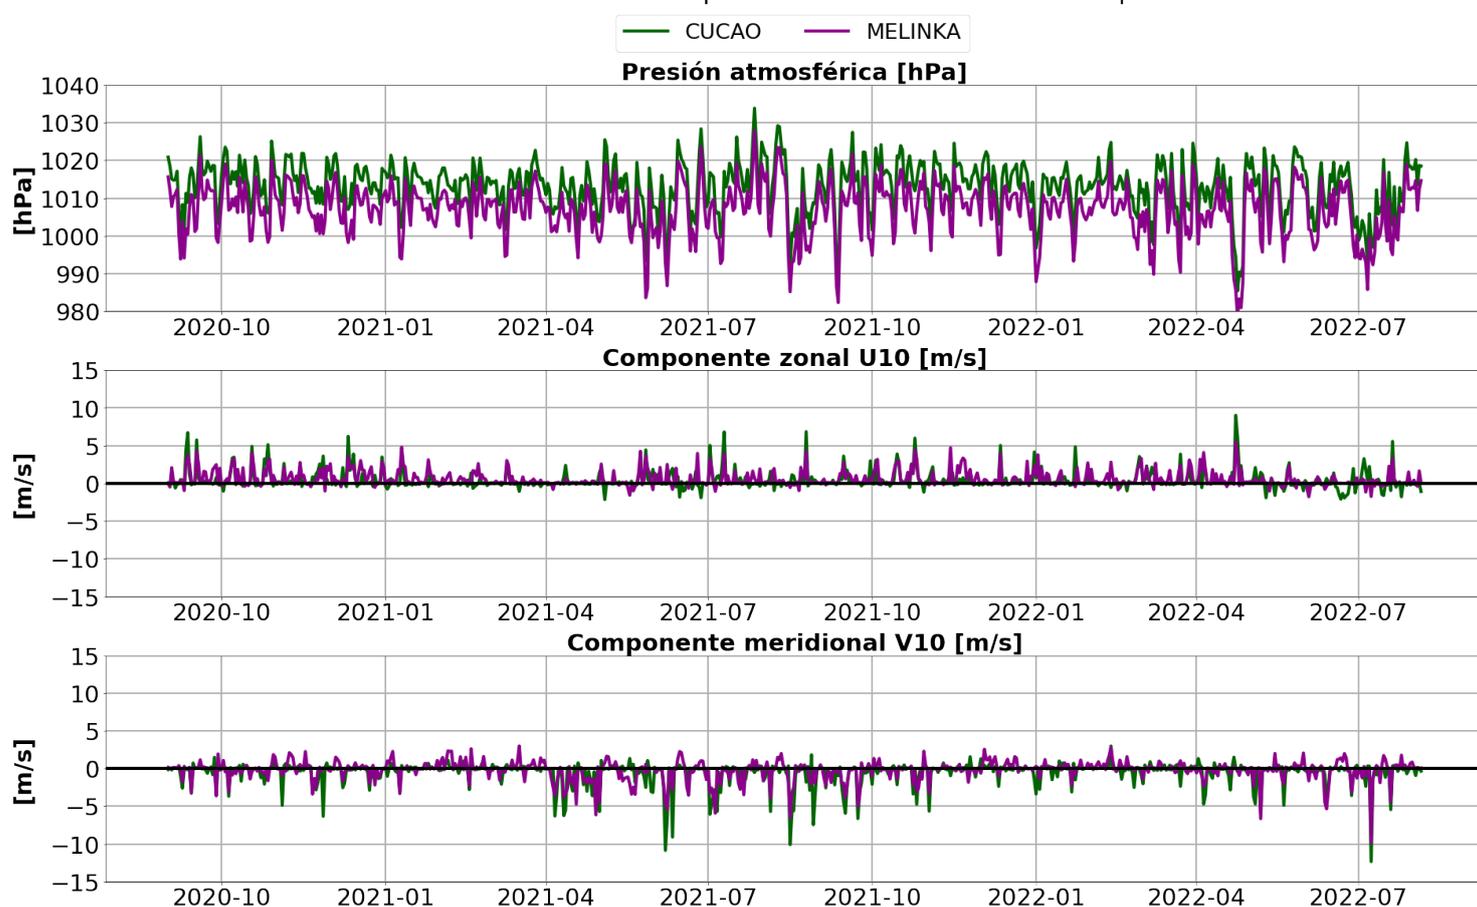


**Figura 4.2.4:** Distribución del sesgo en Melinka separado por época del año (invierno en azul, primavera en verde, verano en rojo y otoño en amarillo). Se calcula como la diferencia entre la temperatura mínima pronosticada y observada. Las líneas discontinuas corresponden al sesgo promedio de los datos.

## 4.2.2. Variables predictoras que ajustan la temperatura mínima

En la **Figura 4.2.5** se observan las variables predictoras simuladas por MOSA para los puntos correspondientes a las estaciones meteorológicas instaladas en Cucao y Melinka, que contribuyen como variables auxiliares para ajustar la temperatura mínima diaria simulada. Se consideran los mínimos diarios de la presión atmosférica (hPa), y las componentes zonal (U10) y meridional (V10) del viento (m/s) para el mismo periodo de tiempo (01/09/2020 - 01/08/2022).

Mínimos diarios de las variables predictoras auxiliares simuladas por MOSA-WRF



**Figura 4.2.5:** Variables predictoras simuladas por MOSA-WRF que ajustan la temperatura mínima diaria (presión atmosférica y la componente zonal y meridional del viento). En verde los mínimos diarios de Cucao y en magenta los mínimos diarios de Melinka.

### 4.2.3. Temperatura mínima reconstruida (MOS)

La temperatura mínima reconstruida (MOS) para cada lugar correspondiente se obtiene como:

$$T2_{MOS} = b_0 + b_1 \cdot T2_{WRF} + b_2 \cdot P_{WRF} + b_3 \cdot U10_{WRF} + b_4 \cdot V10_{WRF} \quad (4.2.1)$$

De tal forma, los coeficientes de regresión, que fueron obtenidos a través del método de mínimos cuadrados ordinarios (OLS) y que ajustan la serie de tiempo histórica de la temperatura mínima pronosticada en base a mediciones se resumen en la Tabla 4.2.1:

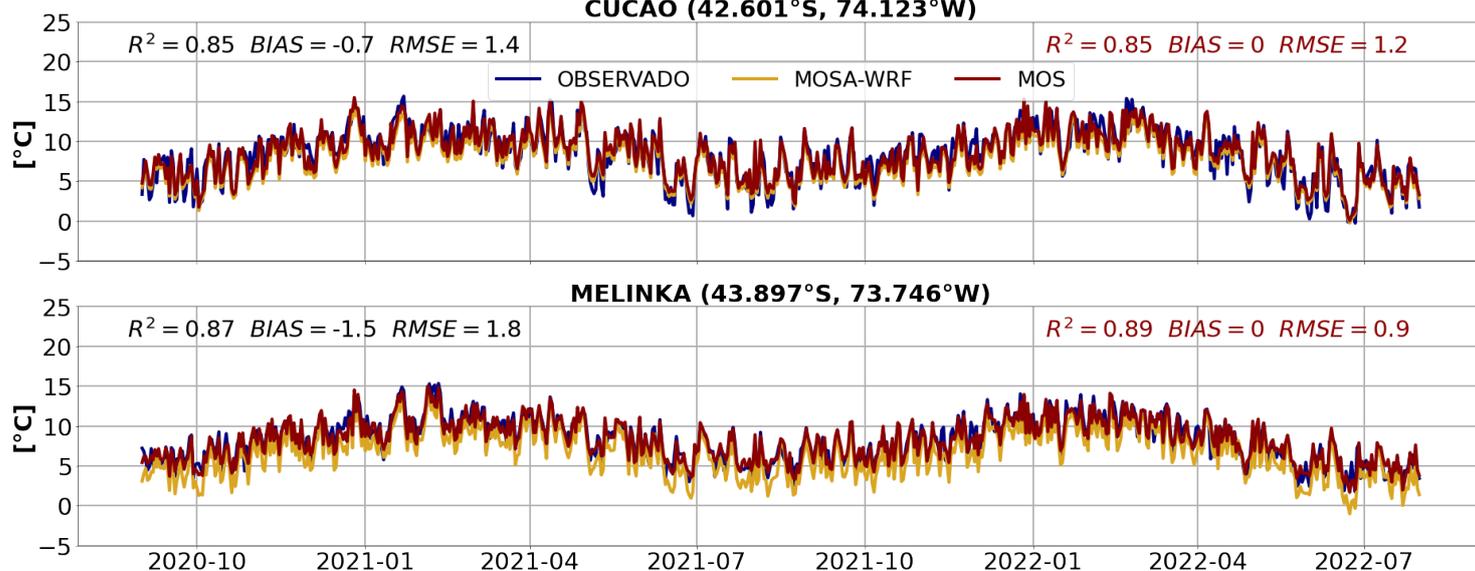
Estación	$b_0$	$b_1$	$b_2$	$b_3$	$b_4$
CUCAO	-13.9508	1.0564	0.0140	-0.0203	-0.0099
MELINKA	-43.0907	0.9006	0.0450	-0.1507	0.0681

**Tabla 4.2.1:** Coeficientes de regresión que ajustan la temperatura mínima pronosticada en Cucao y Melinka.

Al aplicar MOS, se observa una mejora en las series temporales de la temperatura mínima diaria en todo el período, manteniendo el coeficiente de determinación en 0.85 en Cucao y aumentando de 0.87 a 0.89 en Melinka. Además, se reduce el RMSE de 1.4 a 1.2 °C y de 1.8 a 0.9 °C, respectivamente (**Figura 4.2.6**).

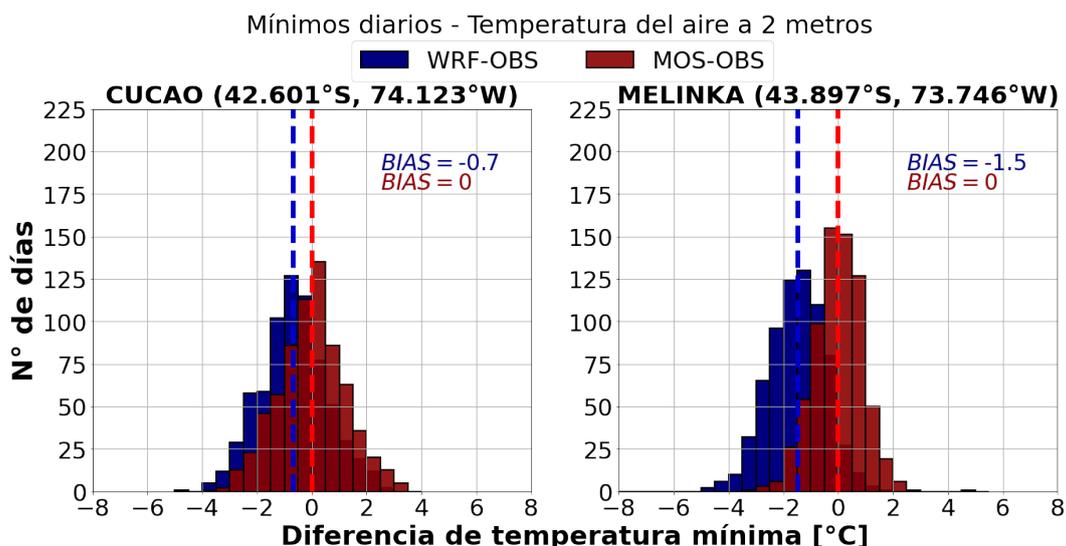
Mínimos diarios - Temperatura del aire a 2 metros

**CUCAO (42.601°S, 74.123°W)**



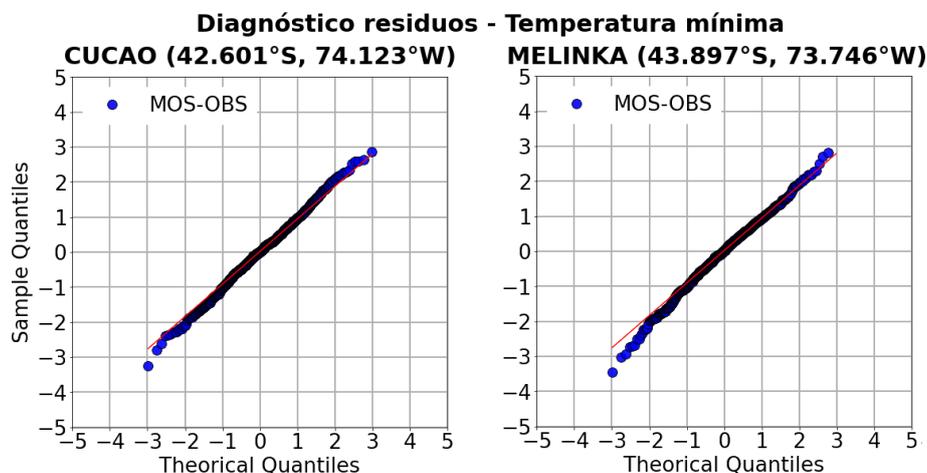
**Figura 4.2.6:** Mínimos diarios de temperatura observada (azul), simulada (amarillo) y ajustada con MOS (rojo) en Cucao y Melinka. El período considera desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022. (N=699).

Con respecto a las diferencias de temperatura mínima entre lo simulado y lo observado, se distingue que en ambas estaciones se subestima la temperatura mínima observada, con un sesgo de  $-0.7$  y  $-1.5$  °C en Cucao y Melinka, respectivamente. Luego de aplicar MOS, el sesgo se corrige en ambos lugares (se centra en 0) y la distribución del error mantiene la misma forma (**Figura 4.2.7**).



**Figura 4.2.7:** Diferencias de temperatura mínima entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 01/09/2020 hasta el 01/08/2022. (N=699).

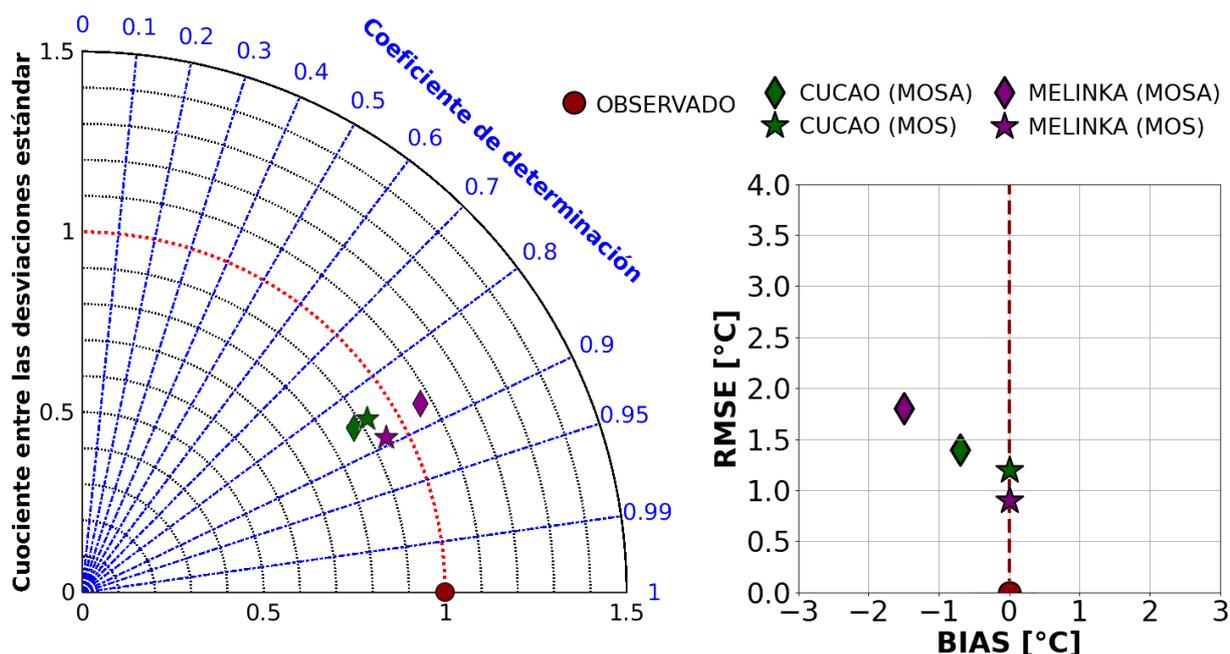
Los residuos siguen una distribución normal en ambos casos, es decir que la mayoría de los datos se concentran simétricamente en torno al promedio y los valores extremos son poco frecuentes. Además, se hace un diagnóstico de los residuos de forma gráfica mediante un QQ plot (**Figura 4.2.8**), donde se observa que las líneas se ajustan a un ángulo de  $45^\circ$ , verificando así la distribución normal.



**Figura 4.2.8:** QQ plot temperatura mínima Cucao y Melinka.

Finalmente, los resultados de los estadísticos para la temperatura mínima simulada (MOSA) y la temperatura mínima corregida (MOS) con respecto a lo observado (estaciones meteorológicas) se muestran en el diagrama de Taylor y en el diagrama BIAS vs RMSE (**Figura 4.2.9**).

Estadísticos para la temperatura mínima pronosticada y reconstruida



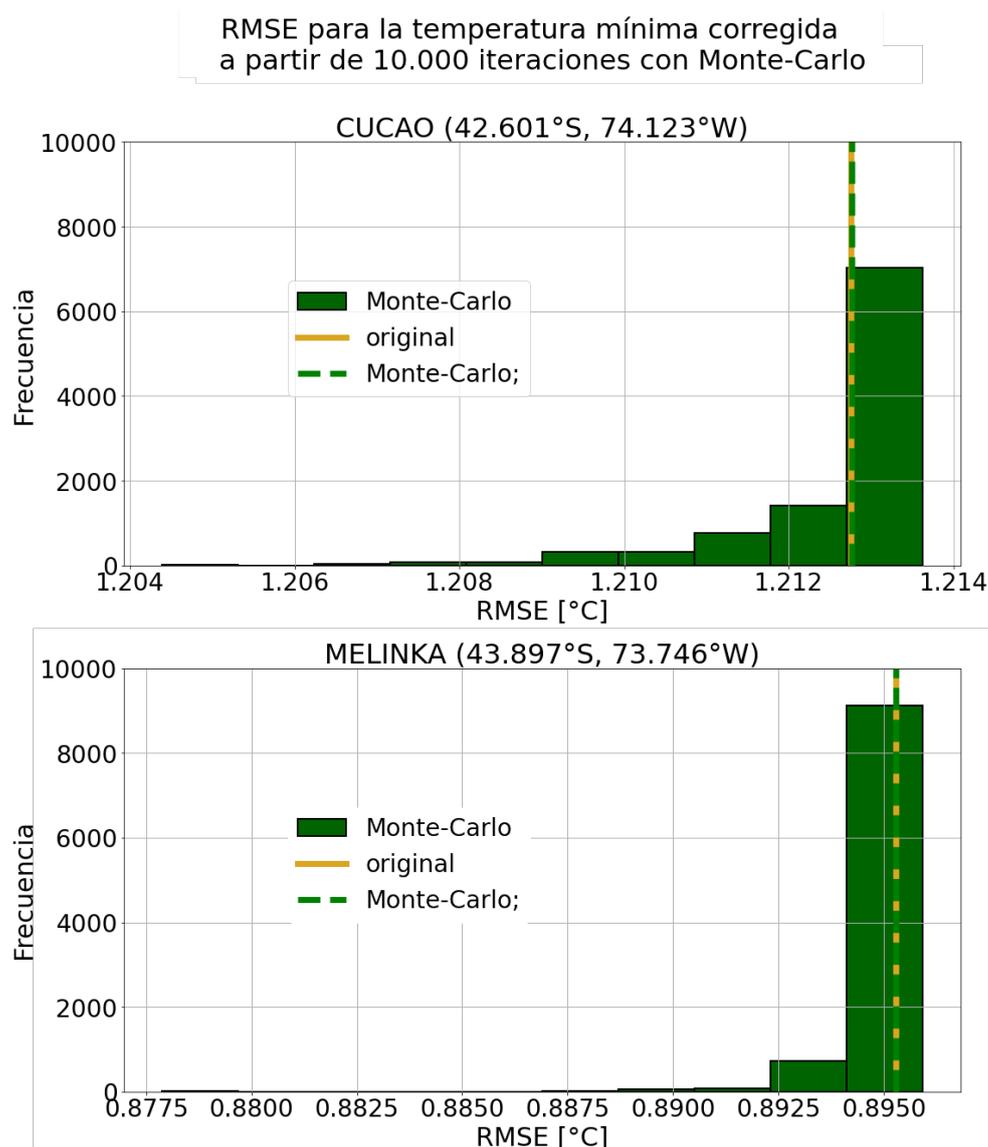
**Figura 4.2.9:** Diagrama de Taylor (izquierda) y diagrama BIAS vs RMSE (derecha) para la temperatura mínima histórica, simulada por MOSA (diamantes) y reconstruida con MOS (estrellas) para el periodo 01-09-2020 - 01-08-2022. El color azul corresponde a Cucao y el verde a Melinka. Los estadísticos fueron calculados con respecto a las mediciones de las estaciones meteorológicas (círculo rojo).

La figura anterior se resume a continuación:

1. Coeficiente de determinación ( $R^2$ ): En Cucao el ajuste se mantiene en 0.85 y en Melinka mejora de 0.87 a 0.89.
2. Cuociente entre las desviaciones estándar: En Cucao la amplitud aumenta de 0.88 a 0.92 mientras que en Melinka disminuye de 1.07 a 0.94, manteniéndose cerca de 1 que es el valor ideal.
3. Raíz del error cuadrático medio (RMSE): El RMSE se reduce en ambas estaciones, de 1.4 a 1.2 °C en Cucao y de 1.8 a 0.9 °C en Melinka.
4. Sesgo (BIAS): El sesgo se elimina en ambas estaciones, de -0.7 a 0 °C en Cucao y de -1.5 a 0 °C en Melinka.

