



**UNIVERSIDAD
DE ANTIOQUIA**

**EVALUACIÓN DEL MODELO ATMOSFÉRICO WRF EN EL
PRONÓSTICO METEOROLÓGICO DE IRRADIANCIA SOLAR EN
EL VALLE DE ABURRÁ, COLOMBIA.**

Maria Alejandra Carmona Rivera

Universidad de Antioquia

Facultad de Ingeniería (Escuela Ambiental.)

Medellín, Colombia

2021



**EVALUACIÓN DEL MODELO ATMOSFÉRICO WRF EN EL PRONÓSTICO
METEOROLÓGICO DE IRRADIANCIA SOLAR EN EL VALLE DE ABURRÁ,
COLOMBIA**

Maria Alejandra Carmona Rivera

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Ingeniera Ambiental

Asesores (a):

Paola Andrea Arias Gómez, PhD.

John Alejandro Martínez Agudelo, PhD.

Línea de Investigación:

Modelación Ambiental

Grupo de Investigación:

Grupo de Ingeniería y Gestión Ambiental (GIGA)

Universidad de Antioquia

Facultad de Ingeniería, Escuela Ambiental

Medellín, Colombia

2021

Agradecimientos

Agradezco al proyecto de Sostenibilidad Energética para Colombia (SENECA) por su apoyo y la oportunidad de participar en el programa. A mis padres y amigos por sus consejos y su constante motivación. Agradezco profundamente a mis asesores Paola y Alejandro quienes con su conocimiento y guía fueron parte esencial en todo este proceso.

Contenido

1. Resumen	4
2. Introducción	5
2.1 Objetivo general	7
2.2 Objetivos específicos.....	7
2.3 Marco Teórico	7
3. Metodología	11
3.1 Área de estudio.....	11
3.2 Datos	12
3.2.1 Piranómetro SIATA	12
3.2.2 Simulaciones WRF y persistencia.....	12
3.3 Procesamiento de datos	13
3.3.1 Métricas de error	13
4. Resultados y análisis	16
4.1 Irradiancia solar SIATA	16
4.1.1 Ciclo anual de irradiancia solar	16
4.1.2 Ciclos diurnos multianuales	17
4.1.3 Series promedios diarios de irradiancia solar.....	18
4.2 Simulaciones WRF con horizonte de 24 horas	20
4.2.1 Datos horarios	20
4.3.1 Errores	24
4.2.4 Datos diarios de irradiación solar.....	29
4.3 Simulaciones WRF con horizonte de 48 horas	31
4.3.1 Valores horarios de irradiancia solar.....	31
4.3.2 Errores	38
4.3.3 Valores diarios de irradiancia solar	47

1. Resumen

Los pronósticos confiables de radiación solar son necesarios para el funcionamiento óptimo de las plantas energéticas basadas en energía solar, principalmente para la planificación operativa y la gestión del recurso. En este trabajo, se evalúa el modelo atmosférico Weather Research and Forecasting (WRF), en el pronóstico de irradiancia solar, para simulaciones con horizontes de 24 y 48 horas. Para lograrlo se compararon las simulaciones del modelo con mediciones in situ obtenidas del Sistema de Alertas Temprana del Valle de Aburrá (SIATA); además, se comparó WRF con el modelo más simple encontrado: la persistencia. Los resultados de la evaluación muestran que, según los valores del Mean Bias Error (MBE), el modelo tiende a sobreestimar la radiación solar en los diferentes periodos de estudio, tanto para los horizontes de 24 horas como para los de 48 horas. Los valores de este error, en su mayoría, se mantienen por debajo del 20%, pero se evidencian pocos días donde el error superó el 100%. Por su parte, los resultados mostraron valores del Root Mean Squared Error (RMSE) particularmente más altos para los meses de temporada lluviosa en la región de estudio, lo cual puede sugerir un mejor rendimiento del modelo para condiciones de cielo despejado. WRF mostró problemas para representar los datos atípicos de radiación, ya que, en general, las correlaciones de las anomalías con respecto al ciclo diurno entre el modelo y las mediciones in situ fueron no significativas. En general, WRF presenta un mejor rendimiento que el modelo de persistencia, aunque el rendimiento fue muy similar en algunos meses del periodo de estudio. Por otra parte, el rendimiento del modelo no disminuyó con el horizonte de tiempo (24 vs. 48 horas), más bien el segundo horizonte (D2, 48 h) de simulaciones de WRF presentó medianas de los diferentes errores con magnitudes menores a las del primer horizonte (D1, 24h) en casi todos los meses de estudio, lo que podría indicar que el modelo necesita más tiempo de estabilización del normalmente usado (6 horas) o que se necesita tomar un periodo de estudio más largo para evaluar el modelo.

2. Introducción

En Colombia, la matriz de generación de energía eléctrica está basada aproximadamente en un 69% en el recurso hídrico, mientras que el 31% restante está cubierto en su mayoría por sistemas de generación termoeléctrica que tienen como base el uso de combustibles fósiles. El uso constante de estos combustibles es una de las principales causas del incremento en la concentración de gases de efecto invernadero a escala global, que producen un desequilibrio en el balance térmico del planeta, aumentando su temperatura y causando alteraciones en el clima (Minambiente, s.f; IPCC, 2014). En el país, el consumo de energía eléctrica anual es aproximadamente 70.000 GWh/año y para el año 2030 se espera un incremento del 2% anual, teniendo en cuenta las expectativas de la dinámica del sector industrial, la electrificación de la economía y un incremento en el número de vehículos eléctricos (Arango, 2019). Por otra parte, la prestación del servicio de energía eléctrica en el país se realiza mediante la conexión física de los usuarios al Sistema Interconectado Nacional (SIN) o a un sistema local aislado del mismo. Este último caso representa el 52% del territorio del país y se refiere a las zonas no interconectadas (ZNI), es decir, las áreas geográficas que no tienen acceso al servicio de energía eléctrica a través de un sistema interconectado, debido a los costos y a los impactos ambientales que tendría la instalación de la infraestructura necesaria, pero que cuentan con soluciones locales, generalmente a partir de combustibles líquidos (Superservicios, 2017). Lo anterior, afecta directamente la calidad de vida de las personas, ya que se restringen las horas con acceso a energía, afectando oportunidades de educación, productividad y acceso a las tecnologías de la información y la comunicación (TICs) y esto, a su vez, contribuye a la perpetuación de la desigualdad regional que afecta el país (González et al., 2014).

Teniendo en cuenta lo anterior, se ve la necesidad de buscar alternativas que garanticen la generación, el transporte y el consumo de recursos energéticos, con el fin de asegurar la estabilidad económica, el suministro a todo el territorio y la disminución de emisiones de gases de efecto invernadero que contribuyen al cambio climático. En este sentido, en distintas zonas del país existe variedad de recursos renovables con capacidad de ser transformados en energía; de ellos, el recurso solar es de gran importancia, ya que la tecnología fotovoltaica usada para la producción de energía solar permite realizar instalaciones que alimentan sistemas alejados de la red de distribución, genera bajas emisiones de gases de efecto invernadero, y tiene costos de fabricación decrecientes con tecnología mejorada y eficiente (UPME, 2015; Cuervo & Méndez, 2011). Además, la disponibilidad del recurso solar en gran parte del territorio nacional tiene un promedio diario multianual cercano a 4,5 KWh/m² e inclusive en algunas zonas puede llegar a los 6,0 KWh/m², valores superiores a los registrados en países referentes en este sector como Alemania y España (Vanegas et al., 2015). Lo anterior se explica porque Colombia se encuentra ubicado en la región ecuatorial donde los niveles de radiación son constantes a lo largo del año (Checa & De la Cruz, 2015).

El pronóstico de la radiación solar es esencial para un diseño óptimo de un sistema energético basado en energía solar, puesto que los costos de inversión de los sistemas de energía renovable son altos en comparación con sistemas convencionales; además, para los operadores de redes eléctricas, el pronóstico es necesario para mitigar el posible impacto que pueda traer la variabilidad de la energía generada por radiación solar, ya que esas variaciones provocan cambios en las plantas de producción, afectando la infraestructura eléctrica (Aryaputera et al., 2015, Urrego et al., 2019). Por lo tanto, es fundamental determinar y evaluar con precisión el posible potencial energético de una región antes de invertir en ella (Hocaoglu, 2011). Debido al comportamiento aleatorio de la atmósfera, uno de los retos para la gestión y la planificación del recurso solar es el pronóstico, ya que es difícil obtener modelos que brinden datos precisos (Hocaoglu et al., 2009). En este sentido, contar con modelos adecuados para la estimación de la radiación solar a partir de los datos disponibles es de vital importancia para los estudios de planificación energética. Hasta ahora se han generado diferentes modelos para la predicción de radiación solar, como lo son los métodos estadísticos, los modelos numéricos de predicción meteorológica (NWP), los modelos basados en imágenes satelitales y los híbridos, que son combinaciones de diferentes modelos. Se encuentra en la literatura numerosos estudios sobre la predicción de irradiancia solar utilizando diferentes modelos NWP en diversas ubicaciones, principalmente en países ubicados en latitudes medias, debido a la concentración de instalaciones de energía renovable allí; aun así, es posible encontrar algunos estudios en regiones tropicales (Aryaputera et al., 2015). Entre los NWP se encuentra el Modelo Weather Research and Forecasting (WRF), el cual ha sido ampliamente utilizado para pronosticar las variables meteorológicas relacionadas con la producción fotovoltaica, con una antelación hasta de 72 horas (Olarte, 2017). Este modelo ha presentado una habilidad considerable para el cálculo de la radiación solar, pero ha mostrado una marcada dependencia de las condiciones del cielo. En general, el modelo entrega resultados más precisos para cielos despejados, lo que refleja una capacidad limitada para pronosticar adecuadamente las condiciones nubladas (Lara et al., 2012).

Teniendo en cuenta que según la UMPE, se espera que entre el 2021-2029 se tengan plantas solares que entreguen hasta 329 MW, lo que es aproximadamente el 2% de la capacidad energética en Colombia (Urrego et al., 2019), es importante encontrar un modelo que realice pronósticos con la suficiente precisión para una adecuada gestión y planificación del recurso solar en las diferentes zonas del país. En este sentido, este Trabajo de Grado evalúa el desempeño del modelo atmosférico WRF en el pronóstico meteorológico de radiación solar, específicamente en el Valle de Aburrá, Colombia, en aras de conocer las capacidades de este modelo para la estimación de radiación solar en esta zona. Para esto, se emplearon diferentes métricas de error comúnmente encontradas en este tipo de estudios, como el error de sesgo medio (MBE), el error cuadrático medio (RMSE) y la correlación de Pearson. Además, se comparó el modelo WRF con un modelo de persistencia, que es un modelo sencillo que asume que la radiación del día de mañana es idéntica a la actual, esto con el ánimo de saber

si WRF presenta menor margen de error que el modelo más simple encontrado, y así, orientar posibles decisiones sobre el método a elegir para la estimación del recurso solar en la región de estudio.

2.1 Objetivo general

Evaluar el desempeño del modelo atmosférico WRF en el pronóstico meteorológico de irradiancia solar en el Valle de Aburrá, Colombia.

2.2 Objetivos específicos

- Caracterizar la variabilidad de la irradiancia solar en superficie en el Valle de Aburrá a partir de información proporcionada por el Sistema de Alertas Tempranas del Valle de Aburrá (SIATA).
- Caracterizar la variabilidad de la irradiancia solar en superficie en el Valle de Aburrá a partir de simulaciones mediante el modelo WRF.
- Comparar las simulaciones de irradiancia solar en superficie del modelo atmosférico WRF con la información de observaciones in situ de la red de piranómetros del SIATA.

2.3 Marco Teórico

La radiación solar es la energía emitida por el sol mediante ondas electromagnéticas que viajan a la velocidad de la luz. Esta energía determina la dinámica de procesos atmosféricos y climáticos, además de que es una fuente alternativa en la generación de electricidad (IDEAM, s.f). Esta radiación es emitida sobre un espectro de longitud de onda conocido como espectro electromagnético, el cual se divide en radiación de onda corta y radiación de onda larga. La radiación de onda corta está asociada a una longitud de onda menor a $4 \mu\text{m}$, y se refiere a la energía emitida por el sol, que tiene mayor contenido energético; por su parte, la radiación de onda larga tiene una longitud de onda mayor a $4 \mu\text{m}$, y está asociada a la energía emitida por la Tierra, que es menos energética (Wallace y Hobbs, 2006).

La magnitud de radiación que llega al tope de la atmósfera terrestre está dada por la constante solar, que tiene una magnitud aproximada de 1367 W/m^2 ; sin embargo, este valor puede variar dependiendo de la actividad solar, la cual está relacionada con el número de manchas solares presentes en la superficie del sol, que varían con un periodo aproximado de 11 años (Chambi, 2018). Además, el valor de la constante solar también depende de las variaciones en la forma de la órbita alrededor del sol, es decir, cambios en la excentricidad, los cuales se dan cada 80,000 a 90,000 años (IDEAM & UNAL, 2018). La radiación solar recibida en la

superficie terrestre es considerablemente menor a la presentada en la parte superior de la atmósfera, debido a que la radiación, al llegar a la atmósfera, sufre una serie de fenómenos que generan cambios importantes en su magnitud. Aproximadamente, el 30% de la radiación solar es reflejada hacia el espacio exterior debido al fenómeno de reflexión atmosférica; el 70% de radiación solar restante ingresa a la atmósfera y sigue sufriendo cambios debido a fenómenos de absorción, difusión y dispersión que se dan por el choque de los fotones con gases y aerosoles presentes en la atmósfera (Vázquez Axotla, 2014). También es importante tener en cuenta que la radiación solar que llega a la superficie de la Tierra se rige por consideraciones astronómicas como el ciclo del día y la noche, efectos estacionales que dependen de la latitud, y algunos eventos excepcionales como los eclipses (Engeland et al., 2017).

La magnitud de radiación solar que llega a la Tierra es conocida como irradiancia, la cual mide la energía incidente por unidad de tiempo y área y se mide en W/m^2 . La medición y la predicción confiable de la irradiancia solar se hace fundamental en cualquier etapa de un proyecto de energía solar, ya que diseñar, construir e implementar un sistema que involucre la transformación de la energía solar a otro tipo de energía con un rendimiento óptimo, demanda conocer la cantidad de radiación recibida del sol, lo que posibilita conocer la viabilidad o la incertidumbre del proyecto (Peña, 2018). La medición de la irradiancia solar depende de la inclinación y orientación en la que esté ubicado el sensor, ya que, no es lo mismo registrar radiación incidente en una superficie horizontal que en una vertical. Esta medición se hace tradicionalmente mediante radiómetros, los cuales pueden ser de dos tipos: pirheliómetros y piranómetros. Estos sensores convierten la energía proveniente del sol en otro tipo de energía, principalmente eléctrica, de modo tal que esta última pueda ser medida de una forma mucho más sencilla (Pérez, 2007). Los pirheliómetros son instrumentos cuya superficie receptora se dispone perpendicularmente a los rayos solares incidentes y miden irradiancia normal directa (DNI), es decir, la radiación recibida desde el sol sin haber sido dispersada por la atmósfera; por su parte, los piranómetros miden la radiación global (GHI), la cual se define como la suma de la radiación que procede directamente del disco solar (DNI) y de la radiación difusa (DHI), es decir, la radiación solar que ha sido dispersada por nubes, aerosoles y otros componentes atmosféricos (Peña, 2018).

La creciente incorporación de la energía solar en la generación de energía eléctrica ha aumentado el interés en el pronóstico de la irradiancia solar, ya que esta se ha convertido en una variable clave para muchas aplicaciones, como la planificación operativa, la gestión del recurso, las compras de energía, la programación de los sistemas de energía, etc. (Lago et al., 2018). En las redes eléctricas, la información sobre la producción de energía solar esperada es crucial para garantizar la estabilidad del sistema. El pronóstico adecuado de la radiación solar también reduce los costos de integración de la energía solar en la red eléctrica al igual que aumenta la competitividad de la energía solar frente a las energías convencionales (Arbizu-Barrena et al., 2017).

En general, los métodos para el pronóstico de irradiancia solar se dividen en tres categorías: métodos estadísticos, modelos numéricos de pronóstico meteorológico (NWP) y modelos basados en imágenes satelitales. Los métodos estadísticos son métodos de predicción que se basan en datos históricos de irradiancia solar, los cuales se han utilizado durante décadas con éxito en la predicción de radiación solar y de otras variables meteorológicas (Mostafavi et al., 2013; Peña, 2018). Los NWP simulan condiciones meteorológicas; estos infieren información sobre la cobertura local de nubes a través del modelado dinámico de la atmósfera y se basan en la resolución de las ecuaciones de Navier-Stokes para el movimiento fluido en la atmósfera. Además, se han utilizado ampliamente para pronosticar la radiación solar entre 6 y 48 horas a priori (Mostafavi et al., 2013; Reikard, 2020). Los modelos basados en imágenes capturan directamente la información de nubes de imágenes satelitales para realizar pronósticos de radiación solar, proporcionando pronósticos efectivos que varían de minutos a horas de anticipación, pero el alto costo de las instalaciones de captura de imágenes limita el uso de estos modelos (Zang et al., 2020). En la literatura también es común encontrar híbridos de modelos, es decir, el uso integrado de varios modelos que proporcionan una buena alternativa para la predicción de la radiación solar (Mostafavi et al., 2013; Zhang et al., 2017; Zang et al., 2020).