#### 4.2.4. Simulación de Monte-Carlo

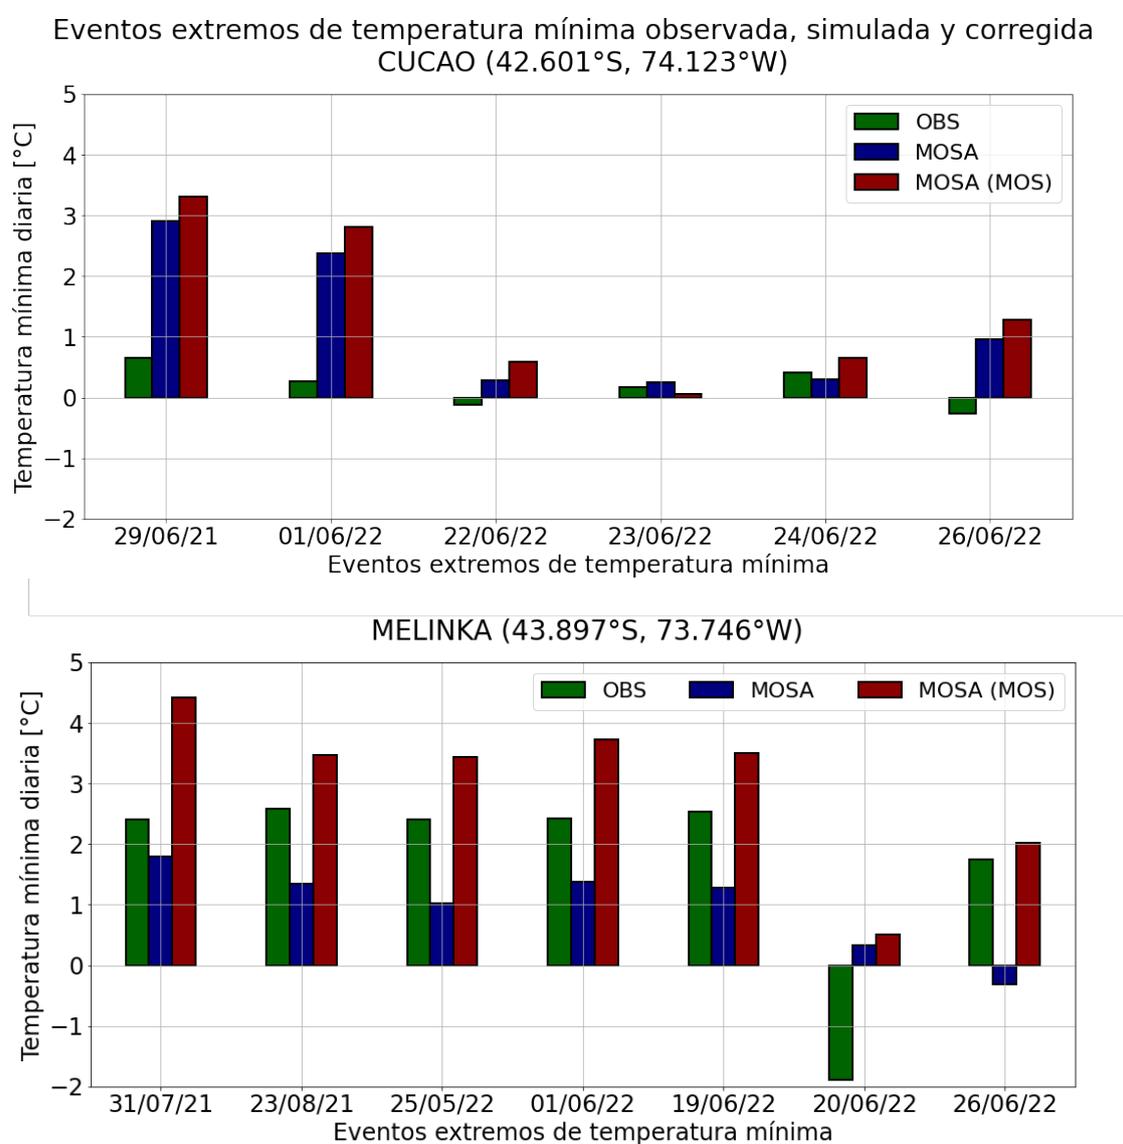
Distribución de RMSE para la temperatura mínima corregida considerando 10.000 iteraciones donde la serie calibrada con MOS se remuestra aleatoriamente y luego se calcula el estadístico para cada una de las iteraciones (**Figura 4.2.10**). El RMSE promedio de las 10.000 iteraciones coincide con el RMSE obtenido con MOS originalmente (1.2 °C para Cucao y 0.9 °C para Melinka).



**Figura 4.2.10:** Simulación de RMSE con Monte-Carlo para la temperatura mínima corregida considerando 10.000 iteraciones. En verde se observa la distribución del RMSE obtenido para cada una de las iteraciones, con la línea verde segmentada se observa el promedio de los 10.000 RMSE y con la línea amarilla segmentada se muestra el RMSE obtenido con MOS originalmente, los cuales coinciden tanto en Cucao como en Melinka.

#### 4.2.5. Eventos extremos de temperatura mínima

En la **Figura 4.2.11** se observan los eventos extremos de temperatura mínima observada, pronosticada y corregida en Cucao y Melinka. Se define evento extremo de temperatura mínima como los valores que están por debajo del percentil 1 de los datos observados, donde se obtienen 6 eventos extremos ocurridos en Cucao y 7 eventos extremos ocurridos en Melinka en los inviernos del 2021 y 2022 (sólo un evento ocurre en otoño, el 25 de mayo de 2021).



**Figura 4.2.11:** Eventos extremos de temperatura mínima ocurridos en Cucao y Melinka el 2021 y 2022 (valores por debajo del percentil 1). En verde se tiene la temperatura mínima diaria observada, en azul se tiene el pronóstico y en rojo se tiene el pronóstico corregido.

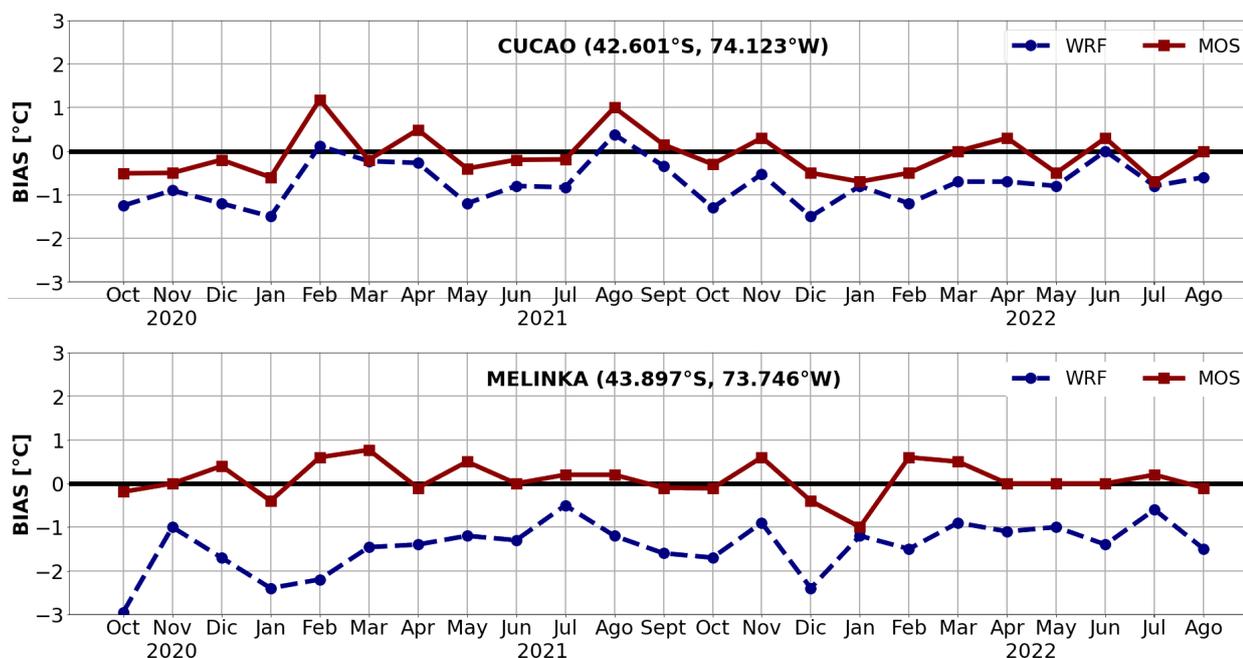
### 4.3. Temperatura (MOS Operacional)

Considerando desde el 1 de septiembre de 2020 hasta el 5 de agosto de 2022, se ajusta el pronóstico de 96 horas de la temperatura del aire a 2 metros que MOSA-WRF genera el primer día de cada mes (23 meses en total), y se compara el sesgo con lo medido por las estaciones. Las series de tiempo generadas se muestran en el Anexo A3.

#### 4.3.1. Prueba de sensibilidad

Para el entrenamiento se consideran los últimos 720 datos horarios (últimos 30 días de medición de las estaciones meteorológicas) correspondientes a cada día que se ajusta. De esa forma, resolviendo como un problema inverso, se obtienen los coeficientes de regresión y luego se le aplican a los nuevos datos que sería el pronóstico de 96 horas, de tal forma, la validación cruzada se divide en 88 % para el entrenamiento y 12 % para la validación, obteniendo así una nueva serie de tiempo calibrada (**Figura 4.3.1**), en la que se corrige la subestimación sistemática en la mayoría de los casos, excepto cuando el pronóstico es insesgado.

BIAS para la temperatura pronosticada y ajustada con respecto a las observaciones  
Para el entrenamiento se utilizan los últimos 30 días de datos (720 horas)  
y se aplican los coeficientes al primer pronóstico (de 96 horas) que se genera cada mes (train=88%)



**Figura 4.3.1:** BIAS para la temperatura pronosticada (azul) y ajustada (rojo) con respecto a las observaciones. El periodo de evaluación considera desde octubre (2020) hasta agosto (2022).

## Capítulo 5

### Discusión

Los resultados obtenidos muestran el desempeño del pronóstico de temperatura máxima y mínima simulado por MOSA-WRF al ser comparado estadísticamente con las mediciones de las estaciones meteorológicas (sin MOS), mientras que por el otro lado, se compara lo obtenido en el postprocesamiento (con MOS) con las mediciones de las estaciones meteorológicas. Es evidente que utilizar MOS mejora las predicciones en todos los casos, no sólo a nivel de eliminar el sesgo (BIAS) sino que también de mejorar el ajuste ( $R^2$ ) y reducir la variabilidad (RMSE). Estos resultados concuerdan con lo reportado por [Hart et al. \(2004\)](#). Estos autores observaron mejoras significativas en los pronósticos de temperatura cuando se utilizaron métodos estadísticos para calibrar las series de tiempo.

Para que la significancia (p-value) y los intervalos de confianza asociados a los predictores sean precisos, es necesario que los residuos del modelo de regresión lineal sean independientes, con varianza constante y con distribución normal ([Montgomery et al., 2021](#)). Habitualmente, esta última condición se evalúa con contrastes de hipótesis como el Shapiro-Wilk test ([Fisher, 1925](#)). Cuando esto ocurre, es importante entender la relación entre p-value y tamaño de muestra. A mayor número de residuos mayor potencia tiene el test y pequeñas desviaciones de la normalidad resultan significativas. A su vez, el teorema del límite central indica que, cuanto mayor el tamaño de la muestra, más robustos son los resultados frente a desviaciones de la normalidad. Debido a estas propiedades, [Schützenmeister et al. \(2012\)](#) y [Das \(2016\)](#) sugieren evaluar la normalidad de forma gráfica mediante representación de los cuantiles teóricos qq-plot.

La ventaja de MOS es que al satisfacer las condiciones necesarias para la regresión lineal múltiple, se logra conseguir la mejor predicción lineal posible bajo el método de mínimos cuadrados (OLS). Esta propiedad se conoce como el teorema de Gauss-Markov, que establece que si se cumplen los supuestos del modelo de regresión, entonces el coeficiente estimado será el mejor estimador lineal insesgado (Best Linear Unbiased Estimator, BLUE, por sus siglas en inglés) entre todos los coeficientes de la población, tal como lo indica [Liao et al., \(2021\)](#). En este contexto, con la definición de mejor predicción lineal el autor se refiere a minimizar la varianza, ajustando lo máximo posible el pronóstico a las mediciones.

Se empleó una simulación de Monte-Carlo con 10.000 iteraciones donde se remuestran aleatoriamente las series obtenidas tras la calibración (n=699 datos diarios), para evaluar el RMSE, el cual es muy utilizado en estudios internacionales para evaluar la significancia y precisión de los modelos de predicción ([Luo et al., 2018](#)). En este caso se calculó el RMSE para cada iteración y se obtuvo el promedio de los 10.000 valores, consiguiendo valores muy idénticos al RMSE de la serie obtenida originalmente con MOS, al igual que en el estudio de [Lu et al. \(2018\)](#), donde se evaluó el RMSE de las estimaciones de temperaturas máximas y mínimas mensuales con el método de Monte-Carlo utilizando 10.000 iteraciones.

Para los eventos extremos, el método estadístico tuvo mayor capacidad para reproducir las temperaturas máximas extremas en Melinka que en Cucao. Para el caso de las temperaturas mínimas extremas, se sigue el mismo patrón, obteniendo mejor desempeño en Melinka. Lo anterior puede ocurrir debido a que el pronóstico tenía una mayor subestimación en Melinka que en Cucao, y el método se enfoca principalmente en corregir ese error sistemático.

Para que MOS haya funcionado de forma óptima, MOSA-WRF tuvo que mantenerse estable en el tiempo, con la misma versión, resolución, configuración y parametrizaciones físicas. Cualquier inestabilidad en el modelo puede alterar el error sistemático en las series de tiempo extraídas y provocar pronósticos menos precisos, como le ocurrió al sistema de pronóstico RAFS (Regional Analysis and Forecast System) que se le aplicó un método estadístico (MOS) para corregir los resultados del modelo. Sin embargo, el ajuste provocó mayor error en los pronósticos ([Erickson et al., 1991](#)). Es por lo anterior que para este estudio se consideró sólo el periodo de MOSA-WRF con resolución de 3 kilómetros y no se incluyó los datos de la versión anterior (con resolución de 5 kilómetros).

La capacidad de MOS para reducir los errores de sesgo representa uno de los atributos más atractivos de este tipo de procedimiento, que en general es superior a otros tratamientos estadísticos similares (Cheng and Steenburgh, 2007). Aunque también podrían utilizarse otros enfoques de post-procesamiento para mejorar los resultados de los modelos, como el Filtro de Kalman (Homleid, 1995; Majewski 1997) y las redes neuronales (Hsieh and Tang, 1998).

### 5.0.1. MOS operacional

Al contar con las mediciones de temperatura en tiempo real, MOS tiene un gran potencial para ser utilizado de forma operacional, ya que es posible corregir el pronóstico de temperatura a 96 horas que se genera cada día en base a las últimas observaciones. En este caso, Kalnay (2005) recomienda hacer la evaluación mediante una validación cruzada, donde los datos se dividen en datos de entrenamiento y datos de evaluación.

Se realizó una prueba de sensibilidad considerando siempre los últimos 30 días para el entrenamiento. Estos 30 días corresponden a 720 datos horarios, los que van a ocuparse cada día para entrenar el modelo estadístico y obtener sus respectivos coeficientes. Así, el porcentaje de la validación cruzada resulta en 88 % de los datos (720) para el entrenamiento y un 12 % de los datos (96) para la validación, porcentaje muy cercano a lo sugerido por Kalnay (2005), que recomienda utilizar el 90 % de los datos para entrenamiento.

Los resultados muestran que MOS operacional tuvo un gran desempeño en reproducir la temperatura del aire a 2 metros, reduciendo significativamente el error sistemático y la variabilidad del pronóstico original en la mayoría de los casos, excepto cuando el pronóstico es insesgado.

Para hacer efectiva la implementación, principalmente se necesita tener acceso a los servidores donde se almacena el pronóstico de 96 horas generado cada día por MOSA-WRF y los respectivos últimos 30 días de datos horarios de las estaciones meteorológicas. El costo numérico no es tan grande, sólo se requiere automatizar el script de la regresión lineal múltiple, proceso que no demora más de un par de minutos. Además, se necesita implementar ciertas tareas en el servidor (crontab) para que notifique mediante correo electrónico en el caso de que no se genere el pronóstico o en el caso de que no existan mediciones. Considerando todo lo anterior, sí es factible implementar este método de forma operacional.

## Capítulo 6

### Conclusión

En este trabajo se presentó la aplicación de la técnica estadística MOS, una herramienta de post procesamiento utilizada para mejorar las predicciones de temperatura de MOSA-WRF basado en el modelo WRF-ARW V3.9.1.

Se calibraron las series de tiempo históricas (con resolución de 3 km) del pronóstico de temperatura máxima y mínima en dos lugares del sur de Chile, Cucao (42.601°S, 74.123°O) y Melinka (43.897°S, 73.748°O). El periodo considerado desde el 1 de septiembre de 2020 hasta el 1 de agosto de 2022, siendo en total una serie de 699 datos diarios.

En particular, se empleó una regresión lineal múltiple utilizando como variable dependiente las mediciones de temperatura registradas en las estaciones meteorológicas instaladas por el IFOP y como variables independientes las variables simuladas por MOSA-WRF (T2, P, U10, V10) para los puntos correspondientes. Al cumplir los supuestos del método de mínimos cuadrados (OLS) como la normalidad, varianza constante e independencia, los coeficientes de regresión obtenidos son la mejor predicción lineal posible.

Para evaluar el desempeño del método se comparó estadísticamente lo pronosticado y lo calibrado con respecto a las mediciones, utilizando diversos índices tales como el error de sesgo (BIAS), el coeficiente de determinación ( $R^2$ ) y la raíz del error cuadrático medio (RMSE), mostrados a continuación.

### **Temperatura máxima histórica**

En Cucao, el  $R^2$  se mantiene en 0.90, el sesgo se elimina totalmente, reduciéndose de  $-2.2\text{ }^{\circ}\text{C}$  a  $0\text{ }^{\circ}\text{C}$  y el RMSE disminuye de  $1.2\text{ }^{\circ}\text{C}$  a  $0.9\text{ }^{\circ}\text{C}$ .

En Melinka, el  $R^2$  aumenta de 0.88 a 0.89, el sesgo se elimina totalmente, reduciéndose de  $-0.8\text{ }^{\circ}\text{C}$  a  $0\text{ }^{\circ}\text{C}$  y el RMSE disminuye de  $2.8\text{ }^{\circ}\text{C}$  a  $1.5\text{ }^{\circ}\text{C}$ .

### **Temperatura mínima histórica**

En Cucao, el  $R^2$  se mantiene en 0.85, el sesgo se elimina totalmente, reduciéndose de  $-0.7\text{ }^{\circ}\text{C}$  a  $0\text{ }^{\circ}\text{C}$  y el RMSE disminuye de  $1.4\text{ }^{\circ}\text{C}$  a  $1.2\text{ }^{\circ}\text{C}$ .

En Melinka, el  $R^2$  aumenta de 0.87 a 0.89, el sesgo se elimina totalmente, reduciéndose de  $-1.5\text{ }^{\circ}\text{C}$  a  $0\text{ }^{\circ}\text{C}$  y el RMSE disminuye de  $1.8\text{ }^{\circ}\text{C}$  a  $0.9\text{ }^{\circ}\text{C}$ .

De esa forma, queda demostrado que utilizar MOS mejora significativamente los pronósticos históricos de temperatura máxima y mínima en todos los casos, no sólo a nivel de eliminar el sesgo (BIAS) sino que también de mejorar el ajuste ( $R^2$ ) y reducir la variabilidad (RMSE), cumpliendo así el Objetivo Específico 1.

### **Eventos extremos de temperatura**

Con respecto a los eventos extremos, MOS tuvo mayor capacidad para reproducir la temperatura máxima en Melinka que en Cucao, ajustándose a los valores observados en todos los casos. Por otro lado, para los eventos extremos de temperatura mínima, MOS nuevamente obtuvo mejor desempeño en Melinka en comparación con Cucao, cumpliendo así el Objetivo Específico 2.

### **MOS operacional**

Al contar con mediciones de estaciones meteorológicas en tiempo real, MOS tiene un gran potencial para ser utilizado de manera operacional y puede implementarse de forma automatizada para obtener los coeficientes y corregir el pronóstico de temperatura de 96 horas que MOSA genera cada día.

Se realizó una prueba de sensibilidad considerando los respectivos últimos 30 días como entrenamiento (720 datos horarios), y los coeficientes fueron aplicados en el pronóstico de temperatura de 96 horas de cada día. De esa forma, el porcentaje de la validación cruzada se divide en 88 % de los datos para el entrenamiento y 12 % de los datos para la evaluación.

Para evaluar el desempeño de MOS operacional, se comparó lo pronosticado y lo ajustado con respecto a lo medido por las estaciones para el primer día de cada mes, desde septiembre de 2020 hasta agosto de 2022 (23 meses), donde el error sistemático y la variabilidad se reduce significativamente en la mayoría de los casos, excepto cuando el pronóstico es insesgado.

Los resultados obtenidos en esta investigación son prometedores y pueden ser utilizados en diferentes ámbitos de la geofísica. De esa forma, se cumple con el Objetivo Específico 3 y se concluye que MOS es una gran herramienta para mejorar el pronóstico de los modelos de predicción meteorológica e implementar esta corrección de forma operacional sería de gran ayuda para mitigar el impacto de los eventos extremos de temperatura.

Como trabajo futuro puede implementarse un pronóstico MOS grillado de precipitación para toda la Patagonia Chilena. Aunque en ese caso se debe contar con muchas más estaciones meteorológicas y debe realizarse un buen control de calidad de los datos. Además, se debe emplear otro método de regresión debido a que la precipitación no sigue una distribución normal por lo que el método de mínimos cuadrados (OLS) no sería el más eficiente.

## Bibliografía

- [1] Arakawa, A. and Lamb, V. R. (1981). A potential enstrophy and energy conserving scheme for the shallow water equations. *Monthly Weather Review*, 109(1):18–36.
- [2] Artal, O., Venegas, O., Besoain, V., Ruiz, C., Salas, M., and Valdebenito, P. (2021). Informe final - desarrollo de sistema de predicción sinóptico de circulación marina, etapa vii. subsecretaría de economía y emt / octubre 2021.
- [3] Barker, D., Huang, W., Guo, Y., Bourgeois, A., and Xiao, A. (2004). A Three-Dimensional Variational Data Assimilation System for MM5: Implementation and Initial Results. *Monthly Weather Review*, 132.
- [4] Barros, S. (2022). Patagonia chilena en grandes cifras. *Ciencia & Investigación Forestal*, 28(1):81–99.
- [5] Bauer, P., Thorpe, A., and Brunet, G. (2015). The quiet revolution of numerical weather prediction. *Nature*, 525(7567):47–55.
- [6] Calvo, F. J. (2018). Modelos atmosféricos: Física del caos en la predicción meteorológica. *Agencia Estatal de Meteorología*, 1:129–143.
- [7] Carter, G., Dallavalle, J., and Glahn, H. (1989). Statistical forecasts based on the national meteorological center's numerical weather prediction system. *Weather and Forecasting*, 4(3):401–412.
- [8] Charba, J. (2011). High-Resolution GFS-Based MOS Quantitative Precipitation Forecasts on a 4-km Grid. *Monthly Weather Review*, 139(1):39 – 68.
- [9] Charney, J. G., Fjørtoft, R., and Neumann, J. (1950). Numerical integration of the barotropic vorticity equation. *Tellus*, 2(4):237–254.
- [10] Che, Y., Peng, X., Delle, L., Kawaguchi, T., and Xiao, F. (2016). A wind power forecasting system based on the weather research and forecasting model and Kalman filtering over a wind-farm in Japan. *Journal of Renewable and Sustainable Energy*, 8(1):13302.
- [11] Cheng, W. Y. Y. and Steenburgh, W. J. (2007). Strengths and weaknesses of

- 
- MOS, running-mean bias removal, and kalman filter techniques for improving model forecasts over the western united states. *Weather and Forecasting*, 22(6):1304–1318.
- [12] Courtier, P., Andersson, E., Heckley, W., Vasiljevic, D., Hamrud, M., Hollingsworth, A., Rabier, F., Fisher, M., and Pailleux, J. (1998). The ECMWF implementation of three-dimensional variational assimilation (3D-Var). I: Formulation. *Quarterly Journal of the Royal Meteorological Society*, 124(550):1783–1807.
- [13] Das, K. R. (2016). A brief review of tests for normality. *American Journal of Theoretical and Applied Statistics*, 5(1):5.
- [14] Dennstaedt, S. (2008). Model Output Statistics Provide Essential Data for Small Airports. *NOAA's National Weather Service*, 6(2):1–11.
- [15] Déqué, M., Drevet, c., Braun, A., and Cariolle, D. (1994). The ARPEGE/IFS atmosphere model: a contribution to the french community climate modelling. *Climate Dynamics*, 10(4-5):249–266.
- [16] Diagne, M., David, M., Boland, J., Schmutz, N., and Lauret, P. (2014). Post-processing of Solar Irradiance Forecasts from WRF Model at Reunion Island. *Energy Procedia*, 57:1364–1373.
- [17] Dudhia, J. (1989). Numerical Study of Convection Observed during the Winter Monsoon Experiment Using a Mesoscale Two-Dimensional Model. *Journal of Atmospheric Sciences*, 46(20).
- [18] Dudhia, J. (1993). A nonhydrostatic version of the penn state–ncar mesoscale model: Validation tests and simulation of an atlantic cyclone and cold front. *Monthly Weather Review*, 121(2):1493–1513.
- [19] Dudhia, J. (1996). A Multi-layer Soil Temperature Model for MM5. *6th Annual MM5 Users Workshop, Boulder*, 1:49–50.
- [20] Erickson, M., Brent, J., Dagostaro, V., Dallavalle, J. P., Jacks, E., John, S., Jensenius, J., and Su, J. (1991). Evaluating the Impact of RAFS Changes on the NGM-Based MOS Guidance. *Weather and Forecasting*, 6(1):142–147.
- [21] Falvey, M. and Garreaud, R. (2007). Wintertime precipitation episodes in central chile: Associated meteorological conditions and orographic influences. *Journal of Hydrometeorology*, 8(2):171–193.
- [22] Fisher, R. A. (1925). *Statistical methods for research workers*. Oliver & Boyd.
- [23] Garreaud, R. (2013). Warm winter storms in central chile. *Journal of Hydrometeorology*, 14(5):1515–1534.