Para garantizar un buen funcionamiento de una planta y producción de energía eléctrica de alta calidad, es necesario contar con información de pronósticos confiables en diferentes horizontes de tiempo. La elección del modelo adecuado depende principalmente del horizonte. En horizontes más largos (desde varias horas hasta unos pocos días), los modelos NWP son más precisos; en cambio, los modelos estadísticos y los basados en imágenes funcionan mejor en horizontes cortos (menos de 1 hora) a intermedios (del orden de 1 a 6 horas) (Reikard, 2020).

El primer NWP operativo se estableció en 1954, y aunque estos modelos se han venido mejorando con el tiempo, aún son tema de estudio. En Europa y en América del Norte se han realizados varios estudios utilizando modelos de NWP, pero en la zona tropical se han estudiado menos y se han encontrado resultados más deficientes, puesto que el clima tropical es más difícil de pronosticar, en particular porque predecir la nubosidad en estas regiones es complicado, ya que las nubes convectivas necesitan altas resoluciones para su predicción (Verbois et al., 2018).

El modelo WRF es un sistema numérico de predicción meteorológica de mesoescala que ha sido diseñado para satisfacer necesidades de predicción operativa y de investigación atmosférica (Lima et al., 2016). Este modelo ha sido utilizado para pronóstico de diferentes variables como lluvia, viento, humedad relativa, radiación solar, etc. Además, WRF ha sido empleado en la región (Medellín-Colombia) para estimaciones iniciales de radiación solar

(Urrego et al., 2019). Sin embargo, en el pronóstico de irradiancia solar se ha evidenciado problemas en el rendimiento de WRF, debido principalmente al conocimiento insuficiente de las condiciones atmosféricas iniciales; además, WRF presenta un error de propagación a través del modelo debido a procesos que no son capturados por la resolución del mismo. Estos procesos son demasiado complejos para ser simulados de manera oportuna (Huva et al., 2020), como la formación de nubes y la presencia de aerosoles en la atmósfera. Para minimizar este error se ha usado WRF en una configuración particular, WRF-SOLAR, que corresponde a una versión de WRF que contiene características útiles para el pronóstico de la energía solar, entre ellos, cambios en la física del modelo que explican la retroalimentación entre aerosoles, irradiancia solar y nubes (D'Isidoro et al., 2020). Otros autores han usado diferentes configuraciones del modelo y procesos de posprocesamiento para mejorar el rendimiento del modelo, ofreciendo resultados significativamente mejores que modelos de referencia como la persistencia y los pronósticos climatológicos (Verbois et al., 2018).

El sector energético colombiano depende principalmente de la energía hidroeléctrica; sin embargo, el país está recurriendo a la energía solar y otras renovables para diversificar su matriz eléctrica. Para lograrlo, se han tenido algunos avances como: la firma de la Ley 1715 el 13 de mayo de 2014 referente a la regulación de la integración de las energías renovables en el Sistema Eléctrico Nacional (SEN), que impulsa e incentiva el uso de las fuentes no convencionales de energía, el crecimiento del número de proyectos solares registrados, el atlas de radiación solar de Colombia, el desarrollo de eventos de energías renovables donde expertos se reúnen para discutir los avances de la transición energética y el desarrollo de estudios en algunas zonas del país, como La Guajira, que demuestran que los niveles de radiación son adecuados para el desarrollo de instalaciones solares (Colombia Energía, 2020; Vanegas et al., 2015). Colombia es un territorio con una ubicación geográfica privilegiada, que le otorga un alto potencial energético solar, inclusive cuenta con niveles de radiación promedio anual mayores a los países que presentan la mayor capacidad fotovoltaica (Checa & De la Cruz, 2015; Vanegas et al., 2015).

Teniendo en cuenta lo anterior, es importante resaltar la necesidad de estudiar el pronóstico de la radiación solar en Colombia utilizando modelos como WRF, ya que esto contribuirá representativamente en la implementación de nuevos proyectos de energía solar. Esto debido a que es importante cuantificar el recurso en todas las regiones, inclusive en aquellas donde la disponibilidad de instrumentos de medición es reducida, para tomar decisiones adecuadas en la implementación de proyectos y evitar omitir alguna región con alto potencial energético solar.

3. Metodología

3.1 Área de estudio

Para realizar la evaluación del modelo WRF en el pronóstico de irradiancia solar, se utilizaron los dominios anidados presentados en la **Figura 1**. El dominio exterior incluye toda Colombia con un tamaño de celda de 12 km, y el interior incluye el departamento de Antioquia, con un tamaño de celda de 4 Km. Ambos contienen el Valle de Aburrá, que es el área donde se realizó la evaluación de WRF. El Valle de Aburrá está ubicado en la cordillera central de Colombia en el centro de Antioquia, y está conformado por 10 municipios. Posee una extensión de 1.165,2 Km² que corresponde al 1,83% del área del departamento; aun así, es un área con alta densidad poblacional, ya que tiene un porcentaje total del 58,5% de los habitantes de todo el departamento (Bernal, 2019).

Según el IDEAM, Medellín, la principal ciudad del Valle de Aburrá y de donde se tomaron las mediciones in situ para este estudio, tiene un clima templado-seco, con un promedio de lluvia total anual de 1685 mm. Las lluvias durante el año se distribuyen en dos temporadas secas, de diciembre a febrero y de junio a agosto, donde enero y febrero son los meses más secos del año; y dos lluviosas, desde finales de marzo hasta principios de junio y desde finales de septiembre hasta principios de diciembre. La temperatura promedio de la ciudad es de 21.5 °C. Al medio día la temperatura máxima media oscila entre 26 y 28°C, mientras que en la madrugada la temperatura mínima está entre 17 y 18°C. Además, el sol brilla cerca de 4 horas diarias en los meses lluviosos, pero en los meses secos, la insolación llega a 6 horas diarias (IDEAM, sf).

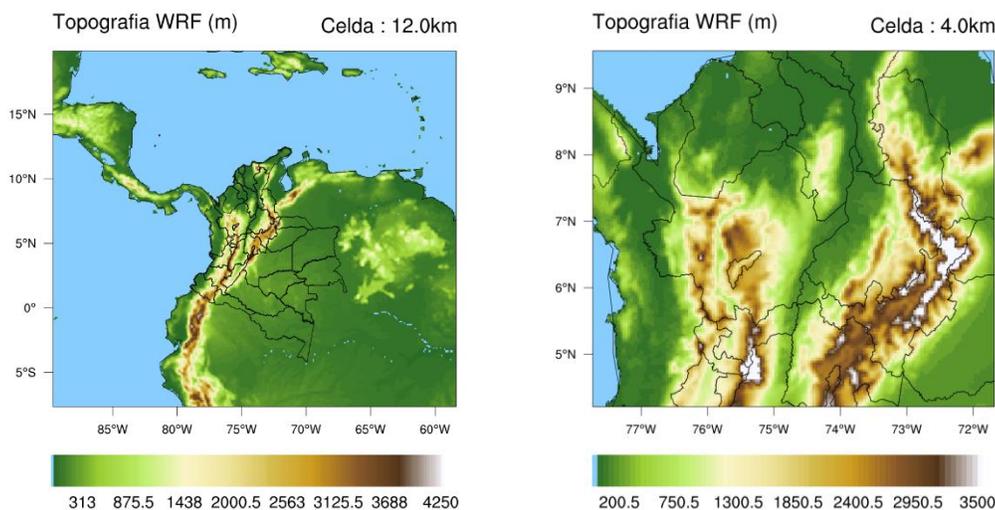


Figura 1. Dominio espacial para las simulaciones mediante el modelo WRF

3.2 Datos

3.2.1 Piranómetro SIATA

Para el estudio, se utilizaron mediciones in situ proporcionadas por el Sistema de Alertas Temprana del Valle de Aburrá (SIATA), específicamente de la estación Torre SIATA, que se encuentra ubicada a 6. 2595° latitud y 75.887° longitud en Medellín, Colombia. El piranómetro Torre SIATA proporciona datos de irradiación solar (GHI), con resolución temporal y espacial de 1 minuto y de 1 W/m², respectivamente. Tiene datos disponibles desde el 9 de marzo de 2016 hasta la actualidad. Para realizar la caracterización de la radiación solar en el sitio de estudio se utilizaron datos comprendidos entre 2016 y 2019; mientras que para comparar las simulaciones del modelo WRF se utilizaron datos del año 2019 para las simulaciones de 24 horas, y 2020 y 2021 para las simulaciones de 48 horas. Los datos se descargaron de https://siata.gov.co/descarga_siata/index.php/Index2/, en formato CSV. En la **Tabla 1** se observa la cantidad de datos faltantes o de calidad dudosa, para el piranómetro Torre SIATA entre las 6 y las 18 horas, que debieron ser previamente eliminados mediante un procesamiento con ayuda de la herramienta Python.

Tabla 1. Porcentaje de datos perdidos del piranómetro Torre SIATA

Año	Porcentaje Datos Perdidos
2016	16.49%
2017	14.02%
2018	10.36%
2019	14.30%
2020	11.57%
2021	7.58%

3.2.2 Simulaciones WRF y persistencia

Para evaluar la capacidad de WRF para representar la irradiación solar se utilizaron simulaciones con horizontes de 24 y 48 horas. Se estudiaron 138 días de simulaciones de 24 horas de anticipación dentro del periodo comprendido entre marzo de 2019 y noviembre de 2019. Los pronósticos comienzan a las 6 UTC (1 am local) y terminan

a las 6 UTC del día siguiente. Las simulaciones mencionadas anteriormente se compararon con el modelo de persistencia, que es simplemente la suposición de que los valores para el día siguiente corresponden a los valores del presente. Todos los datos utilizados para el modelo de persistencia fueron tomados del piranómetro Torre SIATA. Debido a la cantidad de datos faltantes no fue posible estudiar la persistencia con los 138 días de simulaciones sino con 124 días. Por otra parte, se estudiaron 294 días con simulaciones de 48 horas, entre marzo de 2020 y enero de 2021. Los pronósticos inician a la 00 UTC (7 pm del día anterior) y corren por 54 horas; no se tienen en cuenta las primeras 6 horas porque se considera que el modelo necesita tiempo para estabilizarse. Por lo tanto, estas simulaciones se dividieron en dos partes para ser estudiadas: se analizaron primero las horas de sol del primer día y por separado se estudiaron las horas de sol del segundo día. Las simulaciones de 48 horas también fueron comparadas con modelos de persistencia. Las horas de sol del primer día se compararon con un modelo de persistencia que también suponía que la irradiancia del presente corresponde a la que sucedió en las 24 horas anteriores, mientras que las horas de sol del segundo día se compararon con un modelo de persistencia que suponía que la irradiancia del presente corresponde a la que sucedió en las 48 horas previas.

3.3 Procesamiento de datos

Para el procesamiento de los datos se utilizó Python a partir de diferentes librerías como Numpy, Pandas y Matplotlib. Estas librerías permiten calcular todos los estadísticos y las gráficas necesarias para cumplir los objetivos planteados. Debido a que la irradiancia solar disminuye notoriamente en la mañana y en la tarde, se recortaron las horas de estudio, utilizando un rango entre las 6 y las 18 horas para todos los cálculos, que es un periodo que ha sido estudiado anteriormente en estudios similares (Urrego, 2018). Además, teniendo en cuenta la resolución temporal de las mediciones de Torre SIATA (1 minuto) y las simulaciones de WRF (15 minutos) son diferentes, ambos conjuntos de datos fueron llevados a una misma resolución temporal de 1 hora para una adecuada comparación.

3.3.1 Métricas de error

Se usaron tres métricas de error: la desviación media del error (MBE), el error cuadrático medio (RMSE) y el coeficiente de correlación de Pearson (r), que como se mencionó anteriormente, son métricas comúnmente usadas en estudios de pronóstico de radiación solar. Con estas se evalúa el desempeño del modelo WRF, ya que cuantifican el error del modelo respecto a los registros del SIATA.

3.3.1.1 Desviación media del error (MBE)

Es el promedio de la diferencia entre lo pronosticado por el modelo WRF y lo observado en los registros del SIATA, de modo que los valores positivos de la métrica representan sobreestimaciones de las observaciones medidas, mientras que los valores negativos representan subestimaciones de las mismas.

$$MBE = \frac{1}{n} \sum_{i=0}^n I_{MODELO,i} - I_{SIATA,i} \text{ w/m}^2 \quad \text{Ec.1}$$

MBE normalizado:

$$nMBE = \frac{MBE}{\bar{I}_{SIATA}} \% \quad \text{Ec.2}$$

3.3.1.2 Error cuadrático medio (RMSE)

El error cuadrático medio es la raíz de las diferencias cuadráticas entre los valores estimados por el modelo WRF y los valores medidos in situ del SIATA. Esta medida es sensible a valores extremos, permitiendo detectar claramente los cambios repentinos de la radiación sobre las series de tiempo evaluadas, además es una medida usada frecuentemente para evaluar la precisión de los pronósticos.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (I_{MODELO,i} - I_{SIATA,i})^2} \text{ w/m}^2 \quad \text{Ec.3}$$

RMSE normalizado:

$$nRMSE = \frac{RMSE}{\bar{I}_{SIATA}} \% \quad \text{Ec.4}$$

3.3.1.3 Coeficiente de correlación de Pearson (r)

El coeficiente de correlación de Pearson mide el grado de correlación entre dos variables, en este caso entre el valor estimado por WRF y el valor medido por SIATA y se obtiene dividiendo la covarianza de las dos variables por el producto de sus desviaciones estándar. Este coeficiente es tal que $-1 < r < 1$. Un valor mayor que 0 indica una asociación positiva, es decir, a medida que crece el valor estimado también lo hará el medido. Por el contrario, un valor menor que 0 indica una relación negativa, es decir, a medida que crece el valor proporcionado por WRF decrece el valor medido o viceversa. Por último, un valor de 0 indica que no hay relación entre el valor simulado por WRF y el valor medido por SIATA.

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \frac{(I_{MODELO,i} - \bar{I}_{MODELO,i})(I_{SIATA,i} - \bar{I}_{SIATA,i})}{\sqrt{\sum_{i=1}^n (I_{MODELO,i} - \bar{I}_{MODELO,i})^2 \sum_{i=1}^n (I_{SIATA,i} - \bar{I}_{SIATA,i})^2}} \quad \text{Ec.5}$$

4. Resultados y análisis

4.1 Irradiancia solar SIATA

Esta sección caracteriza la variabilidad de la irradiancia solar en superficie en el Valle de Aburrá, según las mediciones in situ del piranómetro Torre SIATA, para un periodo de tiempo de 4 años, desde marzo de 2016 hasta febrero de 2020.

4.1.1 Ciclo anual de irradiancia solar

La **Figura 2** muestra el ciclo anual de irradiancia solar para la estación Torre SIATA. En el ciclo anual se evidencia que la irradiancia presentó un comportamiento bimodal. Se presentaron dos picos marcados, uno de ellos iniciando en el mes de diciembre y terminando en marzo, con un valor máximo en febrero de $466,87 \text{ W/m}^2$. El otro pico se dio entre junio y agosto, siendo agosto el mes con mayor radiación solar de todo el ciclo ($477,22 \text{ W/m}^2$). Asimismo, se evidenciaron dos valles, uno entre marzo y mayo con magnitud mínima en mayo de $392,26 \text{ W/m}^2$. El otro valle lo presentó el mes de noviembre, que es el mes que exhibe la menor magnitud de radiación solar de todo el ciclo anual ($375,01 \text{ W/m}^2$). Este comportamiento concuerda con el régimen bimodal de precipitación en la región de estudio; la radiación fue mínima en los meses que la precipitación presenta sus valores más altos en la zona de estudio (entre los periodos marzo-mayo y septiembre-noviembre) y fue máxima en los meses de temporada seca (entre los periodos diciembre-febrero y junio-agosto). Lo anterior, puede ser explicado por la nubosidad, ya que, las nubes son uno de los mayores impedimentos para que la radiación solar llegue a la superficie, porque intervienen tanto en los procesos de absorción como de dispersión (Tzoumanikas et al., 2016).

En un estudio reciente (Correa, 2020), se encontró una temporalidad interanual de nubes en el Valle de Aburrá, donde la nubosidad exhibe un comportamiento bimodal con picos máximos correspondientes a las temporadas húmedas, y valores mínimos en la temporada seca de la región, que estarían asociados al paso de la Zona de Convergencia Intertropical (ZCIT), que se encuentra ubicada sobre la región Andina Colombiana en los meses de temporada lluviosa, facilitando la formación de nubes convectivas; mientras que en meses de temporada seca, la ZCIT se encuentra desplazada hacia el norte del país.