- 
- [24] Glahn, H. and Lowry, D. (1972). The use of Model Output statistics (MOS) in objective weather forecasting. *Journal of Applied Meteorology*, 11(8):1203–1211.
- [25] Grabowski, W. W., Morrison, H., Shima, S.-I., Abade, G. C., Dziekan, P., and Pawlowska, H. (2019). Modeling of cloud microphysics: Can we do better? *Bulletin of the American Meteorological Society*, 100(4):655–672.
- [26] Grell, G. A., D. J. . S. D. (1994). A description of the fifth-generation penn state/ncar mesoscale model (mm5). Technical report.
- [27] Hart, K. A., Steenburgh, W. J., Onton, D. J., and Siffert, A. J. (2004). An evaluation of mesoscale-model-based model output statistics (MOS) during the 2002 Olympic and Paralympic Winter Games. *Weather Forecasting*, 19:200–218.
- [28] Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., and Horányi, A. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146(730):1999–2049.
- [29] Herzog, A. G. and Vogel, F. R. (2012). An application of robust parameter estimation in environmental physics. In *Contributions in Mathematical and Computational Sciences*, pages 287–309. Springer Berlin Heidelberg.
- [30] Hess, P. and Boers, N. (2022). Deep learning for improving numerical weather prediction of heavy rainfall. *Journal of Advances in Modeling Earth Systems*, 14(3).
- [31] Hoke, J. E., Phillips, N. A., Dimego, G. J., Tuccillo, J. J., and Sela, J. G. (1989). The regional analysis and forecast system of the national meteorological center. *Weather and Forecasting*, 4(3):323–334.
- [32] Homleid, M. (1995). Diurnal corrections of short-term surface temperature forecasts using the kalman filter. *Weather and Forecasting*, 10(4):689–707.
- [33] Hsieh, W. W. and Tang, B. (1998). Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin of the American Meteorological Society*, 79(9):1855–1870.
- [34] Huang, X., Xiao, Q., Barker, D., Zhang, X., Michalakes, J., Huang, W., Henderson, T., Bray, J., Chen, Y., Ma, Z., Dudhia, J., and Guo, Y. (2009). Four-Dimensional Variational Data Assimilation for WRF: Formulation and Preliminary Results. *Monthly Weather Review*, 137:299–314.
- [35] Huber, P. J. (1981). *Robust Statistics*. John Wiley & Sons, Inc.
- [36] Instituto Chileno de Campos de Hielos, I. (2022). Campos de hielos, Área geográfica. En: <https://www.camposdehielo.cl/area-geografica/1548930031630-62fd5fbf-63b9>. (Consulta: Enero, 2023).

- 
- [37] Kain, J. S. (2004). The Kain–Fritsch Convective Parameterization: An Update. *Journal of Applied Meteorology*, 43(1):170 – 181.
- [38] Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *J. Basic Eng.*, 82:35–45.
- [39] Kalman, R. E. and Bucy, R. S. (1961). New results in linear filtering and prediction theory. *J. Basic Eng.*, 83:95–108.
- [40] Kalnay, E. (2003). Atmospheric modeling, data assimilation and predictability. *Cambridge University Press*.
- [41] Klemp, J. B. and Wilhelmson, R. B. (1978). The simulation of three-dimensional convective storm dynamics. *Journal of the Atmospheric Sciences*, 35(6):1070–1096.
- [42] Lazić, R., Pejanović, G., Živković, M., and Ilić, L. (2014). Improved wind forecasts for wind power generation using the Eta model and MOS (Model Output Statistics) method. *Energy*, 73:567–574.
- [43] Liao, K., Park, E., Zhang, J., Cheng, L., Ji, D., Ying, Q., and Yu, J. (2021). A multiple linear regression model with multiplicative log-normal error term for atmospheric concentration data. *Science of The Total Environment*, 767:144282.
- [44] Lorenz, E. N. (1963). Deterministic nonperiodic flow. *Journal of Atmospheric Sciences*, 20(2):130 – 141.
- [45] Lu, N., Liang, S., Huang, G., Qin, J., Yao, L., Wang, D., and Yang, K. (2018). Hierarchical bayesian space-time estimation of monthly maximum and minimum surface air temperature. *Remote Sensing of Environment*, 211:48–58.
- [46] Luo, L., Hamilton, D., Lan, J., McBride, C., and Trolle, D. (2018). Autocalibration of a one-dimensional hydrodynamic-ecological model (DYRESM 4.0-CAEDYM 3.1) using a monte carlo approach: simulations of hypoxic events in a polymictic lake. *Geoscientific Model Development*, 11(3):903–913.
- [47] Majewski, D. (1997). Operational regional prediction. *Meteorology and Atmospheric Physics*, 63(1-2):89–104.
- [48] Mass, C. F., Ovens, D., Westrick, K., and Colle, B. A. (2002). Does increasing horizontal resolution produce more skillful forecasts? The results of two years of real-time numerical weather prediction over the Pacific Northwest. *Bull. Amer. Meteor. Soc.*, 83:407–430.
- [49] Matsueda, M., Kyouda, M., Tanaka, H., and Tsuyuki, T. (2007). Daily Forecast Skill of Multi-Center Grand Ensemble. *SOLA*, 3:29–32.

- 
- [50] Misra, V. (2007). Addressing the issue of systematic errors in a regional climate model. *Journal of Climate*, 20(5):801–818.
- [51] Mlawer, E., Taubman, S., Brown, P., Iacono, M., and Clough, S. (1997). Radiative transfer for inhomogeneous atmospheres: RRTM, a validated correlated-k model for the longwave. *Journal of Geophysical Research*, 102:16663–16682.
- [52] Montgomery, D. C., Peck, E. A., and Vining, G. G. (2021). *Introduction to linear regression analysis*. John Wiley & Sons.
- [53] Mooney, C. (1997). *Monte Carlo Simulation*. SAGE Publications, Inc.
- [54] Muñoz, K. (2015). Estimación de ablación en glaciares de Chile Central: Análisis del efecto del albedo en su modelación con WRF. *Universidad de Concepción, Concepción, Chile*.
- [55] NCEP (2015a). Ncep gdas/fnl 0.25 degree global tropospheric analyses and forecast grids.
- [56] NCEP (2015b). Ncep gfs 0.25 degree global forecast grids historical archive.
- [57] Oosthuizen, C., Van Wyk, B., Hamam, Y., Desai, D., and Alayli, Y. (2020). The Use of Gridded Model Output Statistics (GMOS) in Energy Forecasting of a Solar Car. *Energies*, 13(8):1–16.
- [58] Paegle, J., Yang, Q., and Wang, M. (1997). Predictability in limited area and global models. *Meteor. Atmos. Phys.*, 63:53–69.
- [59] Palmer, T. and Hagedorn, R. (1972). *Predictability of weather and climate*. Cambridge University Press.
- [60] Pantoja, S., Iriarte, J. L., and Daneri, G. (2011). Oceanography of the chilean patagonia. *Continental Shelf Research*, 31(3-4):149–153.
- [61] Petetin, H., Bowdalo, D., Bretonnière, P. A., Guevara, M., Jorba, O., Armengol, J. M., Samsó Cabre, M., Serradell, K., Soret, A., and Pérez Garcia-Pando, C. (2021). Model Output Statistics (MOS) applied to CAMS O3 forecasts: trade-offs between continuous and categorical skill scores. *Atmospheric Chemistry and Physics*.
- [62] Pielke, R. A. (1984). *Mesoscale Meteorological Modeling*. Orlando, Academic Press.
- [63] Pierro, M., Bucci, F., Cornaro, C., Maggioni, E., Perotto, A., Pravettoni, M., and Spada, F. (2015). Model output statistics cascade to improve day ahead solar irradiance forecast. *Solar Energy*, 117:99–113.

- 
- [64] Pistoia, J., Pinardi, N., Oddo, P., Collins, M., Korres, G., and Drillel, Y. (2016). Development of Super-ensemble Techniques for Ocean Analyses: The Mediterranean Sea Case. *Natural Hazards and Earth System Science*, 16:1807–1819.
- [65] Reche, P., Artal, O., Pinilla, E., Ruiz, C., Venegas, O., Arriagada, A., and Falvey, M. (2021). CHONOS: Oceanographic information website for chilean patagonia. *Ocean & Coastal Management*, 208:105634.
- [66] Ritchie, H., Temperton, C., Simmons, A., Hortal, M., Davies, T., Dent, D., and Hamrud, M. (1995). Implementation of the semi-lagrangian method in a high-resolution version of the ECMWF forecast model. *Monthly Weather Review*, 123(2):489–514.
- [67] Rixen, M., Le Gac, J. C., Hermand, J. P., Peggion, G., and Coelho, E. (2009). Super-ensemble Forecast and Resulting Acoustic Sensitivities in Shallow Waters. *Journal of Marine Systems*, 78:290–305.
- [68] Rousseeuw, P. J. (1984). Least median of squares regression. *Journal of the American Statistical Association*, 79(388):871–880.
- [69] Ruiz, C., Artal, O., Pinilla, O., and Sepúlveda, H. H. (2021). Stratification and mixing in the chilean inland sea using an operational model. *Ocean Modelling*, 158:101750.
- [70] Ruth, D. P., Glahn, B., Dagostaro, V., and Gilbert, K. (2009). The Performance of MOS in the Digital Age. *Weather and Forecasting*, 24(2):504–519.
- [71] Saha, S., Moorthi, S., and Pan, H. (2010). The NCEP climate forecast system reanalysis. *Bulletin of the American Meteorological Society*, 91(8):1015–1058.
- [72] Schaake, J., Demargne, J., Hartman, R., Mullusky, M., Welles, E., Wu, L., Herr, H., Fan, X., and Seo, D. (2007). Precipitation and temperature ensemble forecasts from single-value forecasts. *Hydrology and Earth System Sciences*, 4:655–717.
- [73] Scheuerer, M. and Möller, D. (2015). "probabilistic wind speed forecasting on a grid based on ensemble model output statistics". *The Annals of Applied Statistics*, 9(3):1328–1349.
- [74] Schützenmeister, A., Jensen, U., and Piepho, H.-P. (2012). Checking normality and homoscedasticity in the general linear model using diagnostic plots. *Communications in Statistics - Simulation and Computation*, 41(2):141–154.
- [75] Seabold, S. and Perktold, J. (2010). Statsmodels: Econometric and statistical modeling with python. In *9th Python in Science Conference*.

- 
- [76] Sepúlveda, C. (2020). Línea de base social de las Áreas protegidas de la patagonia chilena. *Programa Austral Patagonia de la Universidad Austral de Chile*, 1(1):308.
- [77] Shin, Y. (2019). Statistical Downscaling of Urban-scale Air Temperatures Using an Analog Model Output Statistics Technique. *Atmosphere*, 10(8):427.
- [78] Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Barker, D., Duda, M. G., and Powers, J. G. (2008). A Description of the Advanced Research WRF Version 3 (No. NCAR/TN-475+STR). *University Corporation for Atmospheric Research*.
- [79] Söderström, T. (1974). Convergence properties of the generalised least squares identification method. *Automatica*, 10(6):617–626.
- [80] Sugimoto, S., Crook, N., Sun, J., Xiao, Q., and Barker, D. (2009). An Examination of WRF 3DVAR Radar Data Assimilation on Its Capability in Retrieving Unobserved Variables and Forecasting Precipitation through Observing System Simulation Experiments. *Monthly Weather Review*, 137:4011–4029.
- [81] Sukoriansky, S., Galperin, B., and Perov, V. (2005). Application of a New Spectral Theory of Stably Stratified Turbulence to the Atmospheric Boundary Layer over Sea Ice. *Boundary-Layer Meteorology*, 117:231–257.
- [82] Sánchez, O. R., Ordoñez, C. G., Muñoz, G., Llacza, A., Andrade, M. F., Liu, Y., Reátegui-Romero, W., and Brasseur, G. (2018). Modeling Study of the Particulate Matter in Lima with the WRF-Chem Model: Case Study of April 2016. *International Journal of Applied Engineering Research*, 13(11):10129–10141.
- [83] Thompson, G., Field, P., Rasmussen, R., and Hall, W. (2008). Explicit Forecasts of Winter Precipitation Using an Improved Bulk Microphysics Scheme. Part II: Implementation of a New Snow Parameterization. *Monthly Weather Review*, 136(12):5095 – 5115.
- [84] Veenhuis, B. (2013). Spread Calibration of Ensemble MOS Forecasts. *Monthly Weather Review*, 141(7).
- [85] Venegas, O. (2016). Efecto de la topografía de alta resolución en las salidas de simulaciones numéricas de la atmósfera para los fiordos y canales de la Región de Aysén. *Universidad de Concepción, Concepción, Chile*.
- [86] Viale, M. and Garreaud, R. (2015). Orographic effects of the subtropical and extratropical andes on upwind precipitating clouds. *Journal of Geophysical Research: Atmospheres*, 120(10):4962–4974.
- [87] Viale, M., Valenzuela, R., Garreaud, R., and Ralph, M. (2018). Impacts

- 
- of atmospheric rivers on precipitation in southern south america. *Journal of Hydrometeorology*, 19(10):1671–1687.
- [88] Wilks, D. S. (1995). Statistical methods in the atmospheric sciences. *Academic Press*, page 464.
- [89] Wilks, D. S. and Hamill, T. M. (2007). Comparison of Ensemble-MOS Methods Using GFS Reforecasts. *Monthly Weather Review*, 135(6):2379 – 2390.
- [90] Willmott, C. J. and Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1):79–82.
- [91] Wu, L., Seo, D., Demargne, J., Brown, J., Cong, S., and Schaake, J. (2011). Generation of ensemble precipitation forecast from single-valued quantitative precipitation forecast for hydrologic ensemble prediction. *Journal of Hydrology*, 399:281–298.
- [92] Yang, T., Gallagher, C. M., and McMahan, C. S. (2018). A robust regression methodology via m-estimation. *Communications in Statistics - Theory and Methods*, 48(5):1092–1107.
- [93] Zhao, J., Xu, J., Xie, X., and Lu, H. (2016). Drought Monitoring Based on TIGGE and Distributed Hydrological Model in Huaihe River Basin, China. *Science of The Total Environment*, 553:358–365.

## A1. Física del modelo WRF

Las ecuaciones que describen la dinámica de un fluido viscoso son las ecuaciones de Navier Stokes (derivadas parciales no-lineales), mientras que las ecuaciones de Euler son una simplificación de las de Navier-Stokes, despreciando los efectos de la viscosidad y de la conductividad térmica, facilitando así la descripción de los flujos atmosféricos y su computación. Las ecuaciones de Euler comprenden las leyes de Newton, la ley de la termodinámica (conservación de la energía), la ecuación de continuidad (conservación de la masa) y la ley de los gases ideales. Además, se utilizan ecuaciones de conservación para el vapor de agua, agua de nube líquida y en forma de hielo, y para los distintos tipos de precipitación. Entonces, los modelos vienen siendo una representación computacional física y dinámica de la atmósfera y de la superficie terrestre. De tal forma, se plantea un conjunto de principios de conservación que gobiernan la atmósfera, y que se detallan a continuación en un sistema de referencia cartesiano y con notación tensorial (se utiliza la notación de Einstein para la suma).

### ■ Ecuación de estado:

$$p = \rho r_d T_V \quad (\text{A1.1})$$

- $p$  es la presión atmosférica.
- $r_d$  es la constante termodinámica del aire seco.
- $T_V$  es la temperatura virtual del aire.

### ■ Conservación de la masa:

$$\frac{\partial u_i}{\partial x_i} = -\frac{1}{\rho} \frac{d\rho}{dt} \quad (\text{A1.2})$$

- $x_{i=1,2,3}$  son las tres coordenadas espaciales.
- $t$  es el tiempo.
- $u_{i=1,2,3}$  son las tres componentes del vector viento.
- $\rho$  es la densidad del aire.

■ **Conservación de momentum:**

$$\frac{\partial}{\partial t} \rho u_i + \frac{\partial}{\partial x_j} \rho u_j u_i = -\frac{\partial p}{\partial x_i} + \frac{\partial}{\partial x_j} \left[ \mu \left( \frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) - \frac{2}{3} \mu \frac{\partial u_k}{\partial x_k} \delta_{ij} \right] + \rho g_i - 2\rho \epsilon_{ijk} \Omega_j u_k \quad (\text{A1.3})$$

- $\mu$  es la viscosidad molecular del aire.
- $g_i$  es el vector aceleración de gravedad (0,0,-g).
- $\Omega_i$  es el vector de la velocidad angular de la Tierra.
- $\delta_{ij}$  es el delta de Kronecker.
- $\epsilon_{ijk}$  es el tensor de Levi-Civita.

■ **Conservación de la energía:**

$$\delta c = \delta w_T + \delta u_e = \frac{S_c}{\rho} dt \quad (\text{A1.4})$$

- $\delta c$  es el calor por unidad de masa en cierto volumen de aire, que se intercambia durante un proceso.
- $\delta w_T$  es el trabajo por unidad de masa ejercido por el volumen de aire.
- $\delta u_e$  es la variación de energía interna por unidad de masa del volumen de aire durante el proceso.
- $S_c$  es el término de fuentes y sumideros por unidad de volumen y tiempo

■ **Conservación del vapor de agua, del agua líquida y sólida:**

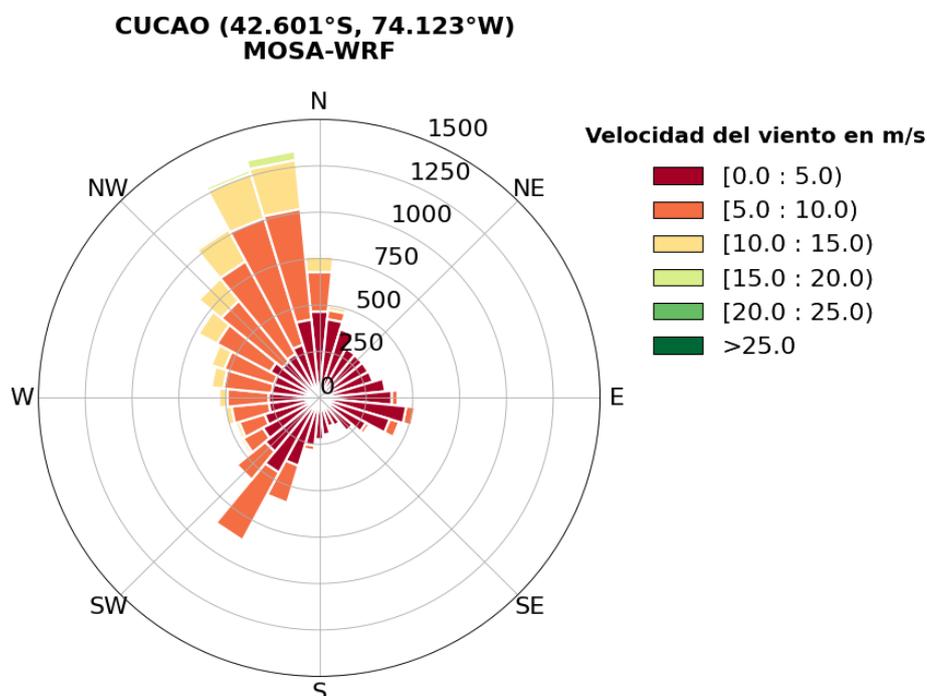
$$\frac{\partial}{\partial t} \rho \chi + \frac{\partial}{\partial x_j} \rho u_j \chi = D_\chi \frac{\partial^2 \rho \chi}{\partial x_j^2} + S_\chi \quad (\text{A1.5})$$

- $\chi$  es la relación de masa de un componente de la atmósfera (valor de agua, agua líquida o hielo)
- $D_\chi$  es la difusividad molecular del respectivo componente.
- $S_\chi$  es el término de fuentes y sumideros adecuado a cada sustancia (relacionado con los cambios de fase y precipitación).

## A2. Rosa de los vientos simulada por MOSA-WRF

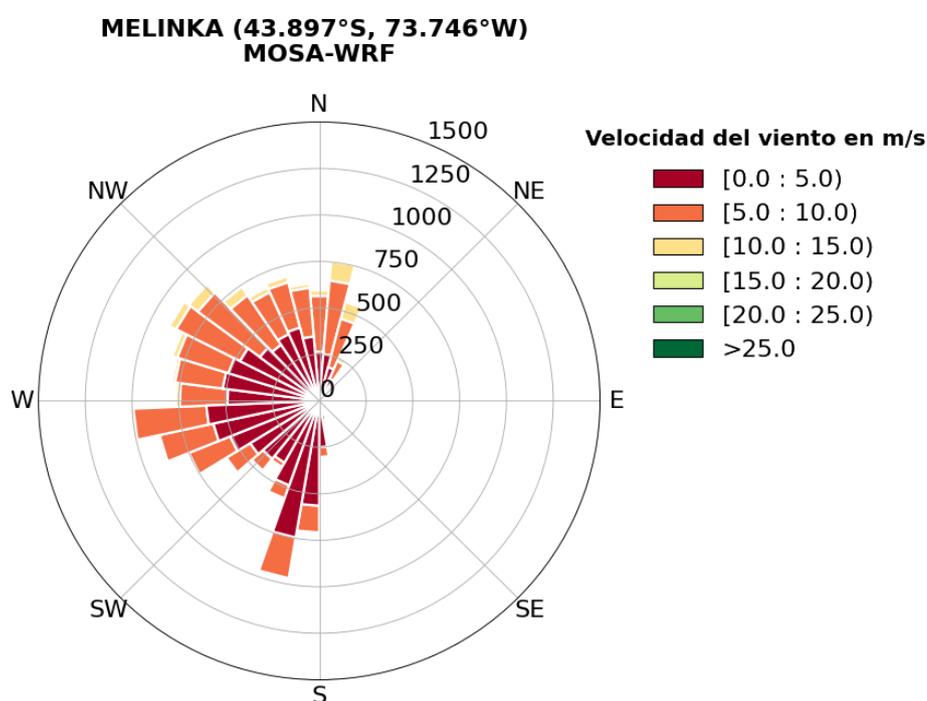
Con respecto a los vientos que fueron utilizados como variables predictoras, se verifica qué componente predomina en cada lugar. Así, se calcula la intensidad y la dirección del viento en cada hora a partir de las componentes U10 y V10 simuladas. En meteorología la dirección del viento se considera desde donde fluye, y aumenta en sentido horario, de modo que un viento del norte es  $0^\circ$ , un viento del este es  $90^\circ$ , un viento del sur es  $180^\circ$  y un viento del oeste es  $270^\circ$ .

En la **Figura A2.1** se muestra la rosa de los vientos simulada por MOSA para la estación Cucao considerando casi 2 años de datos horarios. El periodo comprende desde el 1 de septiembre del 2020 hasta el 1 de agosto del 2022 considerando en total 16.773 datos. Se puede observar que durante la mayor parte del tiempo predomina la dirección nor-noroeste (NNW), coincidiendo con lo expuesto por [Garreaud \(2013\)](#), que menciona que en la Patagonia chilena predominan los vientos del oeste durante todo el año. En la rosa de los vientos se alcanzan intensidades máximas simuladas de 20 [m/s] y las intensidades con mayor frecuencia se registran entre los 5 - 10 [m/s] y 10 - 15 [m/s].