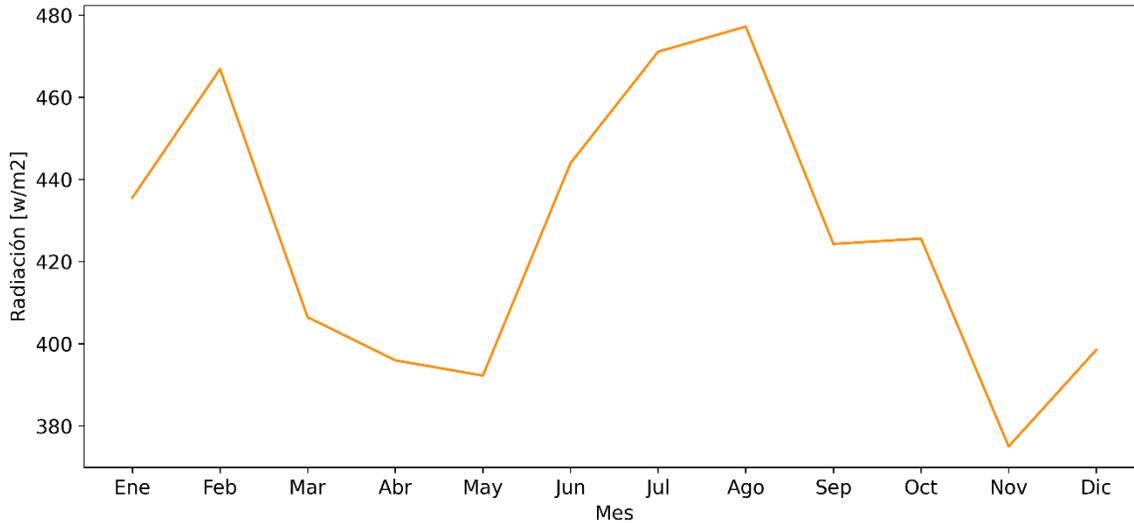


Figura 2. Ciclo anual de irradiancia solar considerando un periodo de cuatro años, desde marzo de 2016 hasta febrero de 2020, según registros de la estación Torre SIATA

4.1.2 Ciclos diurnos multianuales

En la **Figura 3** se presentan los ciclos diurnos multianuales de radiación solar para la estación Torre SIATA. Se observa que, en general, la radiación empieza a aumentar paulatinamente desde las 6 a.m. hasta la hora de mayor insolación que, dependiendo del mes, ocurre entre las 11:00 a.m. y la 1:00 p.m. Después de esa hora, la magnitud de la irradiancia empieza a disminuir. Algunos meses presentaron un pequeño valle a las 11:00 a.m. o 12:00 m. Esto podría darse por la presencia de nubes, ya que las nubes limitan la llegada de radiación solar a la superficie y se ha encontrado que en el Valle de Aburrá, cuando hay presencia de nubes al mediodía, se pueden llegar a ocasionar pérdidas de hasta 200 W/m^2 ; asimismo, las horas más sensibles a esta pérdida están entre las 9 am y el mediodía (Correa, 2020).

Agosto presentó la mayor magnitud de irradiancia solar con un pico máximo de $825,27 \text{ W/m}^2$, le sigue febrero y julio con $824,23 \text{ W/m}^2$ y $794,79 \text{ W/m}^2$, respectivamente. Por otra parte, marzo, abril y noviembre presentaron picos máximos con menor magnitud, con valores de $666,60 \text{ W/m}^2$, $622,09 \text{ W/m}^2$ y $679,90 \text{ W/m}^2$, respectivamente, lo que rectifica que los meses de temporada lluviosa en la región presentaron menores magnitudes de radiación solar.

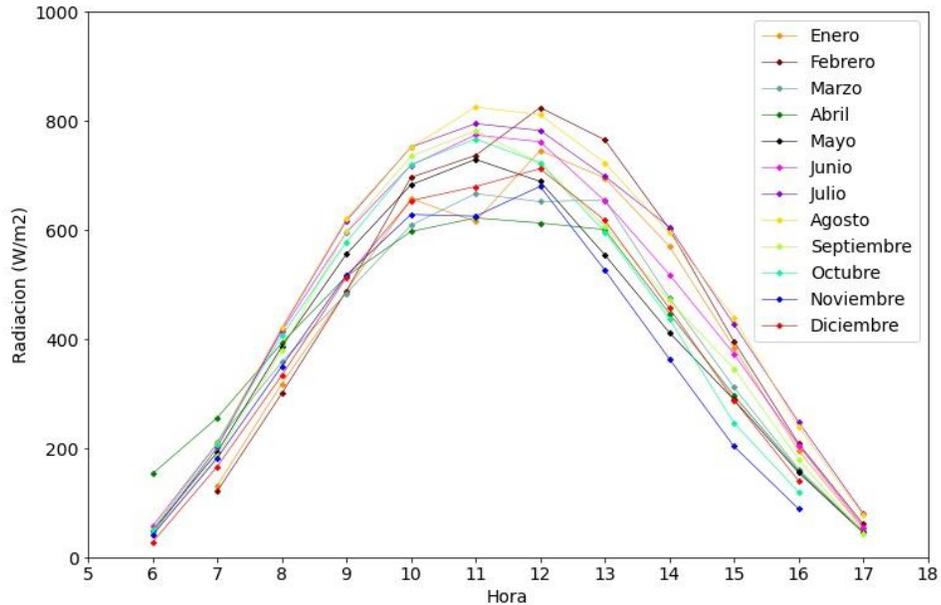


Figura 3. Ciclos diurnos multianuales considerando un periodo de tiempo desde marzo de 2016 hasta febrero de 2020 según registros de la estación Torre SIATA

4.1.3 Series promedios diarios de irradiancia solar

En las **Figuras 4 y 5** se presentan las series de promedios diarios particularmente para los meses de agosto y noviembre, ya que son los meses que presentaron mayor y menor magnitud de radiación solar en el ciclo anual presentado en el apartado 4.1.1. Agosto, presentó picos máximos de irradiancia solar los días 12 (2016) con 595,56 W/m², 14 (2017) con 622,08 W/m², 16 (2018) con 636,34 W/m² y 8 (2019) con 685,03 W/m². Por su parte, noviembre mostró picos máximos los días 21 (2016) con 616,00 W/m², 06 (2017) con 521,97 W/m², 16 (2018) con 530,05 W/m² y 30 (2019) con 545,58 W/m². En general, agosto presentó mayores magnitudes de irradiancia solar que noviembre, como era de esperarse, ya que noviembre hace parte de la segunda temporada lluviosa de la región de estudio, caracterizada por presentar alta nubosidad. Se observa en todos los años, que gran cantidad de días del mes de agosto alcanzaron magnitudes de irradiancia solar mayores a los 450 W/m², mientras gran parte de los días de noviembre se ubicaron por debajo de este valor; aun así, algunos días de agosto alcanzaron promedios diarios más bajos que los presentados por noviembre.

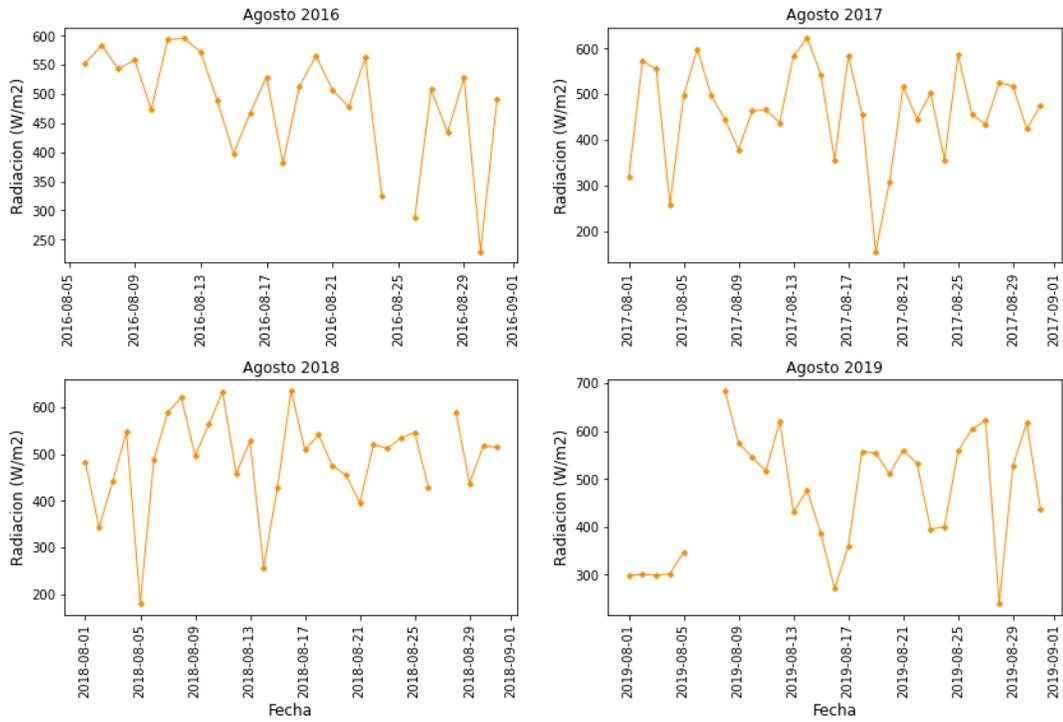


Figura 4. Serie promedios diarios para agosto según registros de la estación Torre SIATA