**Figura A2.1:** Rosa de vientos simulada por MOSA para la estación CUCAO. Se observan 16.776 datos horarios desde septiembre de 2020 hasta agosto de 2022.

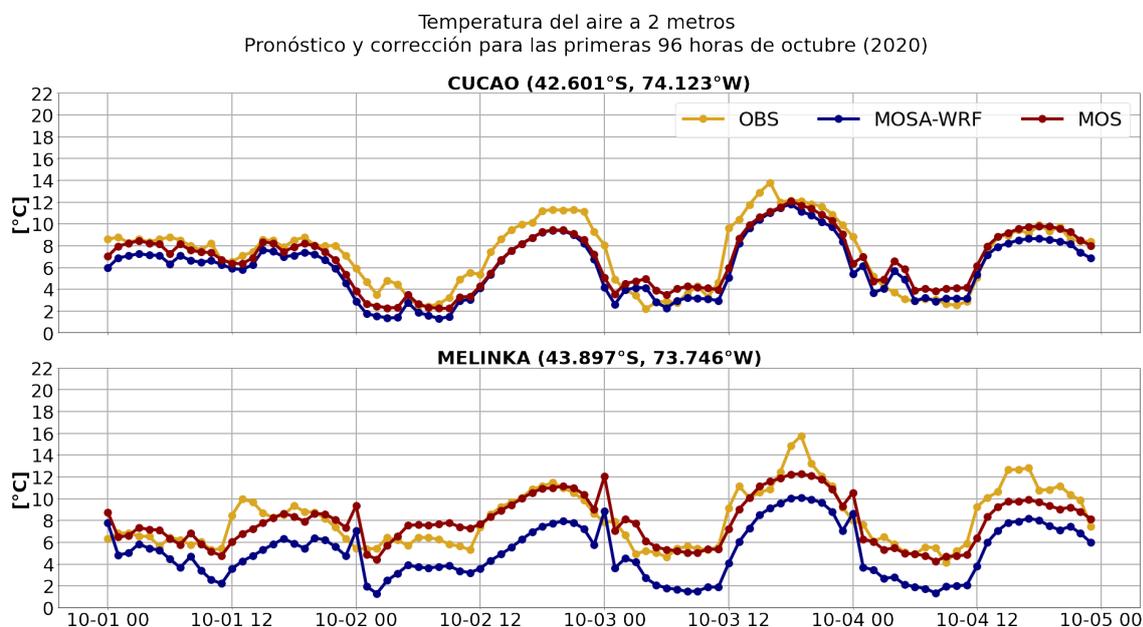
Por otro lado, en la **Figura A2.2** se muestra la rosa de los vientos simulada por MOSA para la estación Melinka considerando el mismo periodo de tiempo. Se puede observar que durante la mayor parte del tiempo predomina la dirección oeste, coincidiendo nuevamente con lo expuesto por [Garreaud \(2013\)](#) sobre los vientos predominantes en la Patagonia. Las intensidades máximas simuladas alcanzan hasta 10 - 15 [m/s], mientras que las intensidades con mayor frecuencia están entre 5 - 10 [m/s] y por último 0 - 5 [m/s].



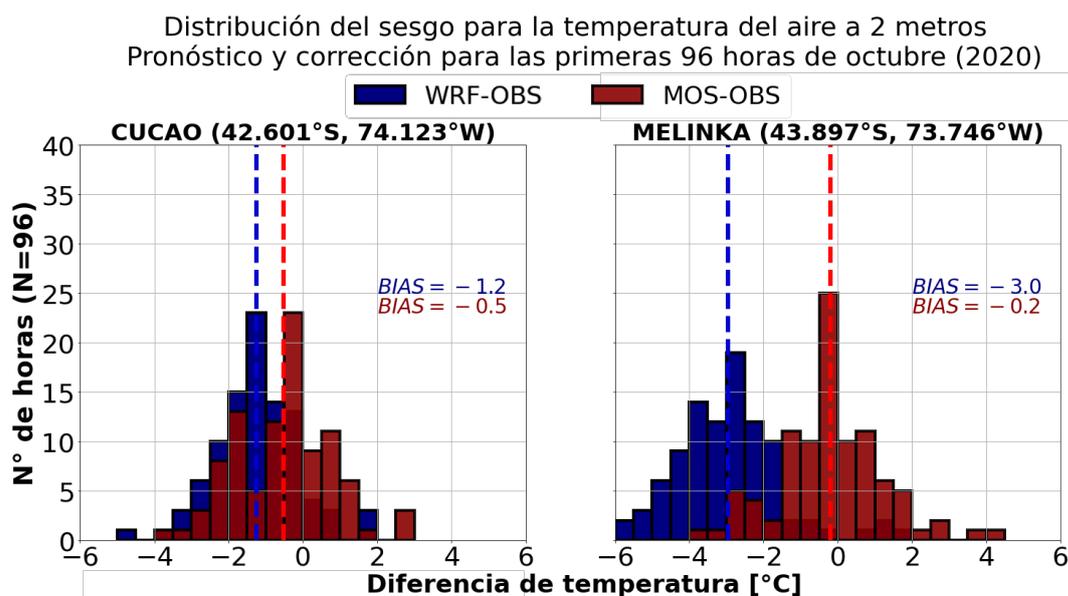
**Figura A2.2:** Rosa de vientos simulada por MOSA para la estación MELINKA. Se observan 16.776 datos horarios desde septiembre de 2020 hasta agosto de 2022.

## A3. MOS Operacional

### A3.1. Pronóstico generado el 1 de octubre de 2020.

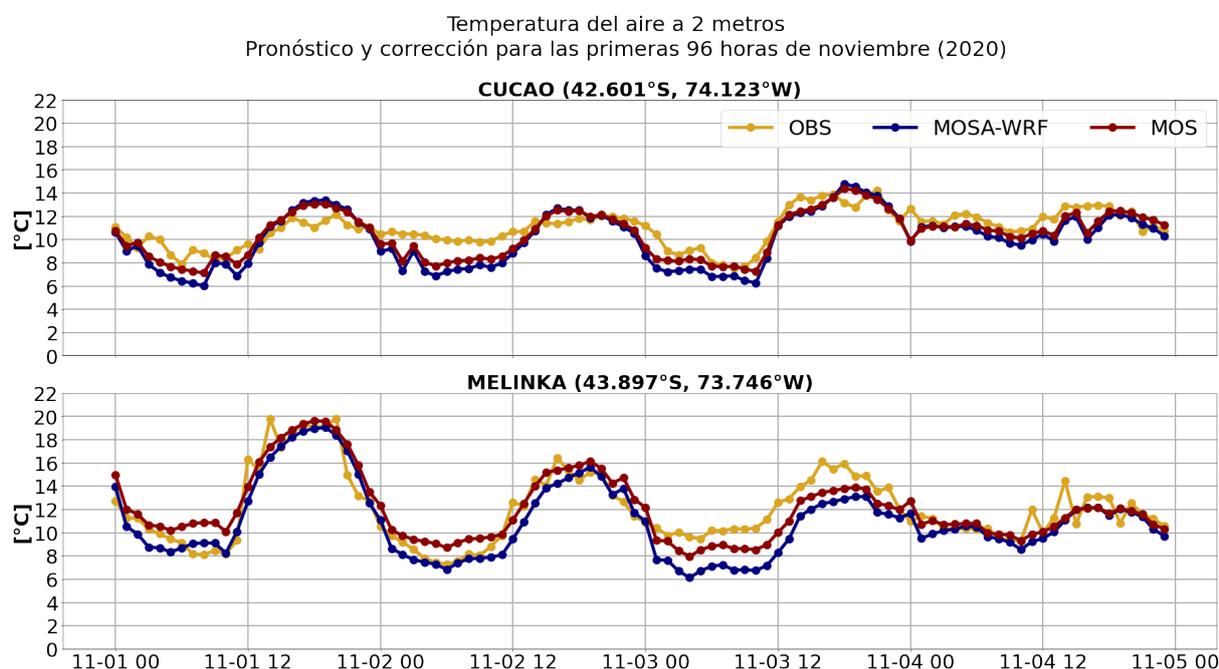


**Figura A3.1:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de octubre de 2020 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

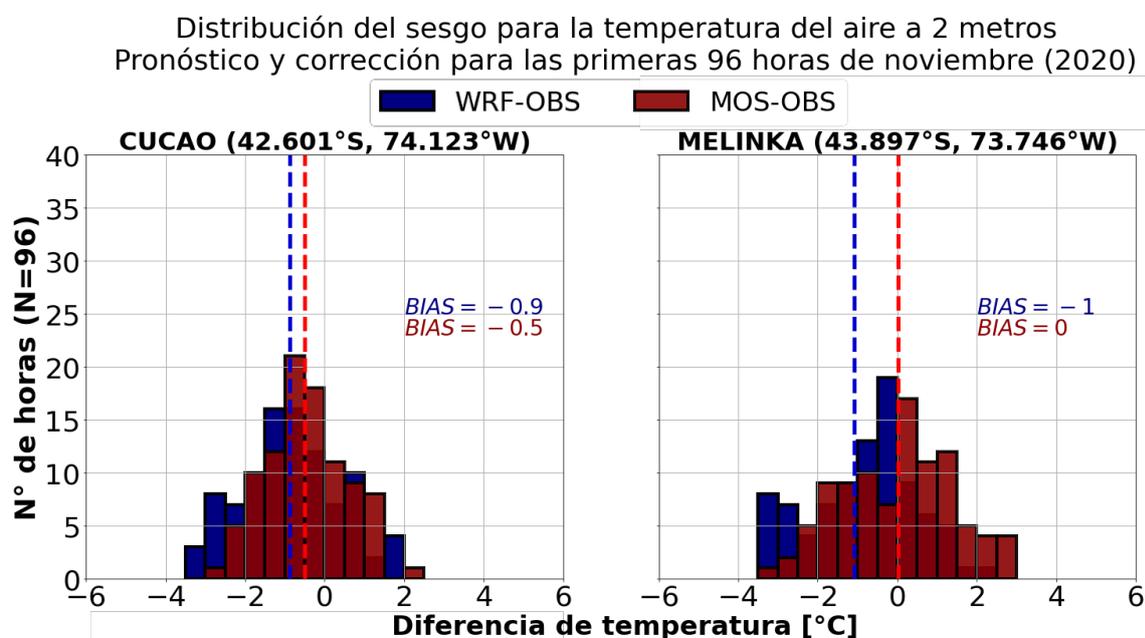


**Figura A3.2:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de octubre de 2020 hasta el 4 de octubre de 2020 (96 datos horarios).

### A3.2. Pronóstico generado el 1 de noviembre de 2020.

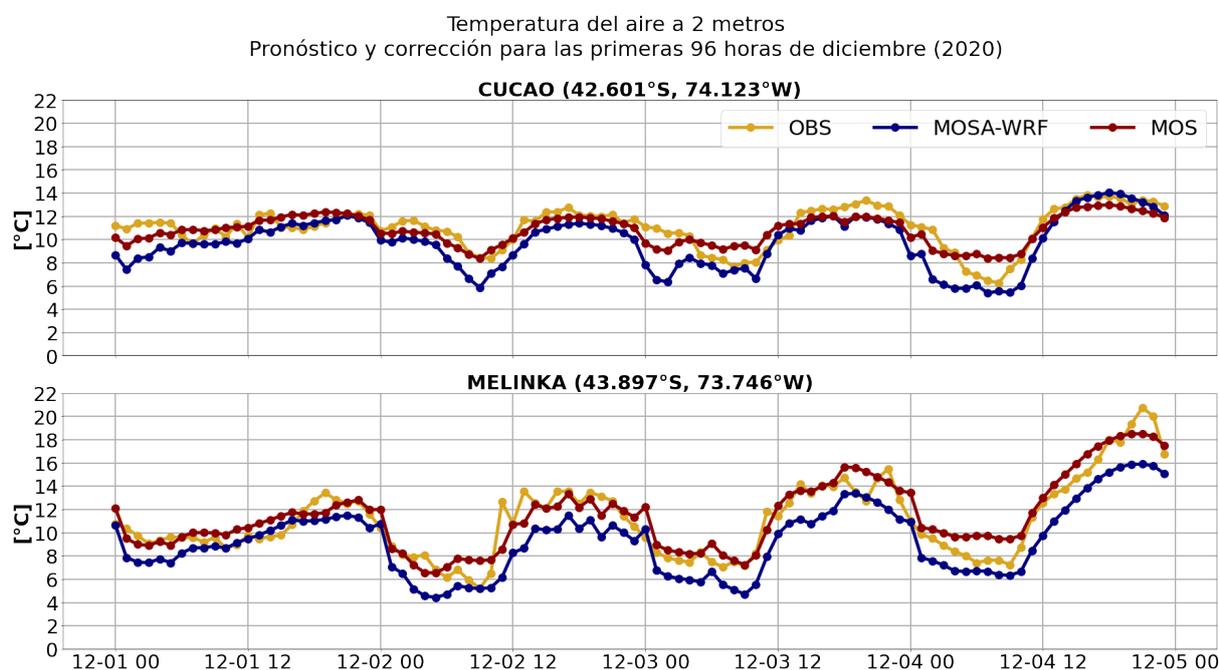


**Figura A3.3:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de noviembre de 2020 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

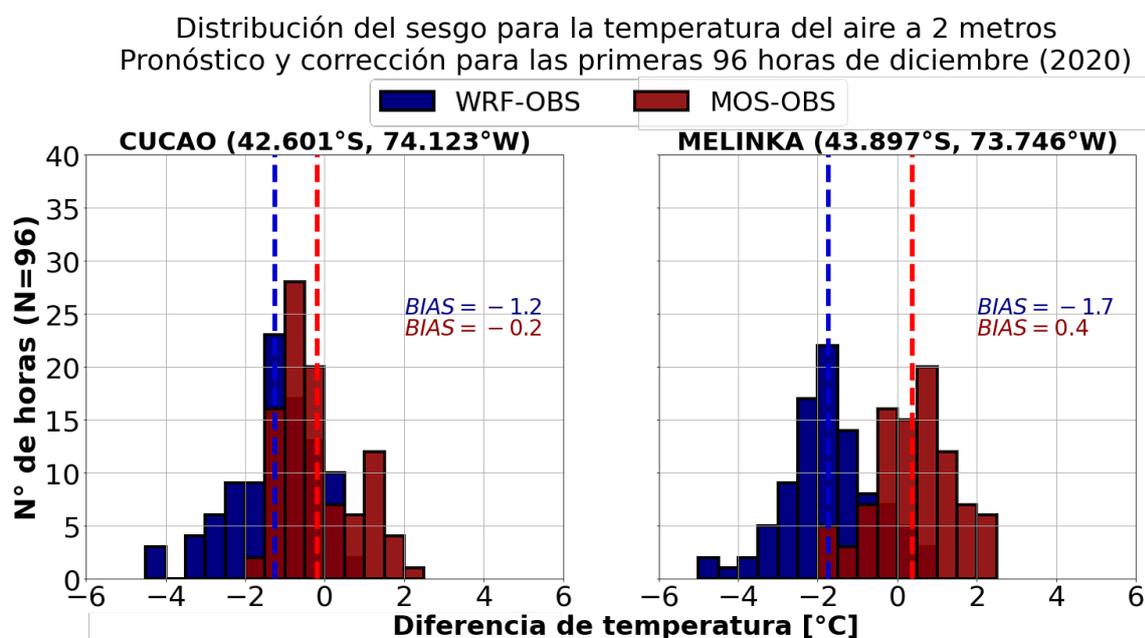


**Figura A3.4:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de noviembre de 2020 hasta el 4 de noviembre de 2020 (96 datos horarios).

### A3.3. Pronóstico generado el 1 de diciembre de 2020.

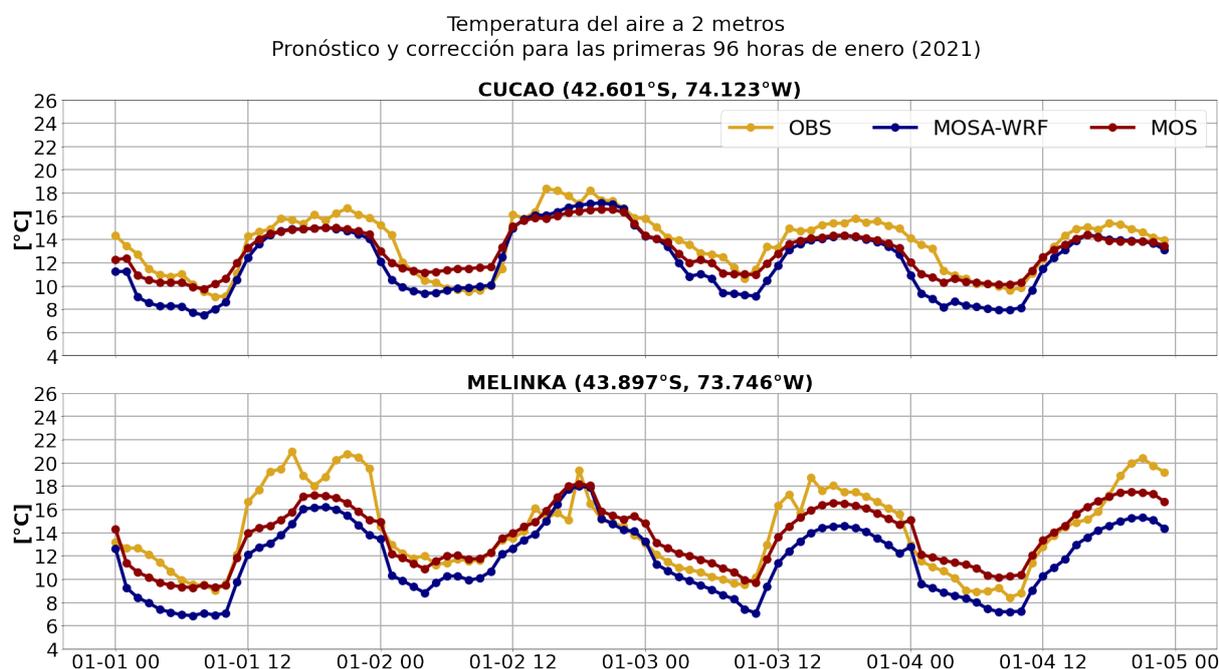


**Figura A3.5:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de diciembre de 2020 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

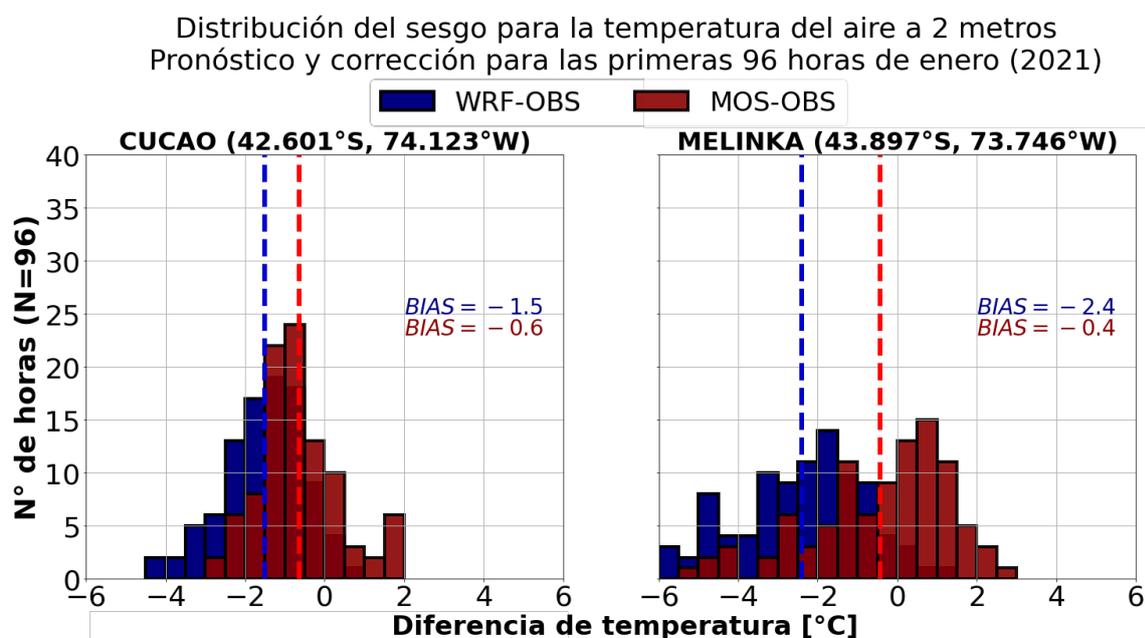


**Figura A3.6:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de diciembre de 2020 hasta el 4 de diciembre de 2020 (96 datos horarios).

### A3.4. Pronóstico generado el 1 de enero de 2021.

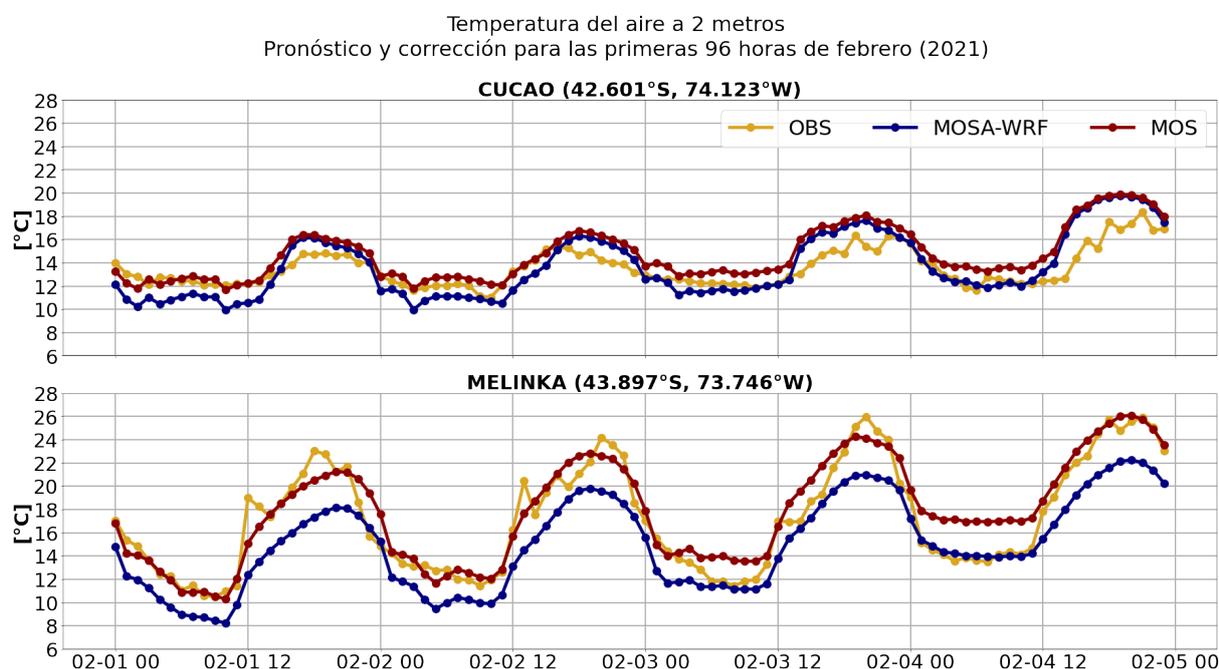


**Figura A3.7:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de enero de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

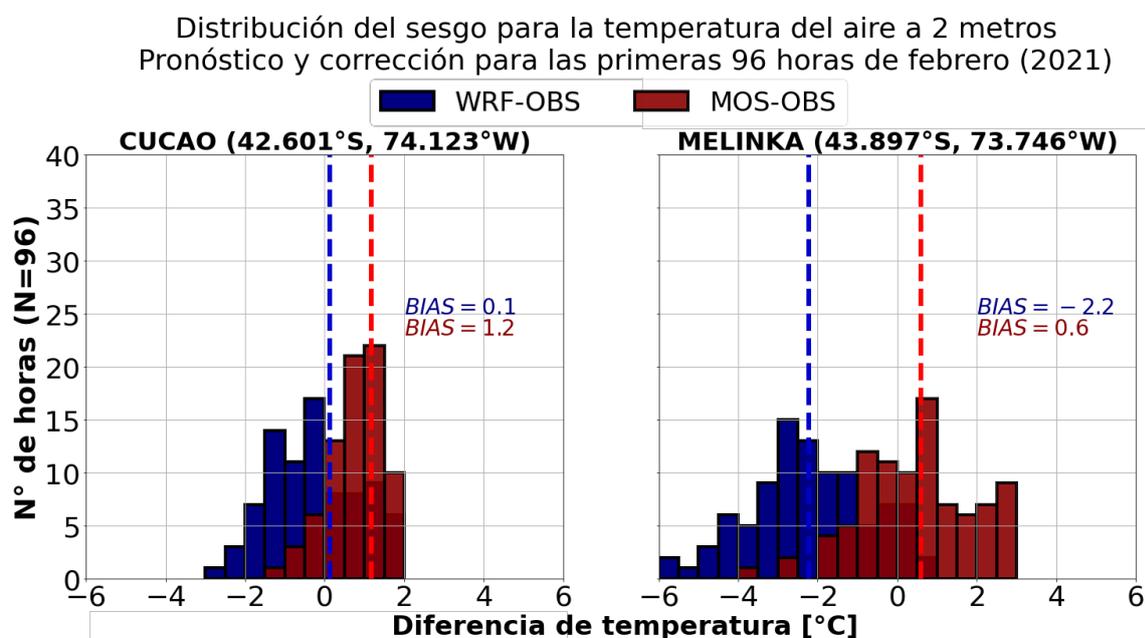


**Figura A3.8:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de enero de 2021 hasta el 4 de enero de 2021 (96 datos horarios).