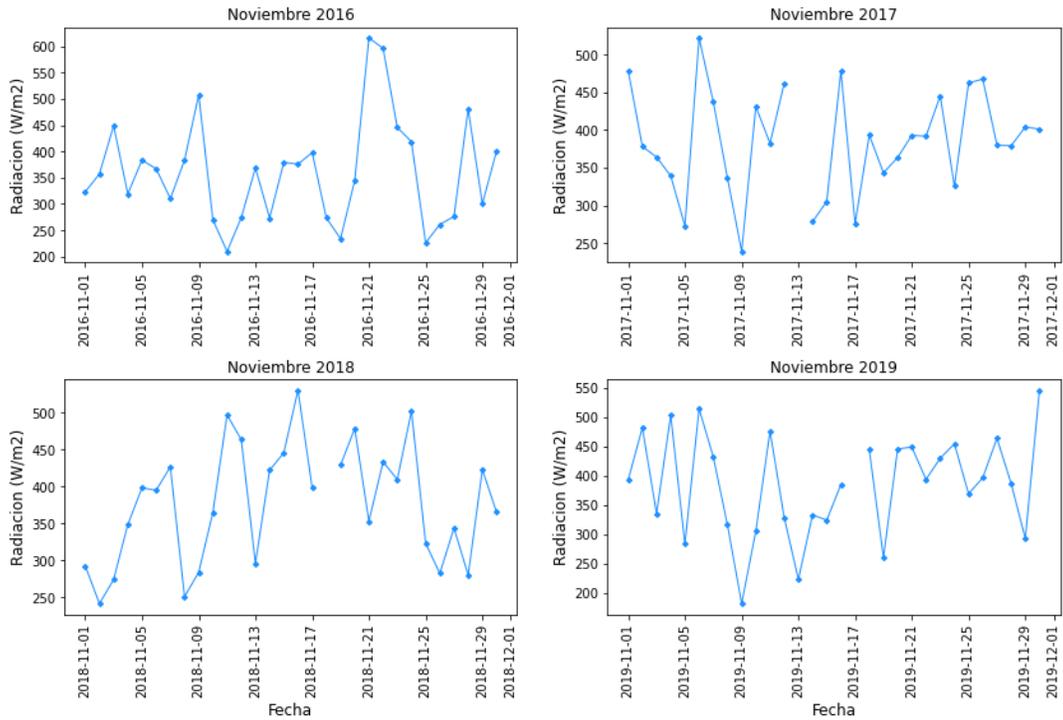


Figura 5. Serie promedios diarios para noviembre según registros de la estación Torre SIATA

4.2 Simulaciones WRF con horizonte de 24 horas

En esta sección se presentan los resultados de la comparación estadística que se realizó entre las mediciones in situ del piranómetro Torre SIATA y las simulaciones de WRF con un horizonte de 24 horas, al igual, que los resultados entre el modelo de persistencia y los registros in situ. El estudio se realizó para un periodo de tiempo entre marzo de 2019 y noviembre de 2019, con el objetivo de evaluar el desempeño del modelo WRF para representar la irradiancia solar en escala horaria y diaria.

4.2.1 Datos horarios

La **Figura 6** corresponde a las distribuciones de los valores horarios de irradiancia solar tanto para los registros de Torre SIATA como para las simulaciones de WRF. Los datos registrados por el piranómetro Torre SIATA y por el modelo WRF van desde los 0 W/m² hasta aproximadamente los 1000 W/m². En general, se evidencia que las mediciones del piranómetro Torre SIATA presentaron mayores frecuencias para valores entre 100 W/m² y 200 W/m² en comparación con las simulaciones de WRF. Por otra parte, el modelo mostró mayores frecuencias que las mediciones de Torre SIATA para los valores más altos de radiación solar, de 800 W/m² en adelante. Esto muestra una inclinación del modelo a sobreestimar la irradiancia solar, la cual ha sido encontrada en variedad de estudios anteriores (Zamora et al., 2005, Lara-Fanego et al., 2012, Ruiz-Arias et al., 2016, Incecik et al., 2019).

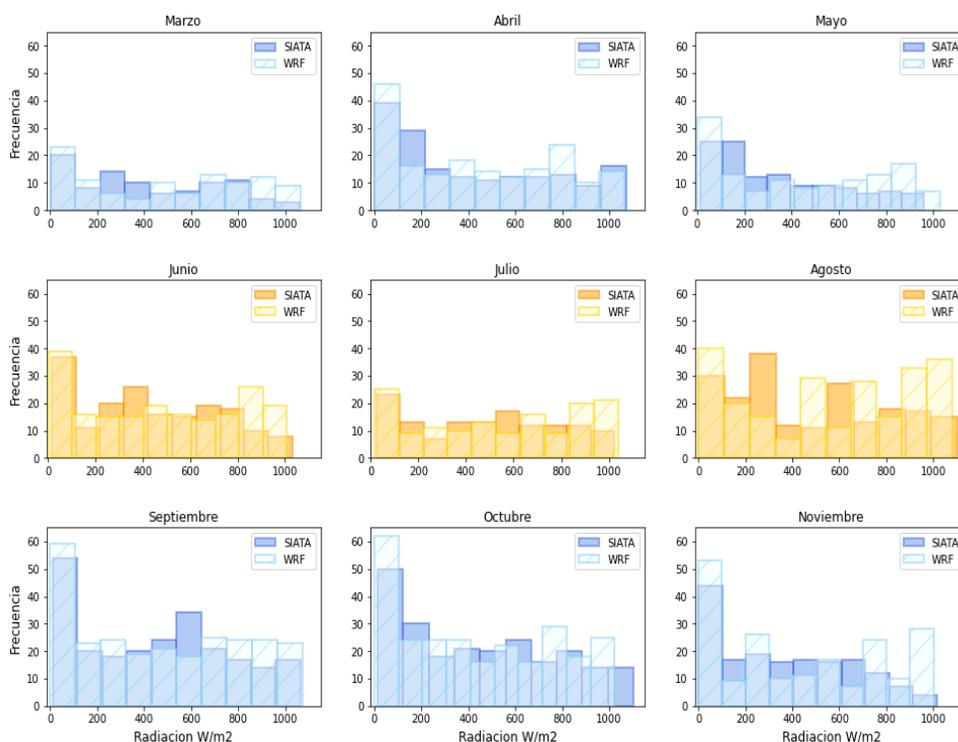


Figura 6. Distribuciones de los valores horarios de irradiancia solar para los registros de Torre SIATA y las simulaciones de WRF

En la **Figura 7** se presentan los diagramas de dispersión de los valores horarios de irradiancia solar calculados a partir de los registros de Torre SIATA y las simulaciones de WRF. Todos los meses presentaron correlaciones sustanciales mayores a 0,60, lo que es mediado principalmente por el efecto del sol, ya que este sale y se pone en el modelo al mismo tiempo que en las observaciones. Marzo, junio, julio y agosto fueron los meses con menor dispersión y correlaciones más altas, todas por encima de 0,80; por su parte, mayo fue el mes con correlación más baja (0,63) y mayor dispersión. El resto de meses presentaron correlaciones por encima de 0,70. **La Figura 8** muestra los diagramas de dispersión de los registros de Torre SIATA y el modelo de persistencia. Al igual que WRF, la persistencia presentó correlaciones sustanciales debido al efecto mencionado anteriormente; aun así, WRF mostró correlaciones más altas que el modelo de persistencia para todos los meses. La persistencia, al igual que WRF, tuvo mayores correlaciones para los meses de temporada seca de la región, y de nuevo mayo fue el mes con correlación más baja, siendo el único mes con correlación por debajo de 0,60.