### A3.5. Pronóstico generado el 1 de febrero de 2021.

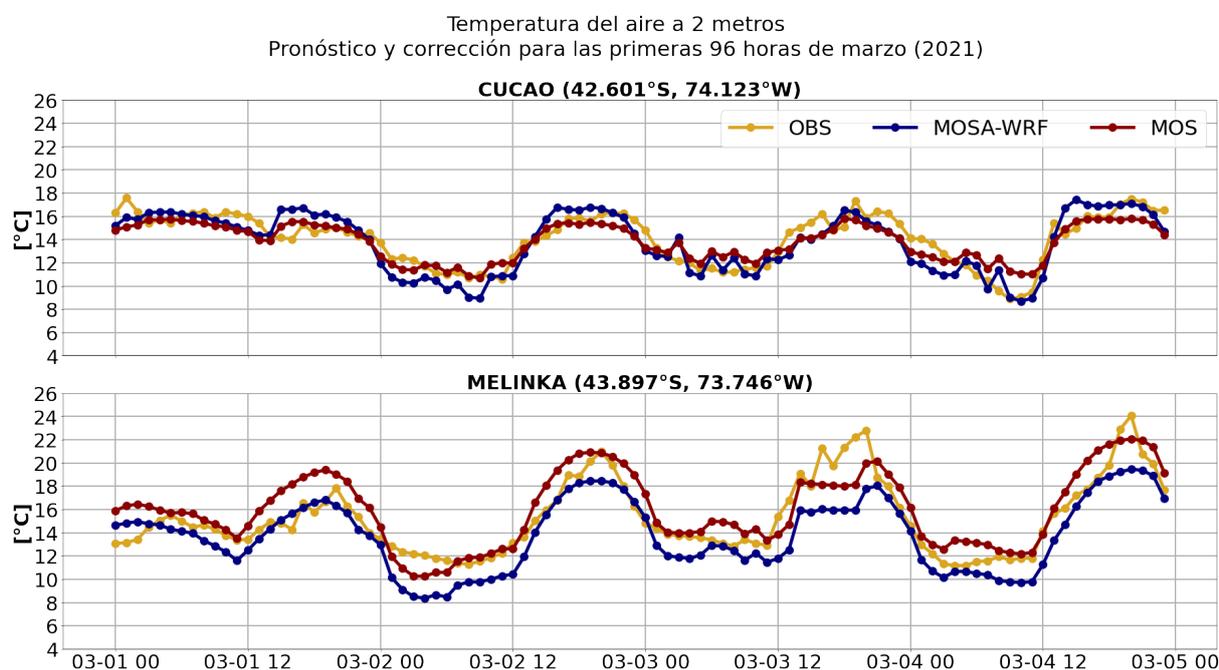


**Figura A3.9:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de febrero de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

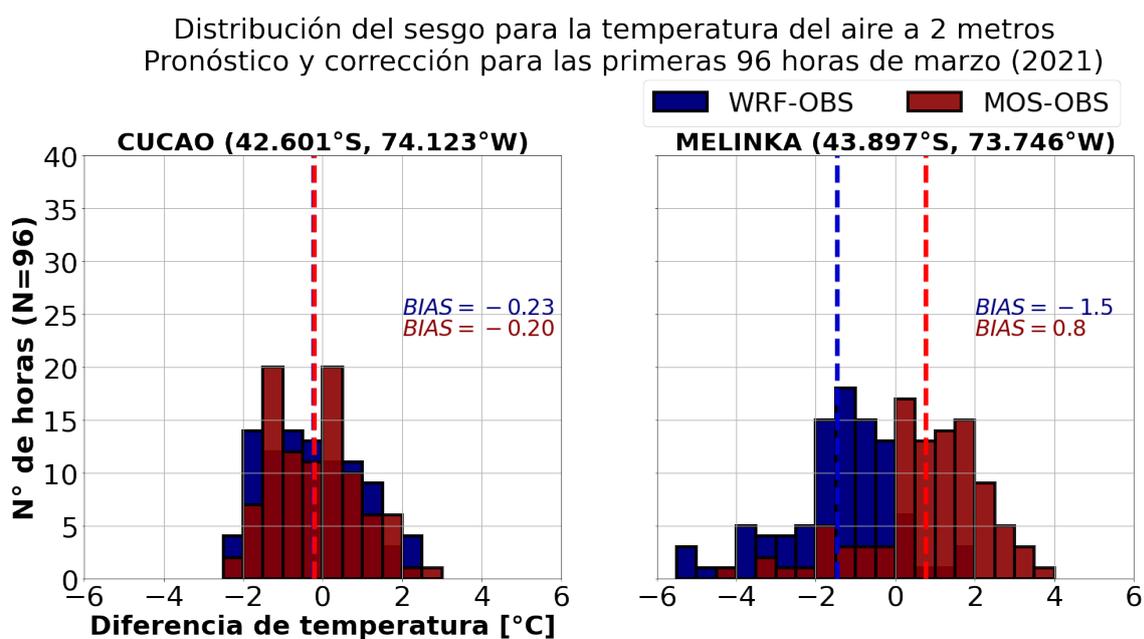


**Figura A3.10:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de febrero de 2021 hasta el 4 de febrero de 2021 (96 datos horarios).

### A3.6. Pronóstico generado el 1 de marzo de 2021.

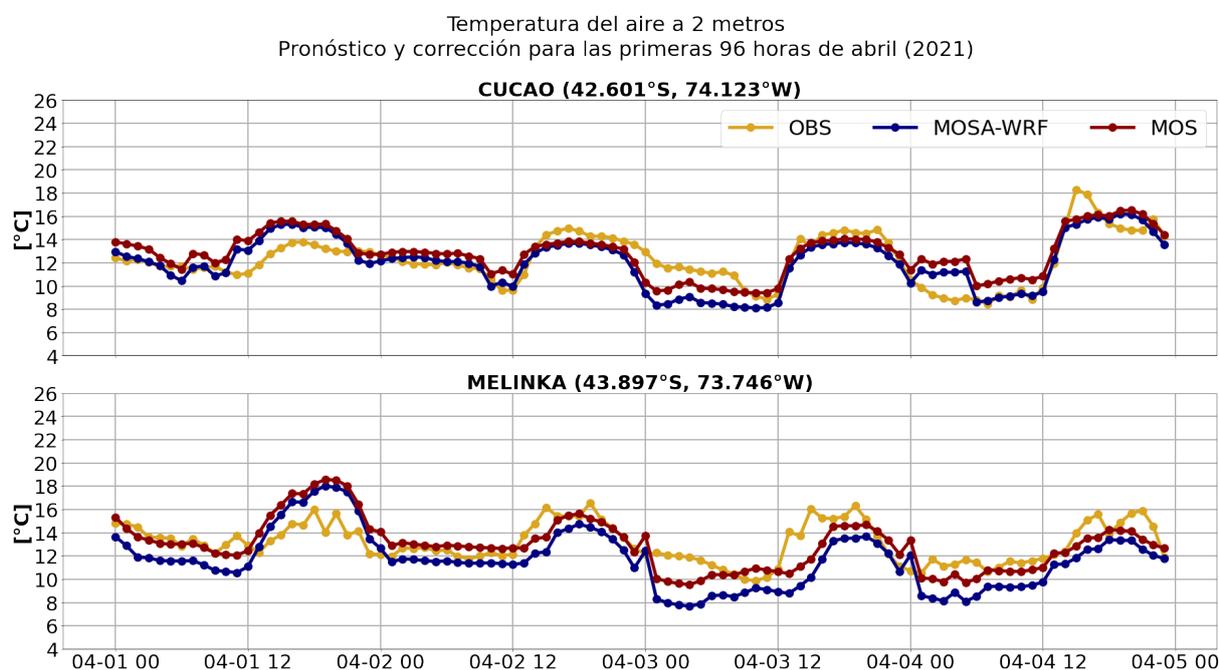


**Figura A3.11:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de marzo de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

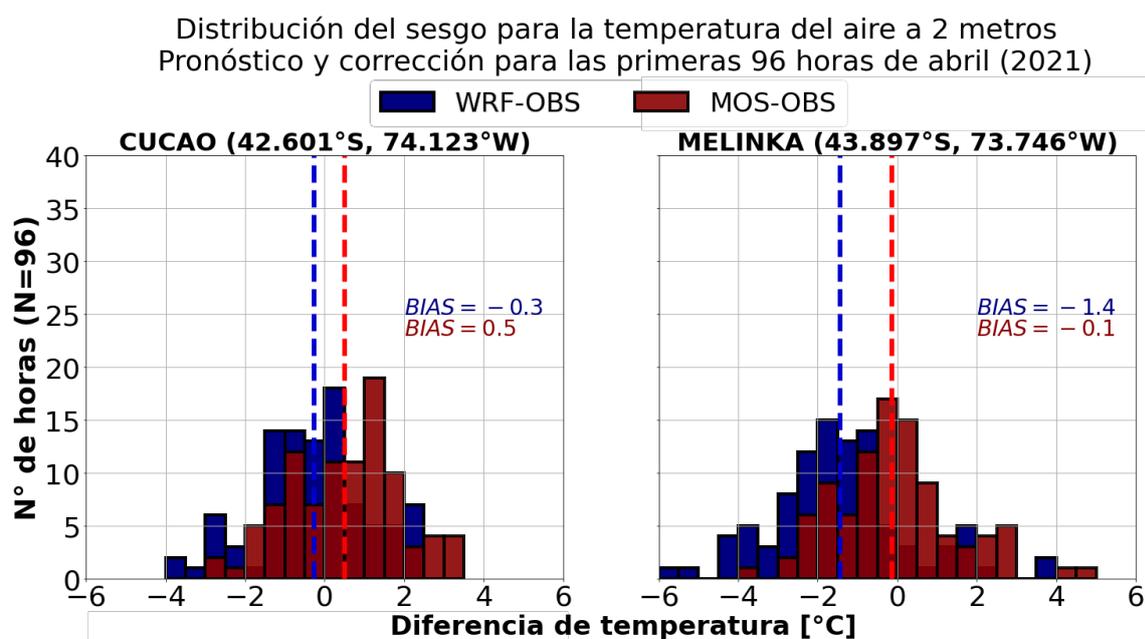


**Figura A3.12:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de marzo de 2021 hasta el 4 de marzo de 2021 (96 datos horarios).

### A3.7. Pronóstico generado el 1 de abril de 2021.

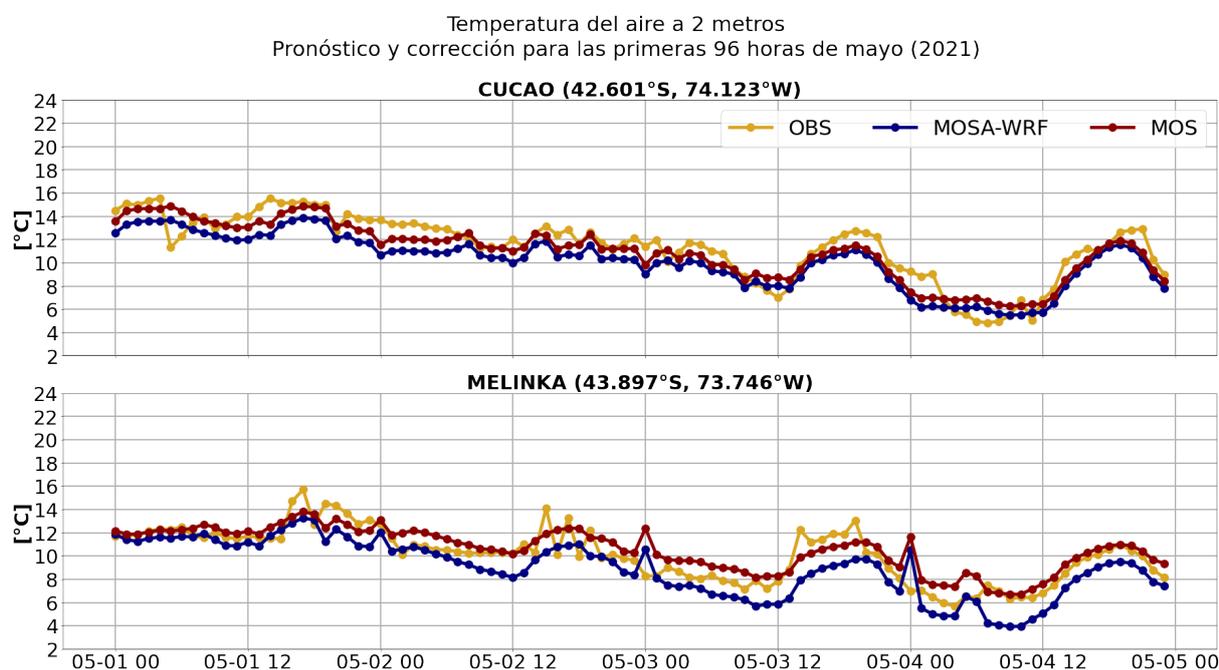


**Figura A3.13:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de abril de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

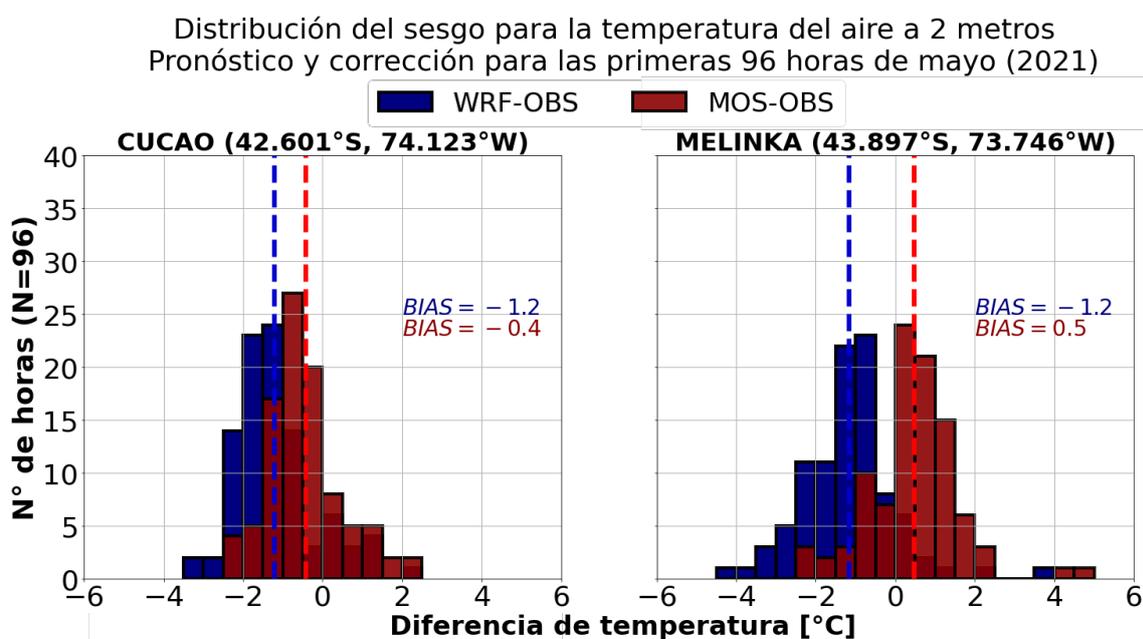


**Figura A3.14:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de abril de 2021 hasta el 4 de abril de 2021 (96 datos horarios).

### A3.8. Pronóstico generado el 1 de mayo de 2021.

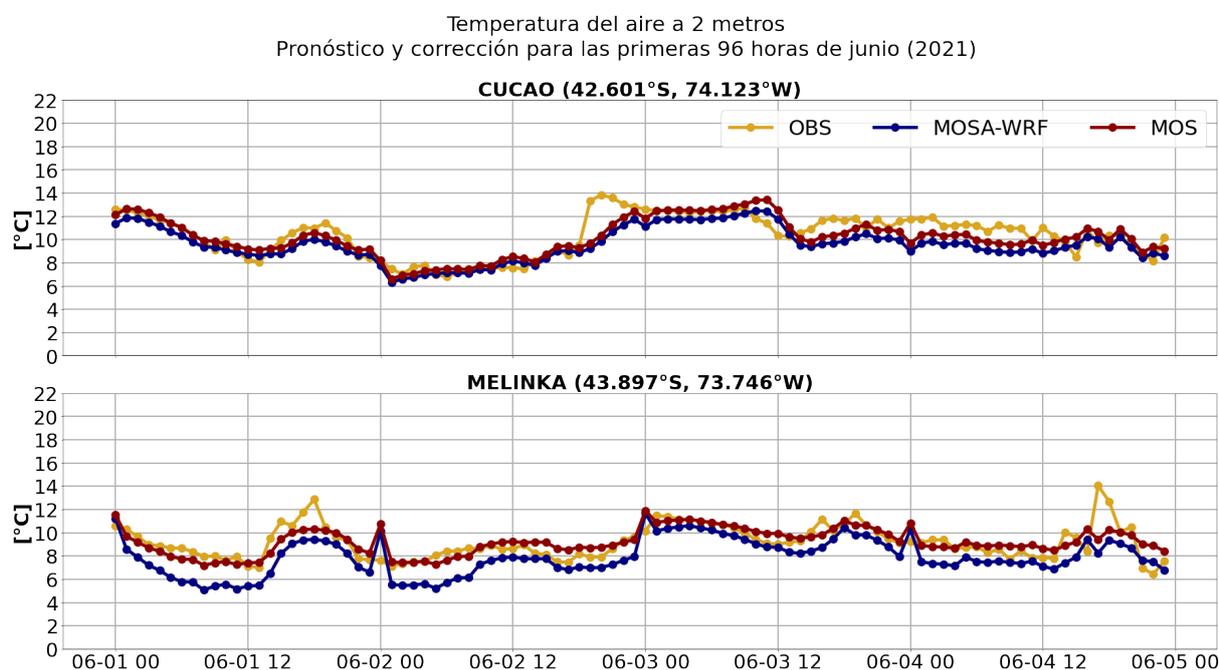


**Figura A3.15:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de mayo de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

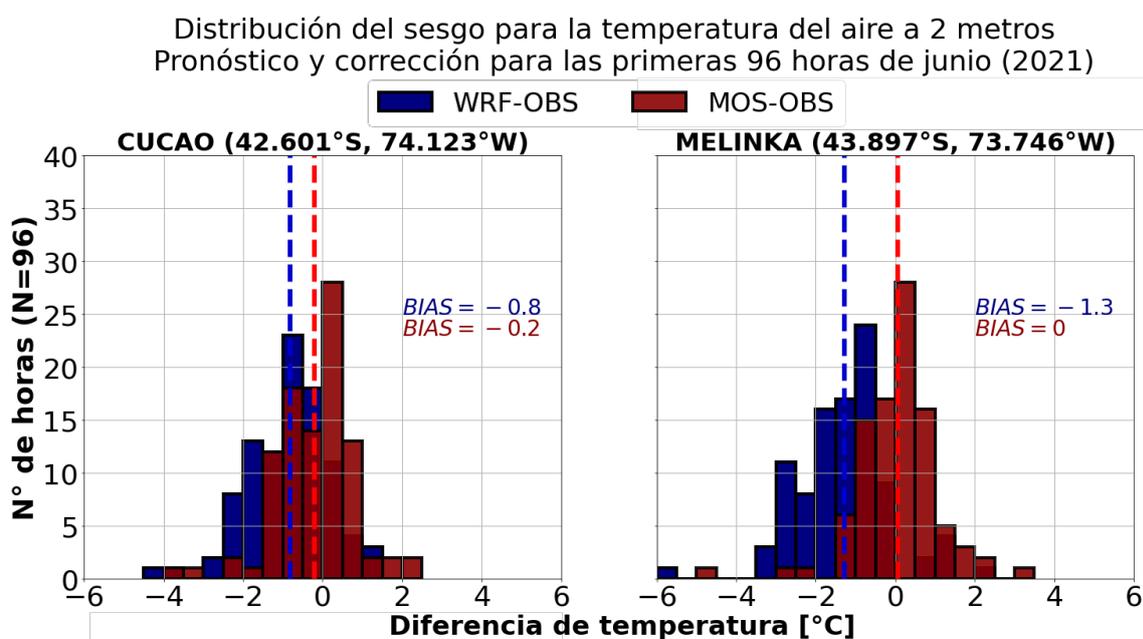


**Figura A3.16:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de mayo de 2021 hasta el 4 de mayo de 2021 (96 datos horarios).