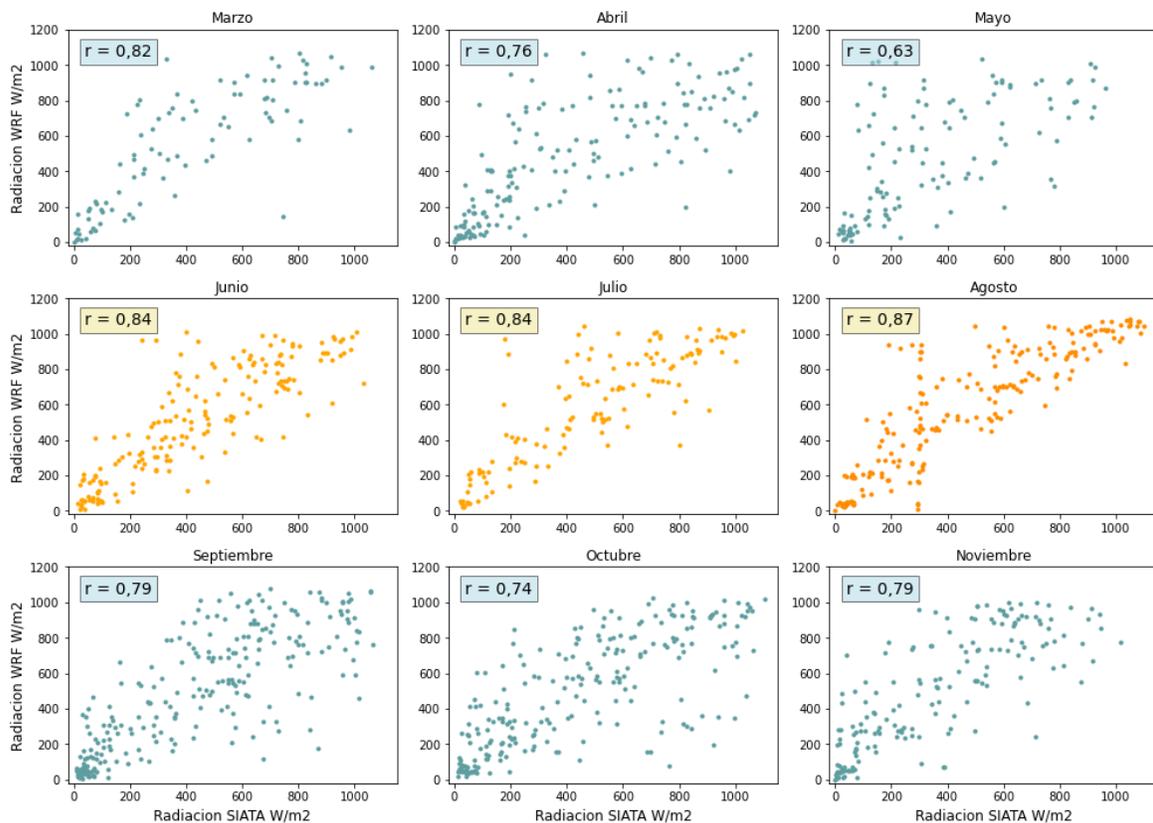


Figura 7. Diagramas de dispersión y correlaciones de los valores horarios de irradiancia solar entre los registros de Torre SIATA y las simulaciones de WRF

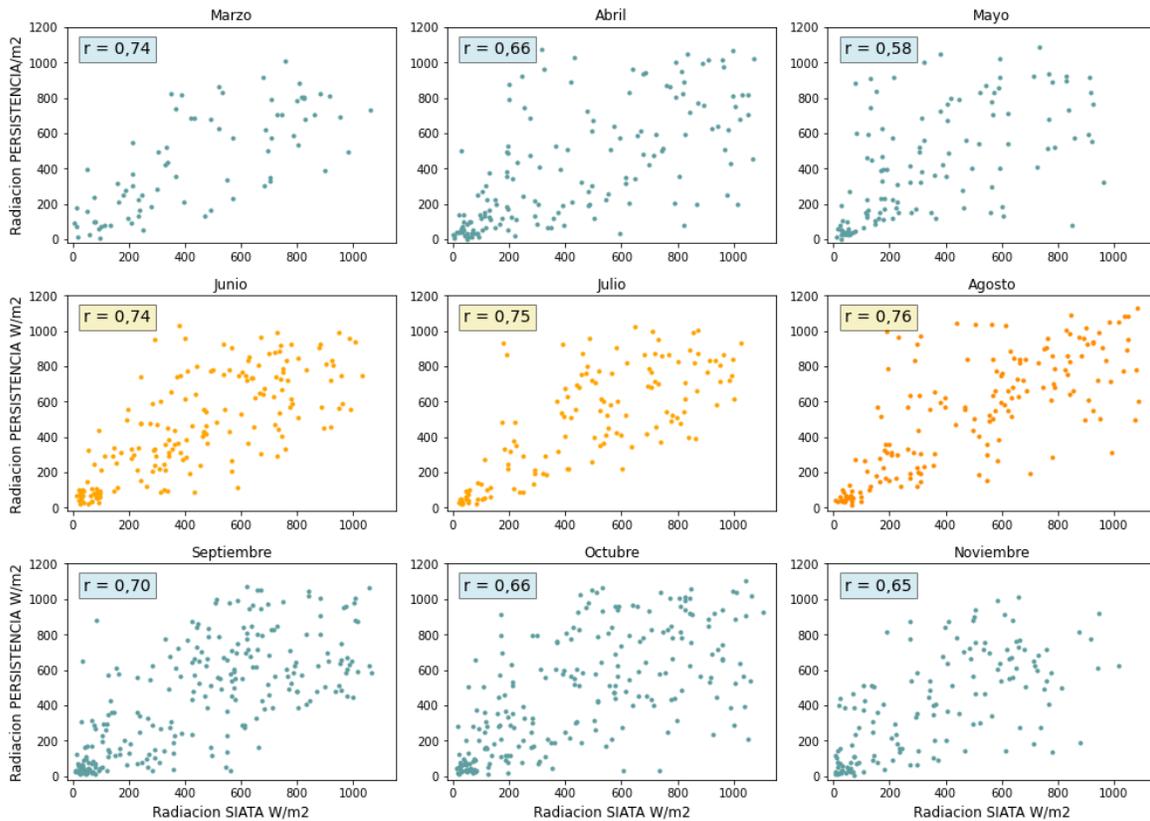


Figura 8. Diagramas de dispersión y correlación de los valores horarios de irradiancia solar entre los registros de Torre SIATA y el modelo de persistencia

En la **Figura 9** se presentan los diagramas de dispersión de las anomalías horarias respecto al ciclo diurno, entre los registros de Torre SIATA y las simulaciones de WRF. En general, se aprecia gran dispersión para todos los meses, exceptuando marzo y agosto. Los coeficientes de correlación en su totalidad mostraron menores magnitudes a los presentados para los valores horarios de irradiancia solar (**Figura 7**), debido a que en las anomalías ha sido removido el efecto del sol mencionado anteriormente. El mes con menor valor de coeficiente de correlación fue mayo, aunque gran parte de los meses presentaron correlaciones no sustanciales, es decir que la relación entre las anomalías respecto al ciclo diurno de las simulaciones de WRF y las anomalías de los registros de Torre SIATA fue muy débil o inexistente. De nuevo, agosto fue el mes con mayor coeficiente de correlación e inclusive fue el único coeficiente sustancial, es decir, agosto de 2019 fue uno de los meses en que WRF representó adecuadamente las mediciones in situ. En la **Figura 10** se muestran los diagramas de dispersión de las anomalías respecto al ciclo diurno entre los registros Torre SIATA y el modelo de persistencia. La persistencia presentó altas dispersiones y correlaciones cercanas a cero para todos los meses, ningún mes presentó alguna correlación sustancial; por lo tanto, comparado con WRF, la persistencia presenta aún más dificultades para representar las mediciones in situ cuando se remueve el ciclo diurno de los datos.