### A3.9. Pronóstico generado el 1 de junio de 2021.

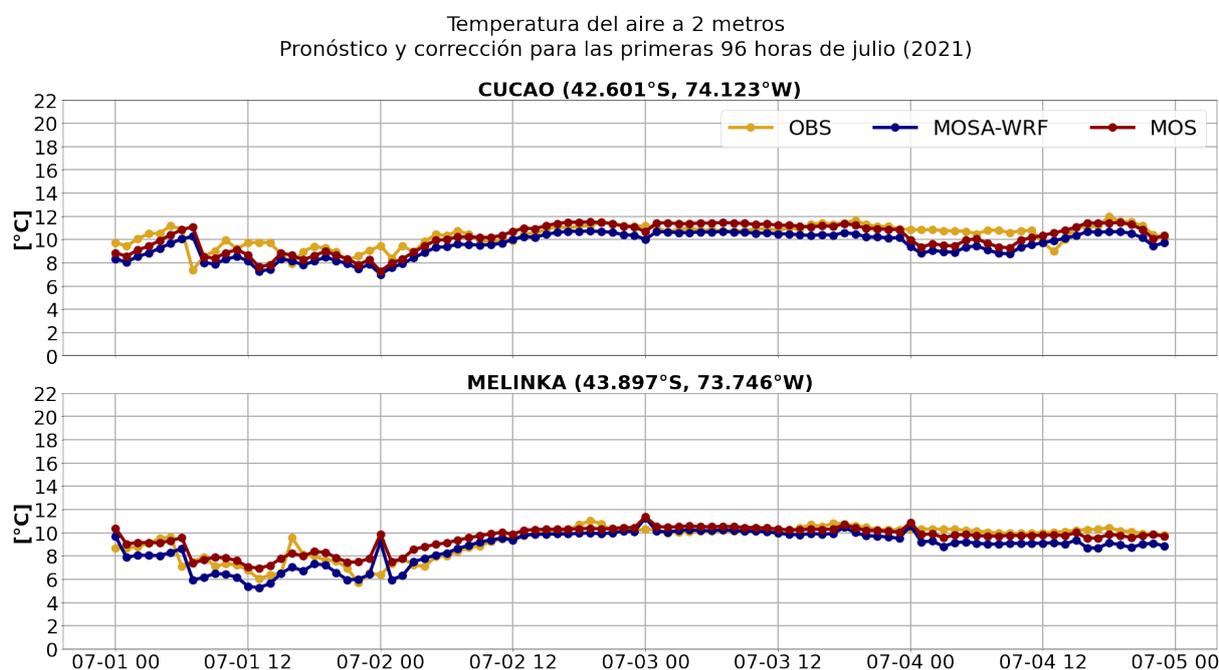


**Figura A3.17:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de junio de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

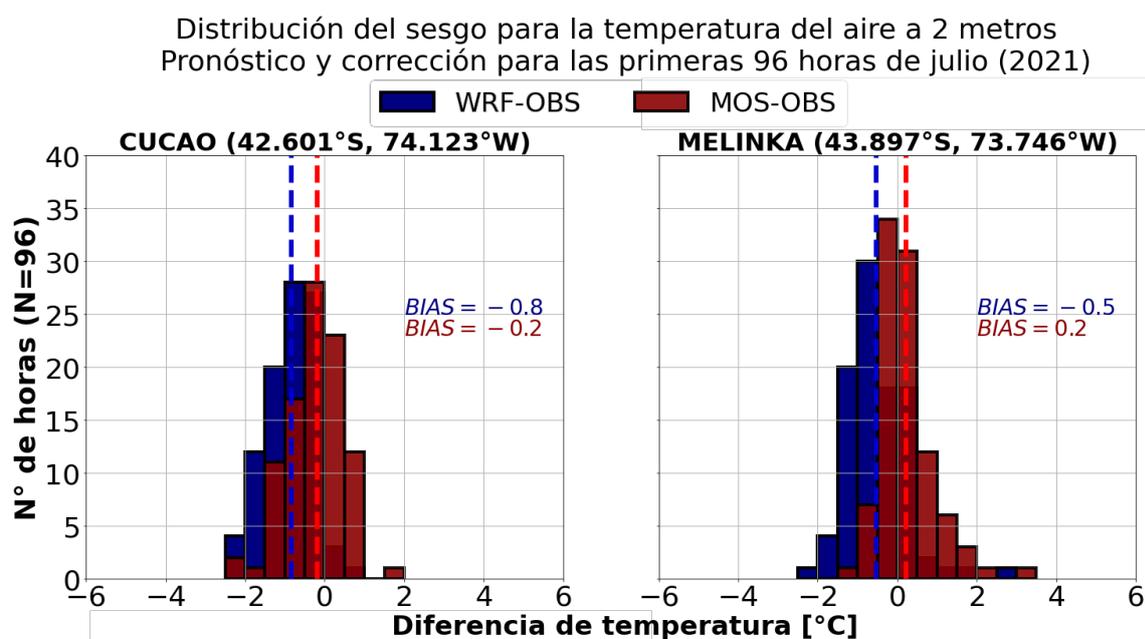


**Figura A3.18:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de junio de 2021 hasta el 4 de junio de 2021 (96 datos horarios).

### A3.10. Pronóstico generado el 1 de julio de 2021.

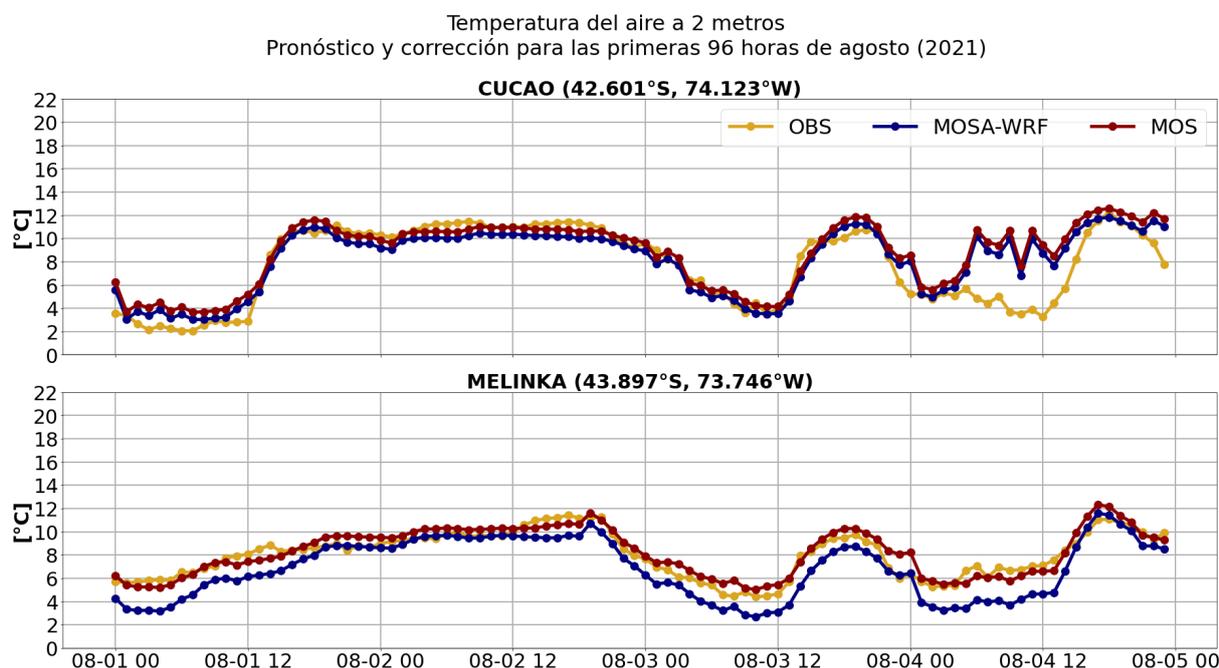


**Figura A3.19:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de julio de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

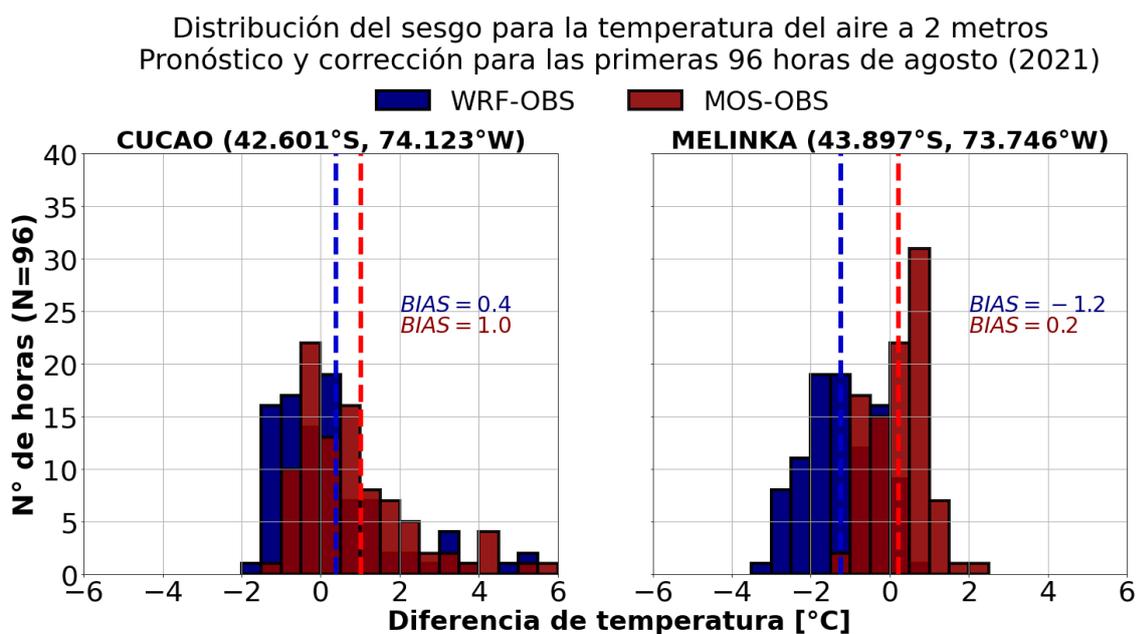


**Figura A3.20:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de julio de 2021 hasta el 4 de julio de 2021 (96 datos horarios).

### A3.11. Pronóstico generado el 1 de agosto de 2021.

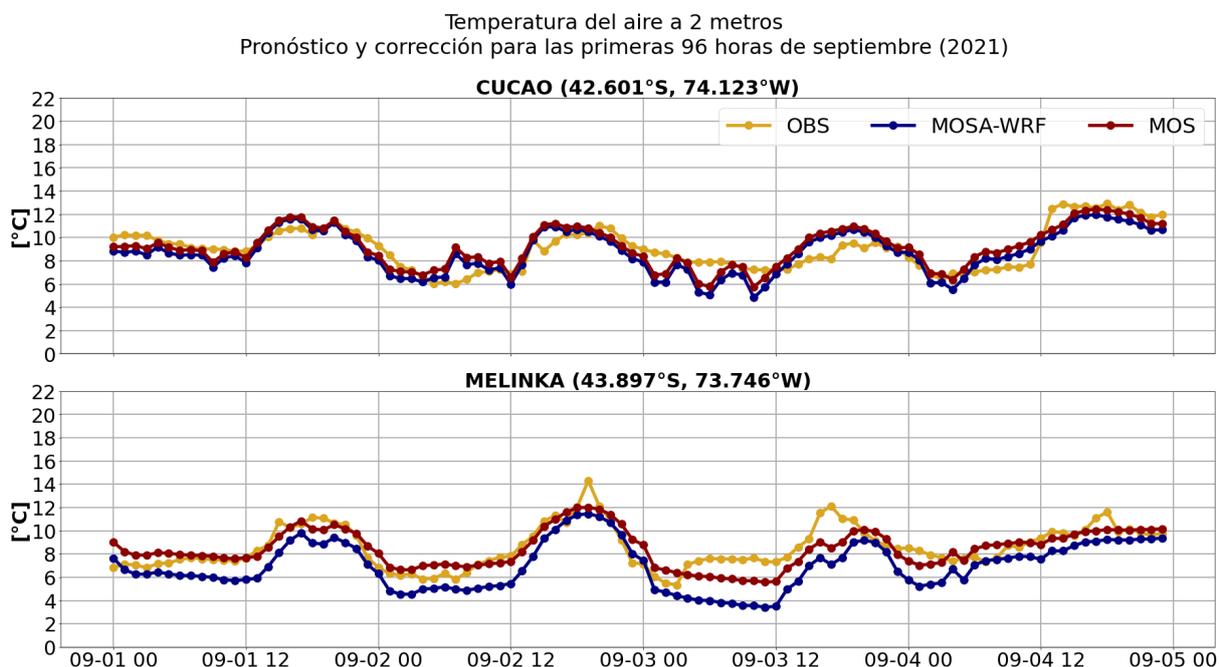


**Figura A3.21:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de agosto de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

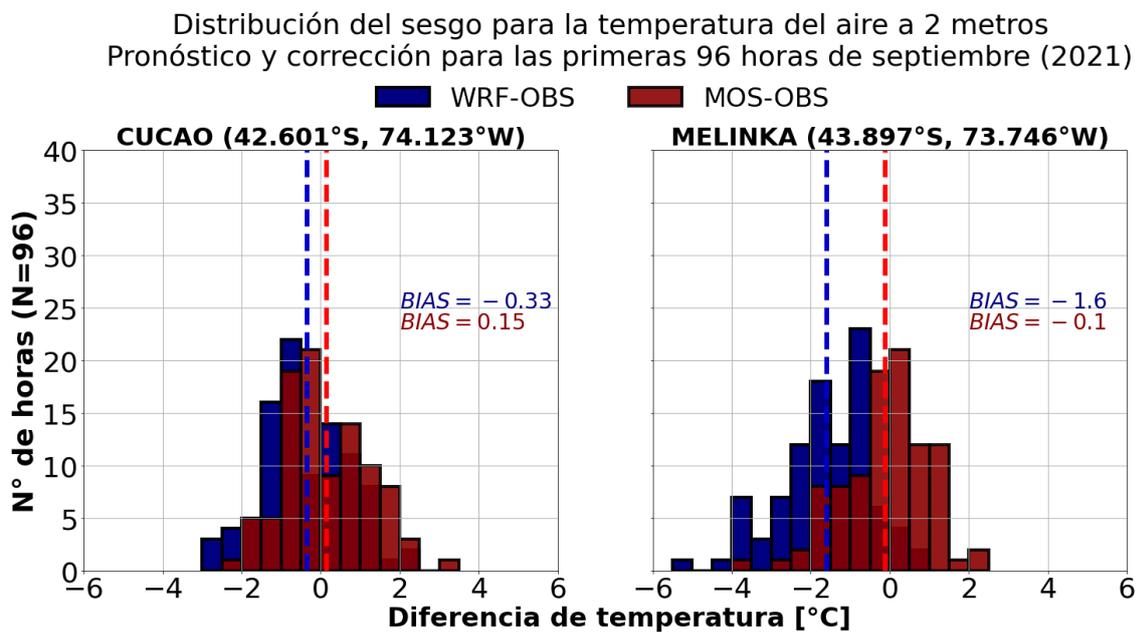


**Figura A3.22:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de agosto de 2021 hasta el 4 de agosto de 2021 (96 datos horarios).

### A3.12. Pronóstico generado el 1 de septiembre de 2021.

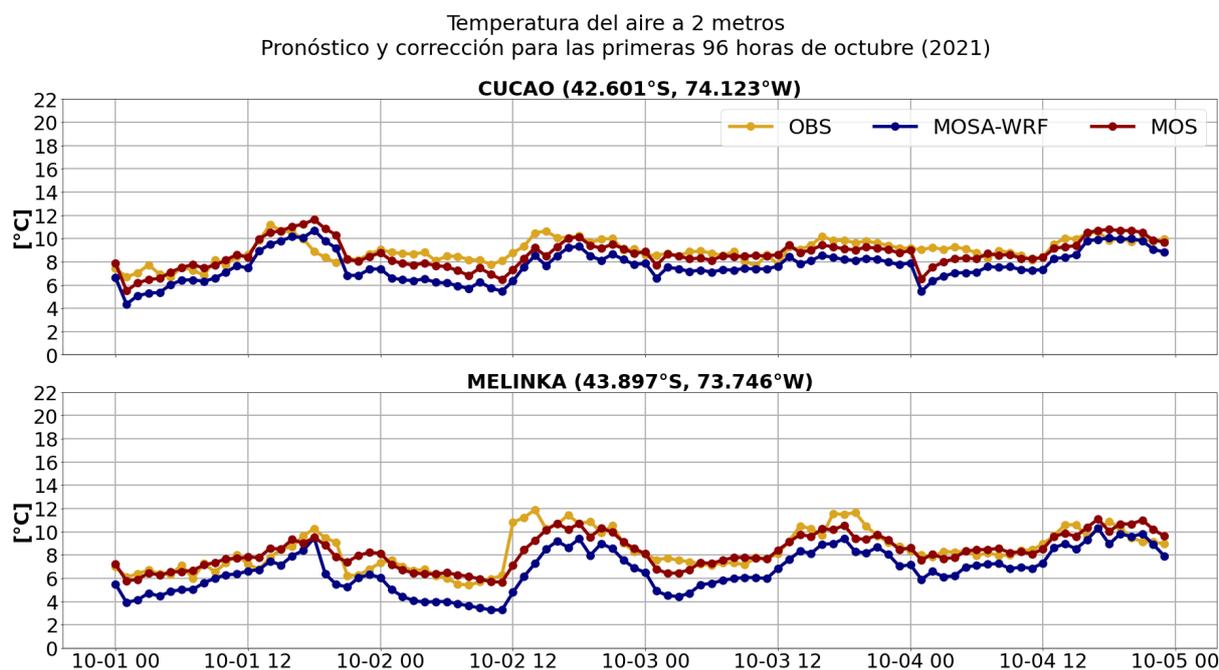


**Figura A3.23:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de septiembre de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

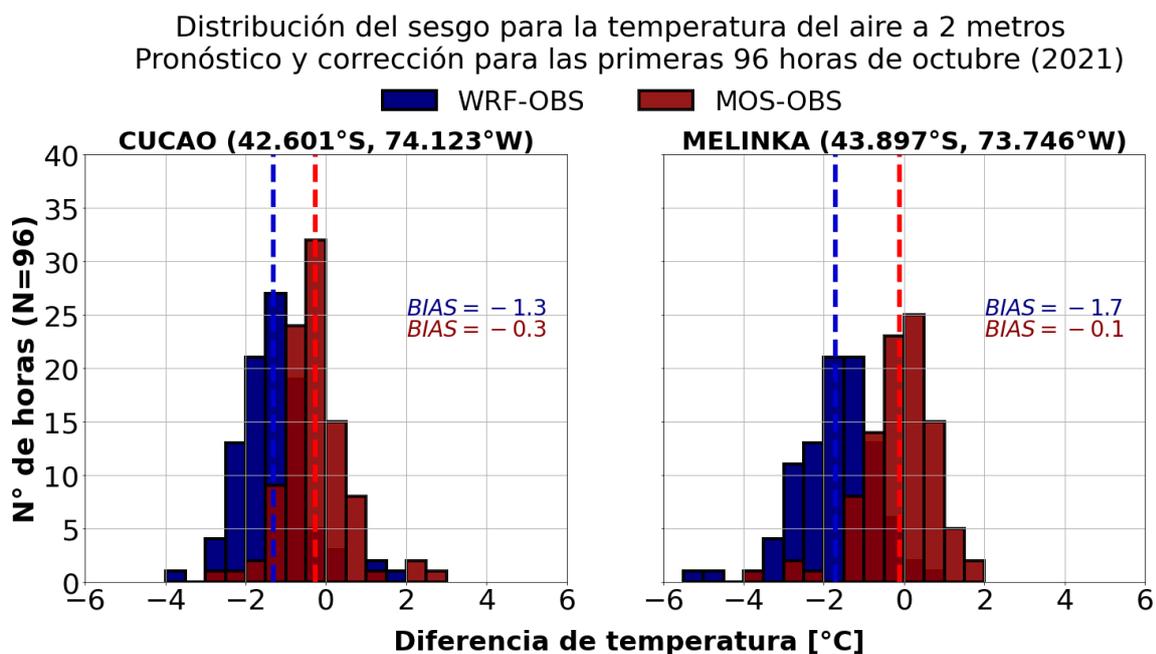


**Figura A3.24:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de septiembre de 2021 hasta el 4 de septiembre de 2021 (96 datos horarios).

### A3.13. Pronóstico generado el 1 de octubre de 2021.

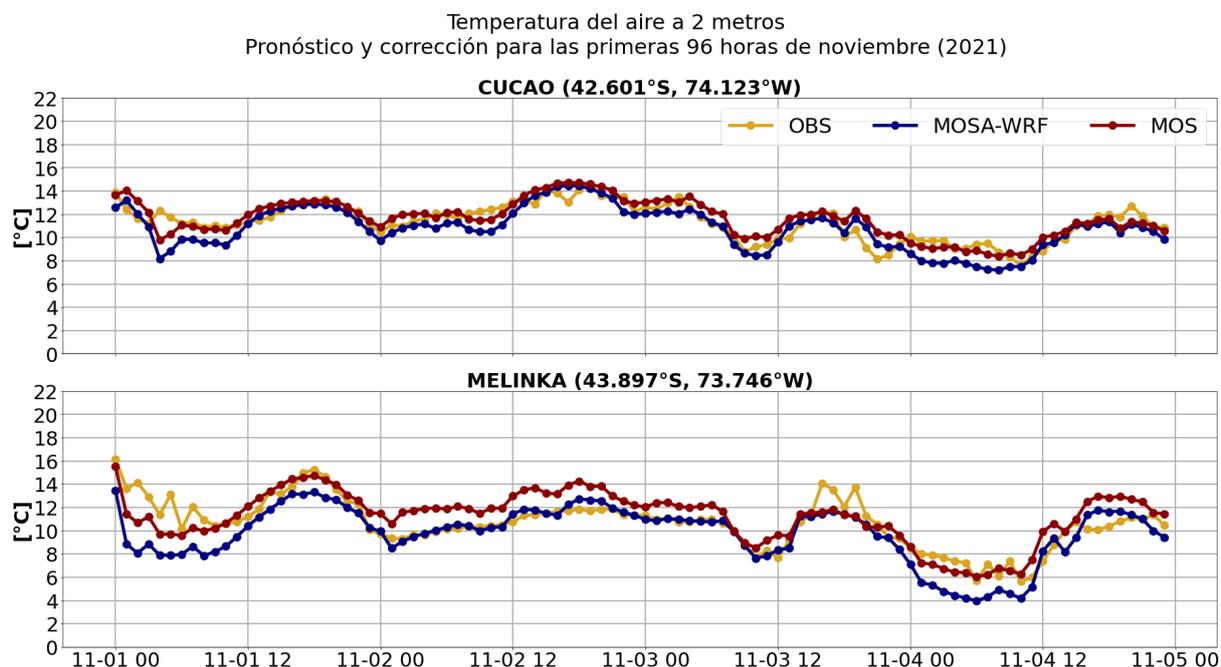


**Figura A3.25:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de octubre de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

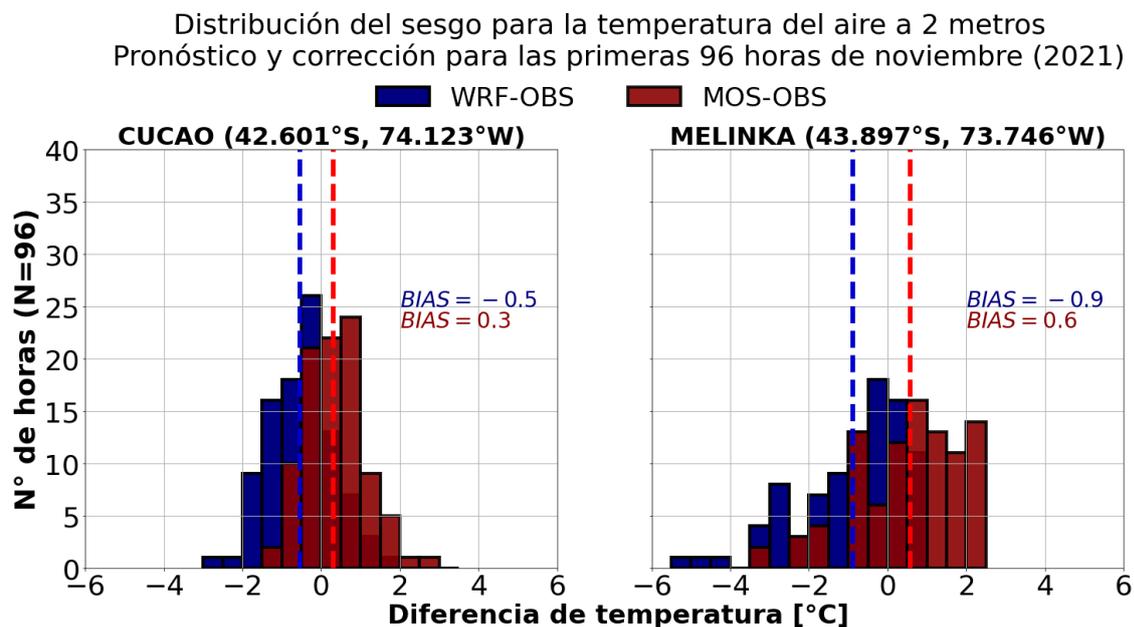


**Figura A3.26:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de octubre de 2021 hasta el 4 de octubre de 2021 (96 datos horarios).

### A3.14. Pronóstico generado el 1 de noviembre de 2021.

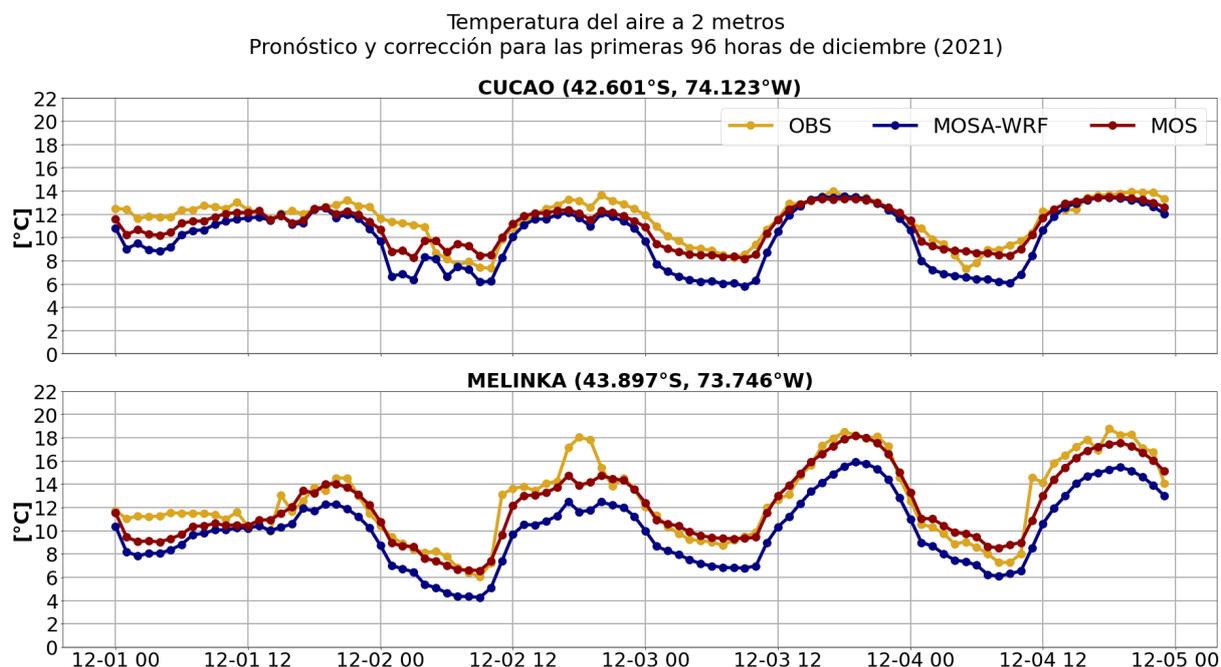


**Figura A3.27:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de noviembre de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

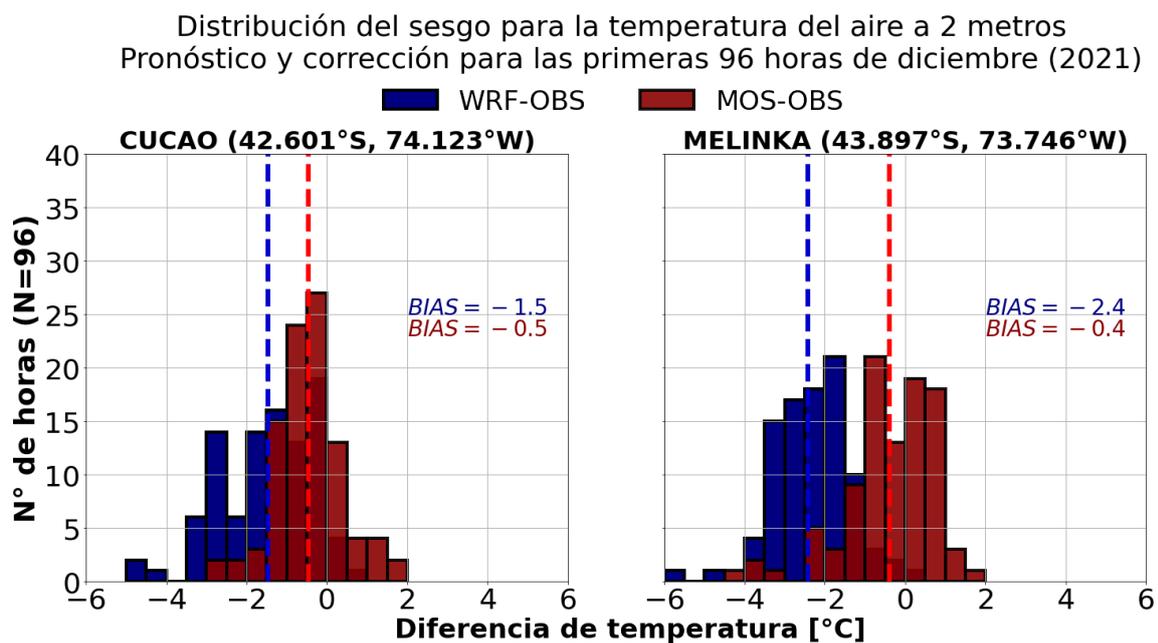


**Figura A3.28:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de noviembre de 2021 hasta el 4 de noviembre de 2021 (96 datos horarios).

### A3.15. Pronóstico generado el 1 de diciembre de 2021.

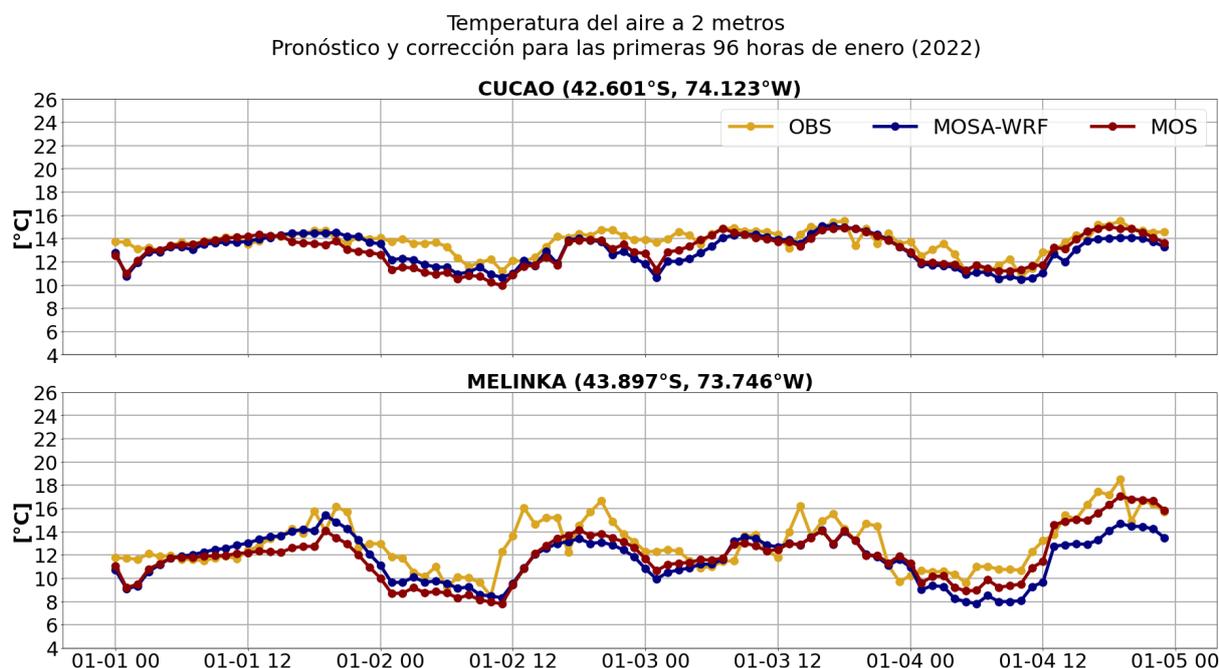


**Figura A3.29:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de diciembre de 2021 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

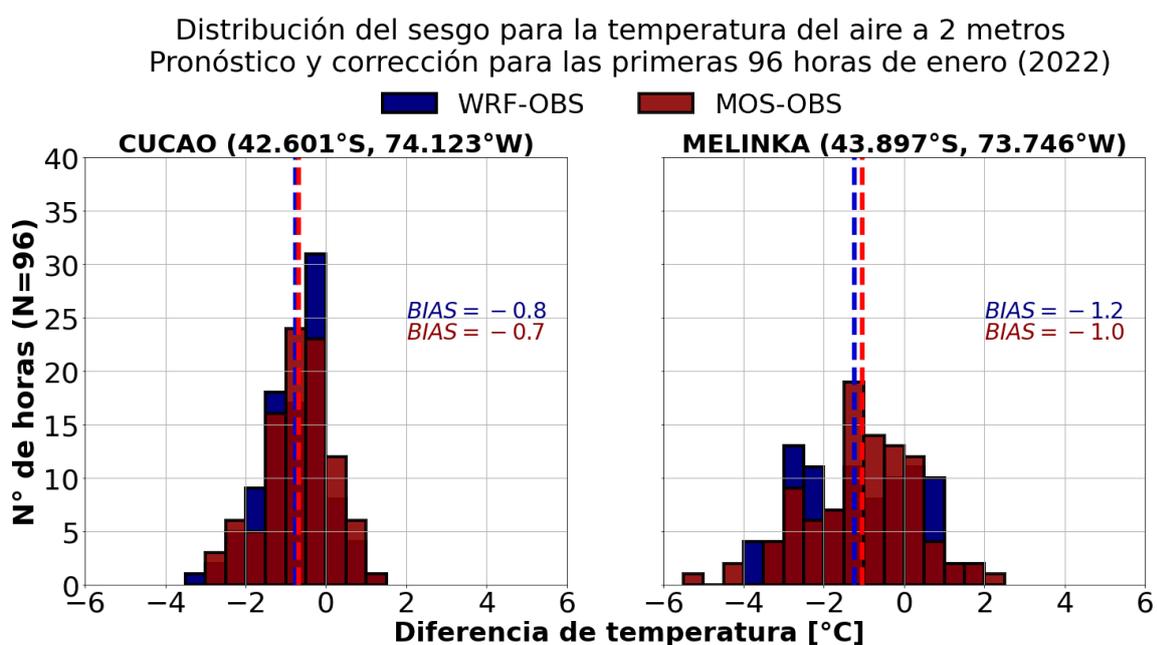


**Figura A3.30:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de diciembre de 2021 hasta el 4 de diciembre de 2021 (96 datos horarios).

### A3.16. Pronóstico generado el 1 de enero de 2022.

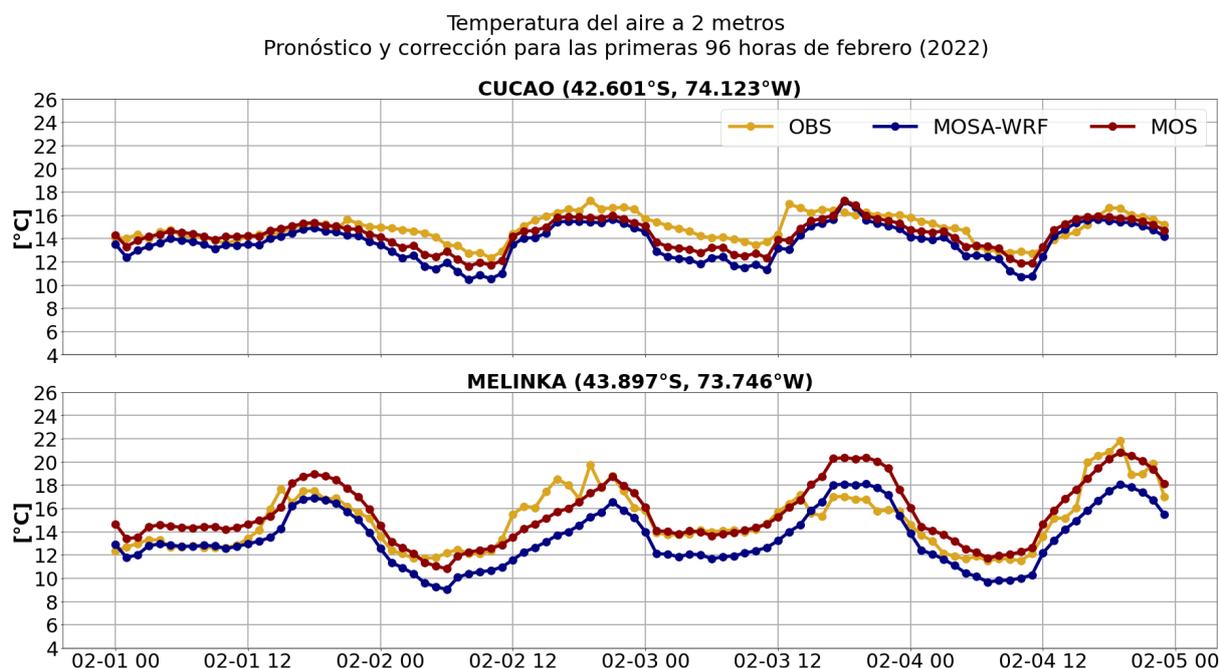


**Figura A3.31:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de enero de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

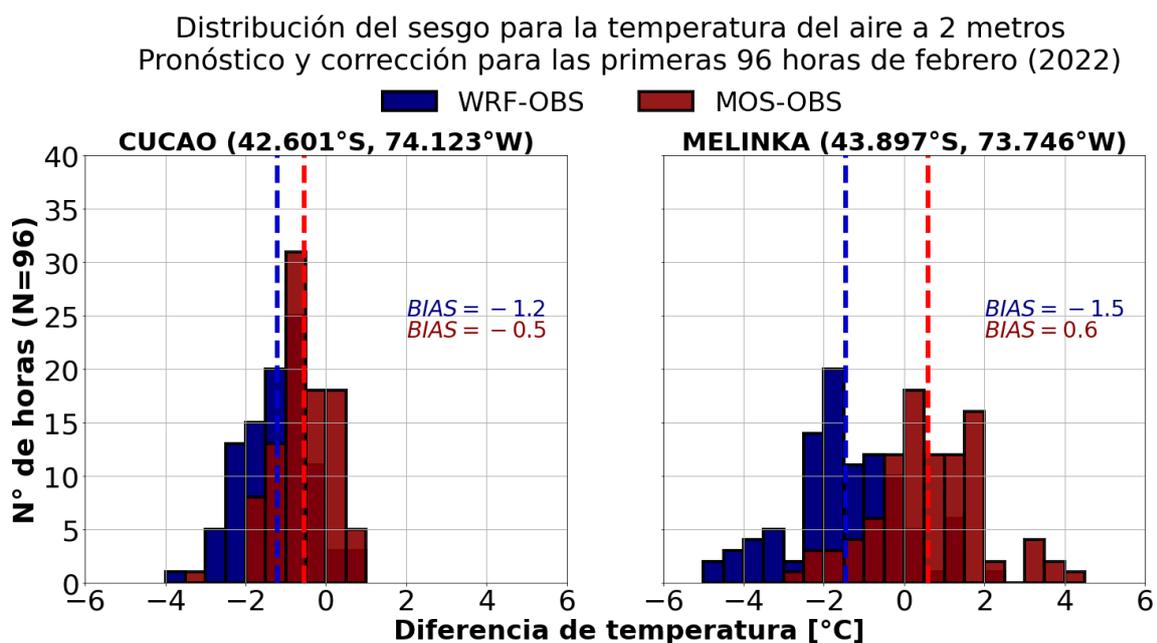


**Figura A3.32:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de enero de 2022 hasta el 4 de enero de 2022 (96 datos horarios).

### A3.17. Pronóstico generado el 1 de febrero de 2022.

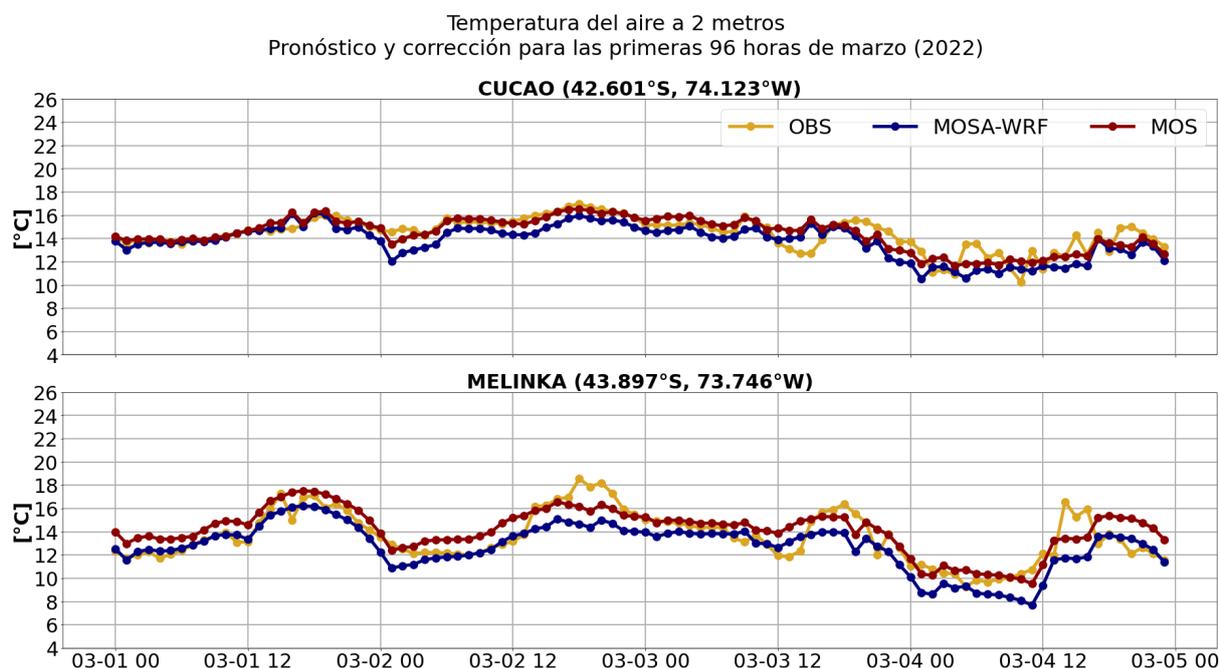


**Figura A3.33:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de febrero de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

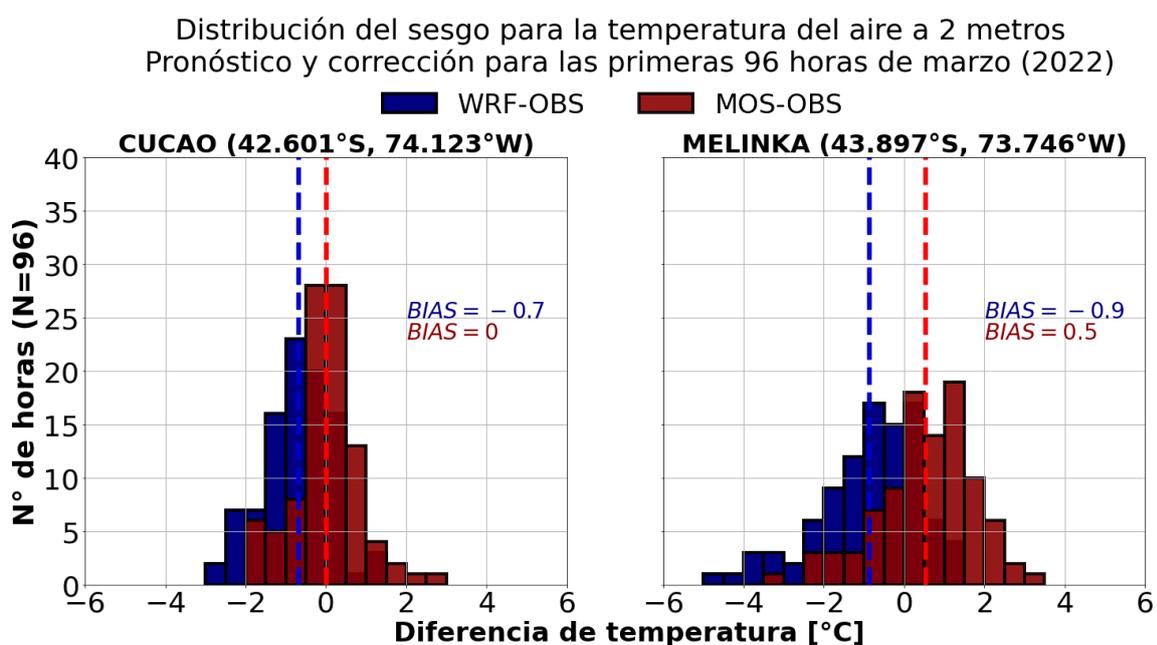


**Figura A3.34:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de febrero de 2022 hasta el 4 de febrero de 2022 (96 datos horarios).

### A3.18. Pronóstico generado el 1 de marzo de 2022.

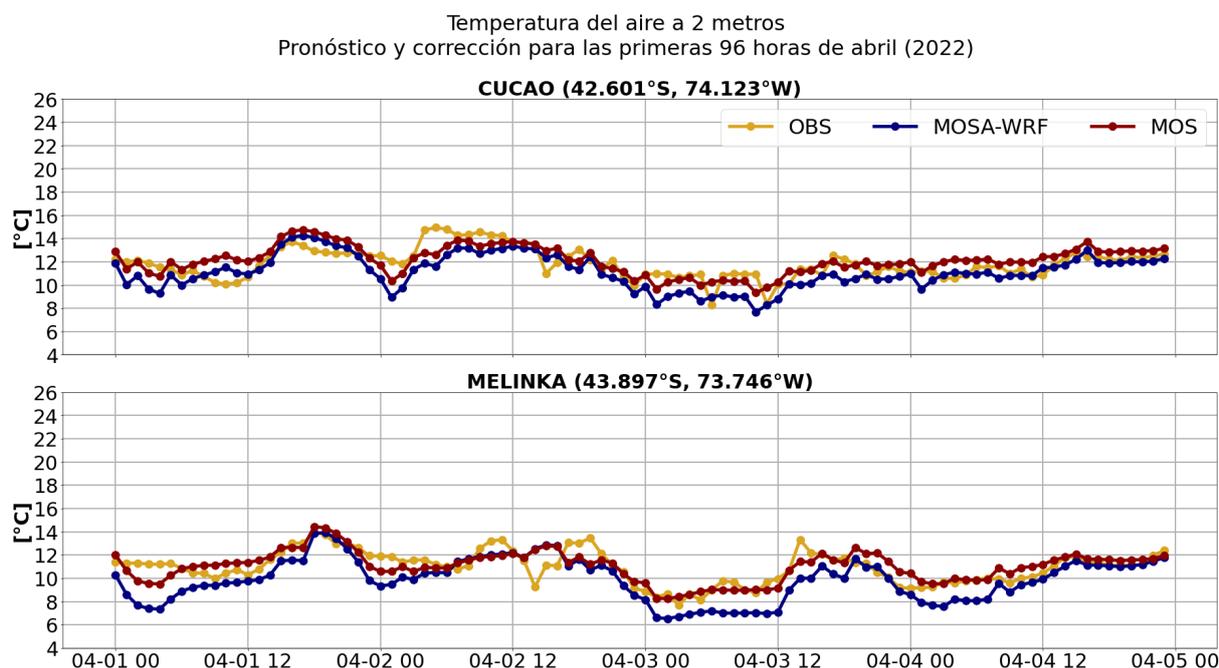


**Figura A3.35:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de marzo de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

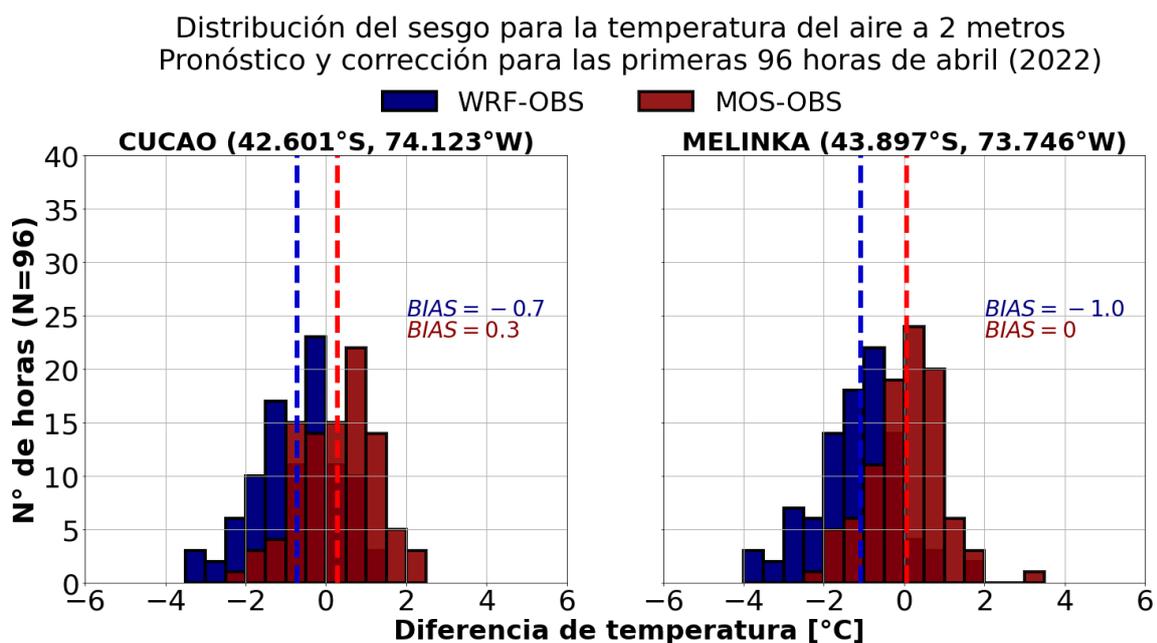


**Figura A3.36:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de marzo de 2022 hasta el 4 de marzo de 2022 (96 datos horarios).

### A3.19. Pronóstico generado el 1 de abril de 2022.

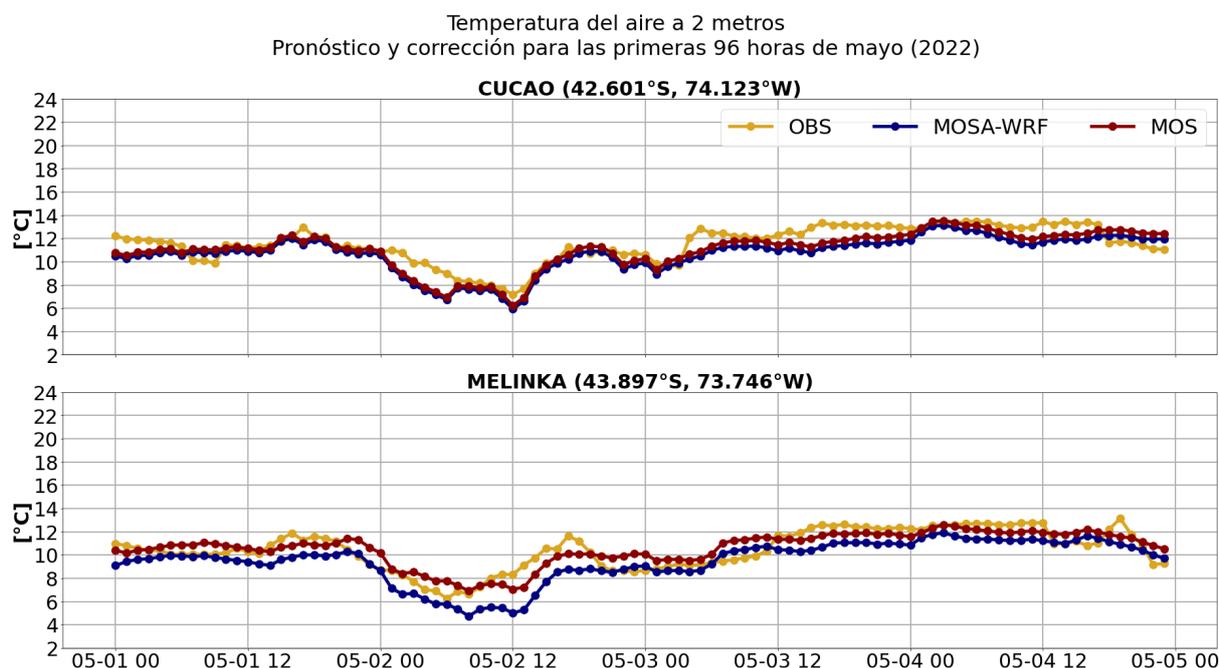


**Figura A3.37:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de abril de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

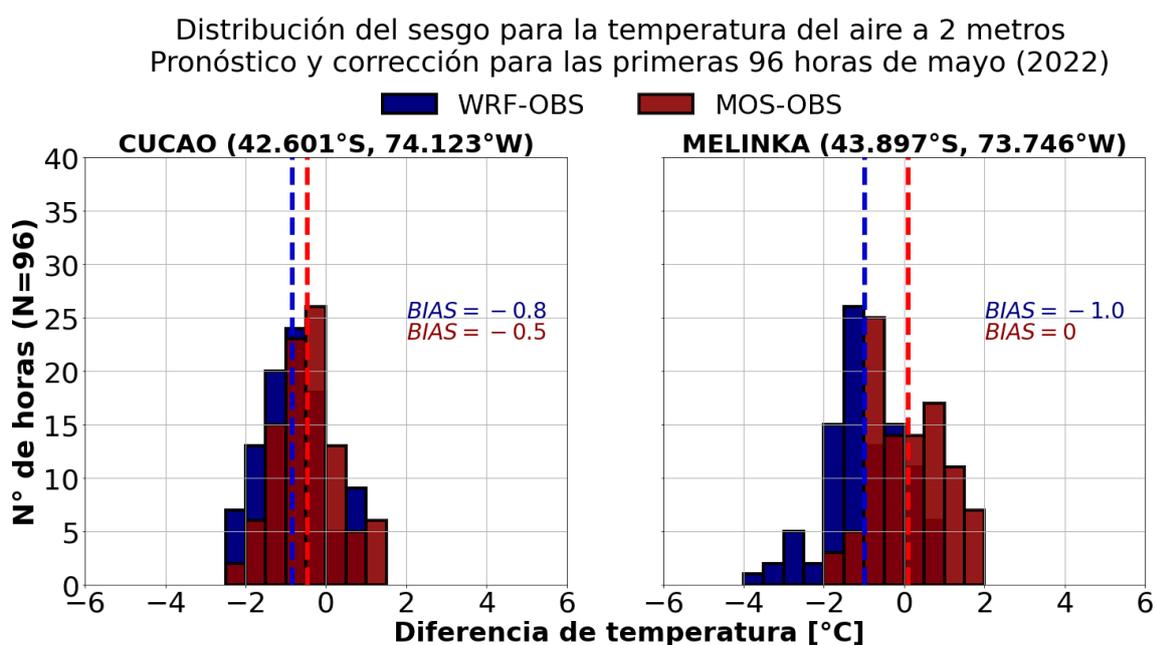


**Figura A3.38:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de abril de 2022 hasta el 4 de abril de 2022 (96 datos horarios).

### A3.20. Pronóstico generado el 1 de mayo de 2022.

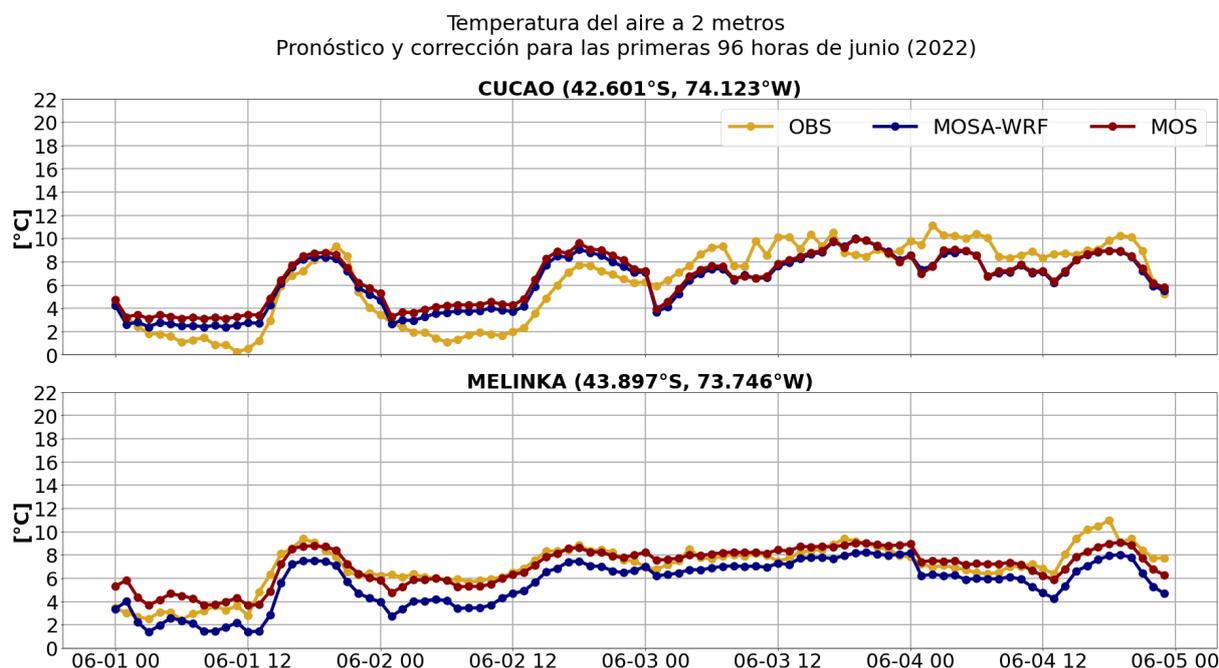


**Figura A3.39:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de mayo de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

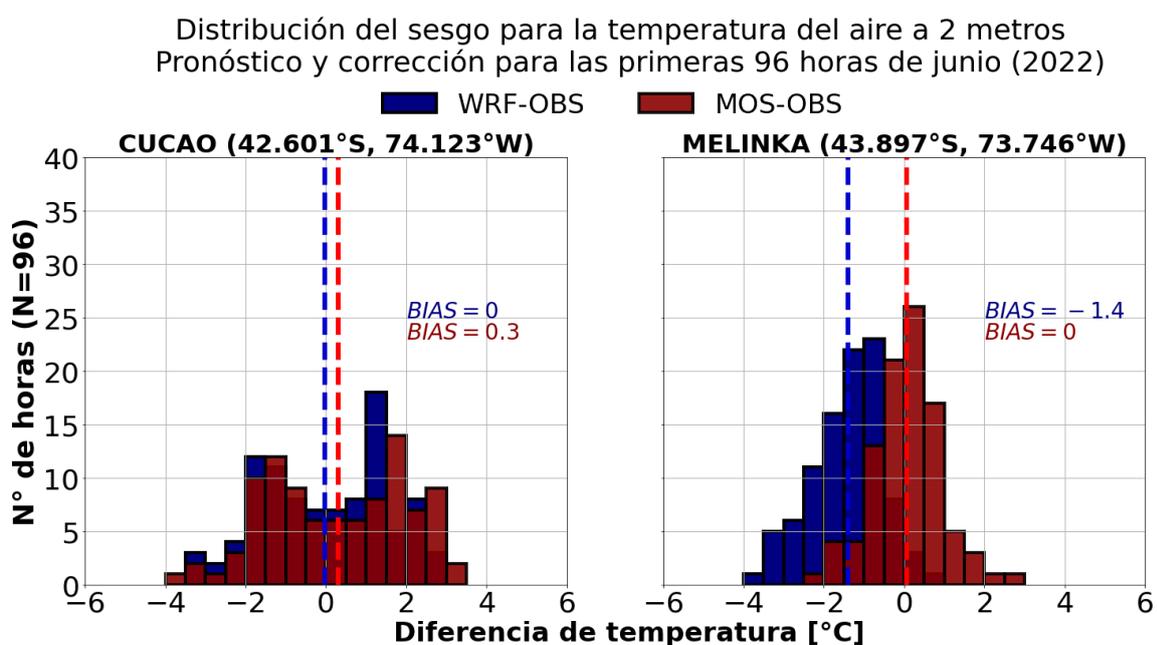


**Figura A3.40:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de mayo de 2022 hasta el 4 de mayo de 2022 (96 datos horarios).

### A3.21. Pronóstico generado el 1 de junio de 2022.

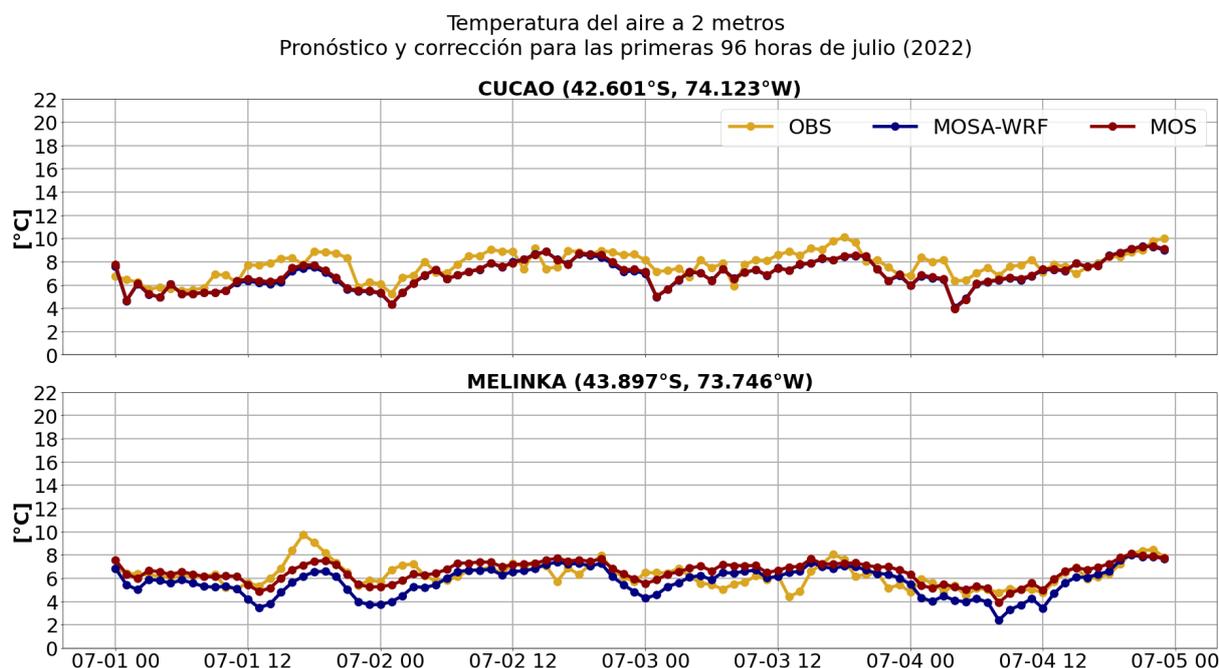


**Figura A3.41:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de junio de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

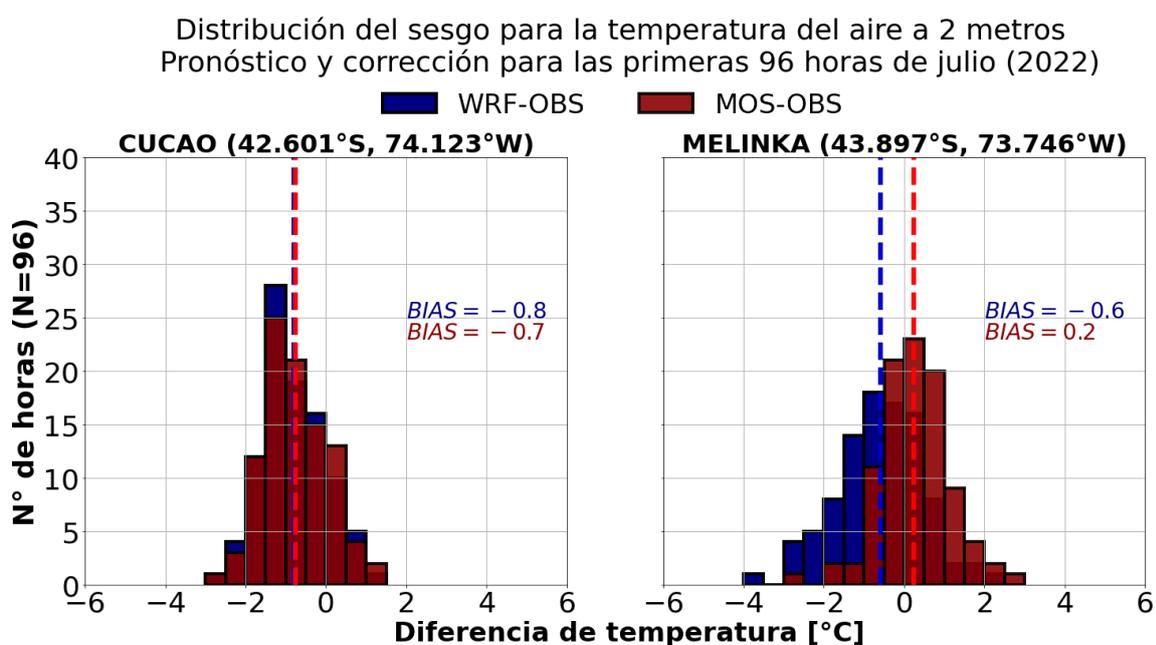


**Figura A3.42:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de junio de 2022 hasta el 4 de junio de 2022 (96 datos horarios).

### A3.22. Pronóstico generado el 1 de julio de 2022.

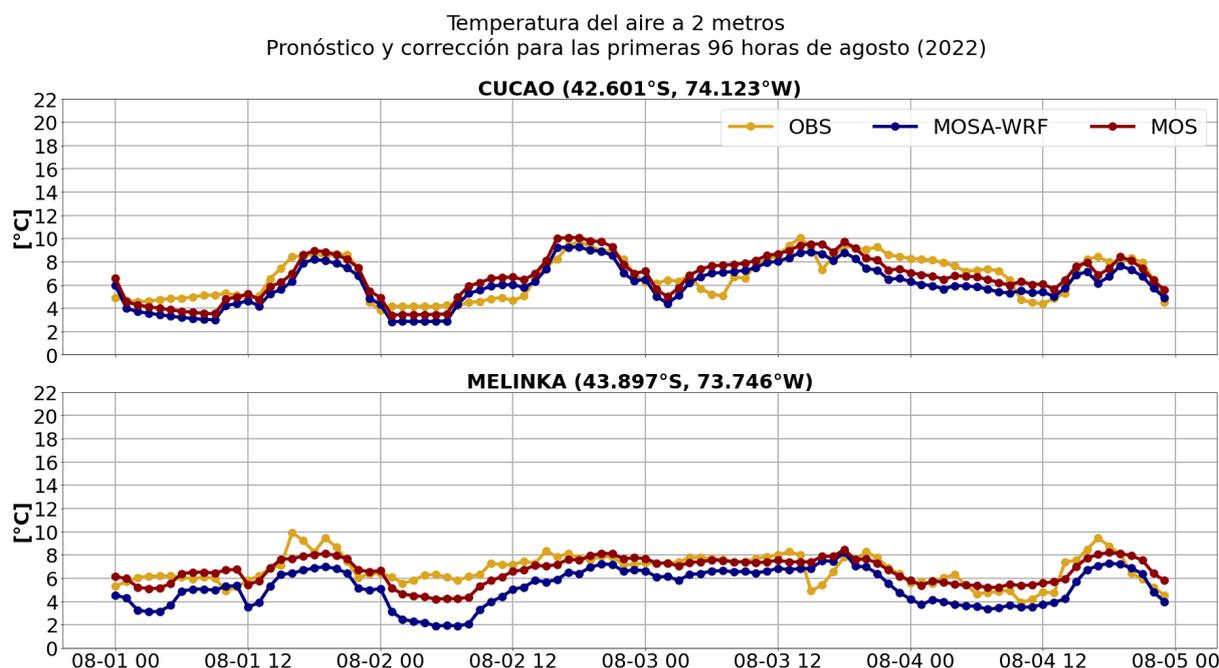


**Figura A3.43:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de julio de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.

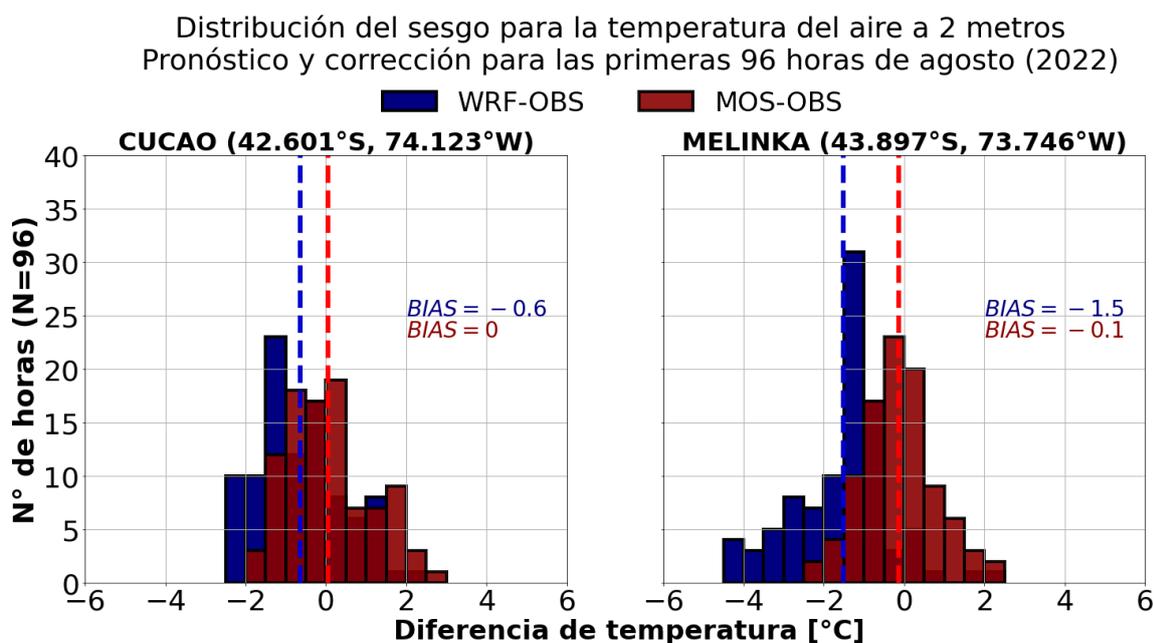


**Figura A3.44:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de julio de 2022 hasta el 4 de julio de 2022 (96 datos horarios).

### A3.23. Pronóstico generado el 1 de agosto de 2022.



**Figura A3.45:** Serie de tiempo de la temperatura del aire a 2 metros pronosticada el 1 de agosto de 2022 (96 datos horarios). En azul se muestra la temperatura pronosticada por MOSA-WRF, en amarillo se muestra la temperatura medida en las estaciones meteorológicas, y en rojo la corregida por MOS.



**Figura A3.46:** Diferencias de temperatura entre lo simulado y observado (azul), y entre lo corregido y observado (rojo) en Cucao y Melinka. El período considera desde el 1 de agosto de 2022 hasta el 4 de agosto de 2022 (96 datos horarios).