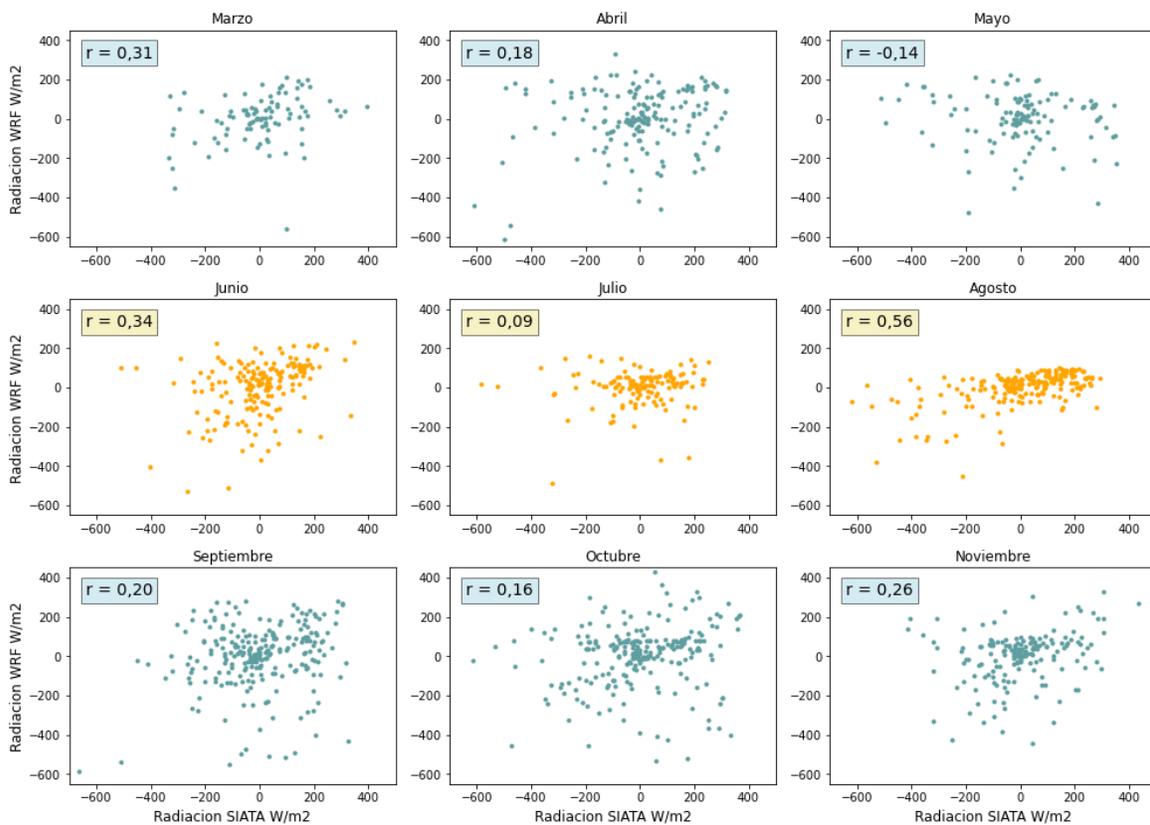


Figura 9. Diagrama de dispersión y correlaciones de las anomalías con respecto al ciclo diario de irradiación solar entre los registros de Torre SIATA y las simulaciones de WRF

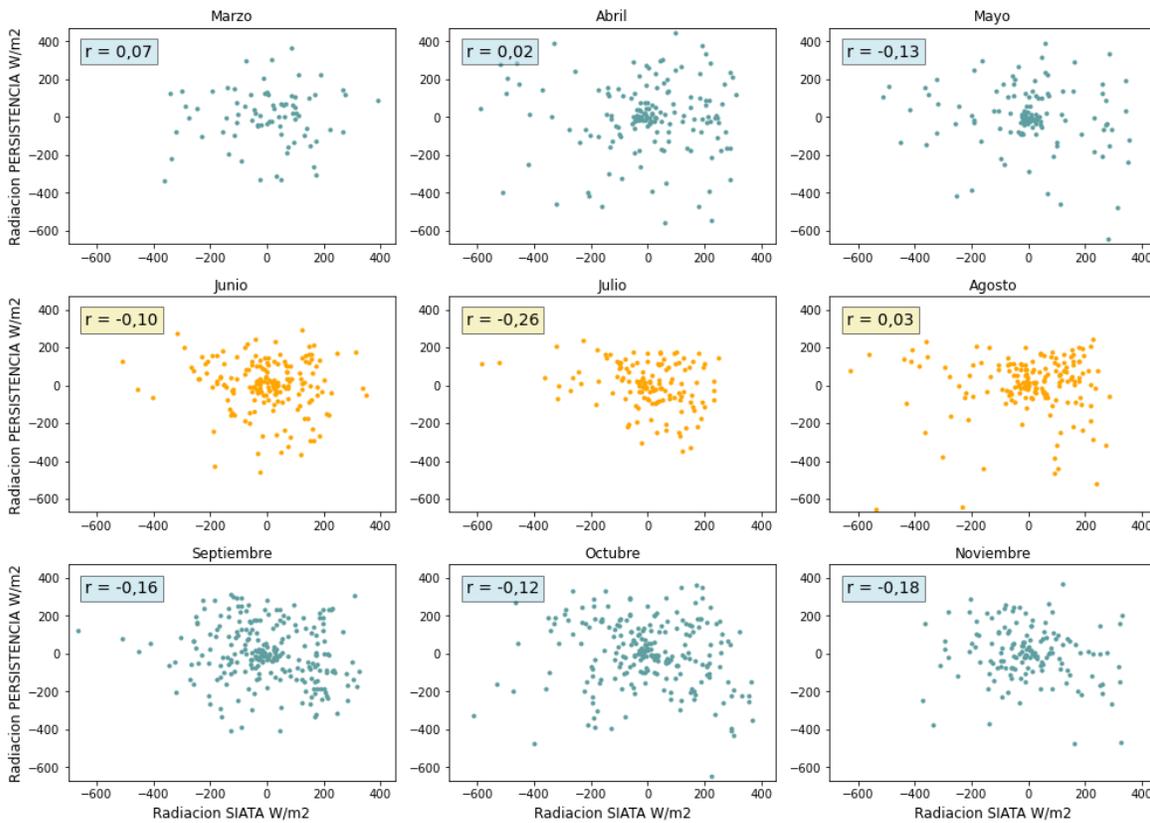


Figura 10. Diagrama de dispersión y correlaciones de las anomalías respecto al ciclo diario de irradiación solar entre los registros de Torre SIATA y el modelo de persistencia

4.3.1 Errores

En la **Figura 11** se presentan los diagramas de barras de los errores RMSE, nRMSE, MBE y nMBE obtenidos de la comparación estadística entre las simulaciones de irradiancia solar del modelo WRF y las mediciones in Situ del SIATA, y del modelo de persistencia con las mediciones in situ. En la **Figura 11-a y 11-e** se observa que WRF obtuvo RMSEs con valores positivos que oscilan entre 43,78 W/m² y 519,17 W/m² y valores de MBE que oscilan entre -133,84 W/m² y 416,85 W/m². En la **Figuras 11-c y 11-g** se observa que al estandarizar los errores se obtienen valores máximos y mínimos de nRMSE de 358,81% y 7,05% respectivamente, mientras que para el nMBE se observa un valor máximo de 289% y un mínimo en magnitud de 0,06%. Es importante resaltar que el valor máximo en todos los errores corresponde al mismo día, 08 de mayo de 2019; mientras, el valor mínimo ocurrió en días diferentes para cada error. En la **Figura 11-b y 11-d** se evidencia valores de RMSE para la persistencia entre 53,07 W/m² y 449,28 W/m² y de nRMSE entre 12,99% y 255,63%. Además, en las **Figuras 11-f y 11-h** se evidencia que el MBE de la persistencia oscila entre 383,13 W/m² y -289,08 W/m² y el nMBE presenta un mínimo de 0,24% y un máximo de 175,71%. De lo anterior, se deduce que, comparado con la persistencia, WRF alcanza valores máximos más altos, pero magnitudes más bajas de los valores mínimos.

En la **Figura 12** se observan los diagramas de cajas y bigotes para los errores RMSE y nRMSE, obtenidos de la comparación estadística entre los modelos (WRF y persistencia) y las mediciones in Situ del SIATA. El RMSE es un indicador de desempeño que permite comparar las desviaciones reales entre los valores calculados y medidos, pero este error no distingue sobreestimaciones o subestimaciones del modelo, por lo tanto, todos los valores observados en la **Figura 12** están por encima de cero. La **Figura 12-a** muestra que los meses que WRF obtuvo valores de RMSE más altos son marzo, abril, mayo, octubre y noviembre, meses que hacen parte de temporada lluviosa de la región. Por otra parte, los valores de RMSE más bajos se visualizan en junio, julio y agosto, que son meses de temporada seca en el Valle de Aburrá. Esto podría indicar que el rendimiento del modelo disminuye sustancialmente a medida que aumenta la nubosidad. La **Figura 12-c** muestra que en general la mayoría de errores (nRMSE) de WRF se encuentran debajo del 100%, exceptuando algunos días de abril, mayo y noviembre. Mayo fue el mes que reportó mayores valores de nRMSE, superando en su totalidad errores del 50% e inclusive llegando a tener errores de aproximadamente 350%. Por su parte, junio y julio fueron los meses con menores porcentajes de nRMSE, junio presenta la menor mediana (33,60%) y julio la menor variabilidad, con un valor máximo de 43,33%, sin tener en cuenta el dato atípico, y un valor mínimo de 20,92%. Por otra parte, la **Figura 12-b y 12-d** muestran que el modelo de persistencia, al igual que WRF, obtuvo mejor rendimiento

para los meses de temporada seca; y en comparación con WRF, la persistencia obtuvo menores medianas de RMSE para los meses de marzo, mayo y noviembre y menores medianas de nRMSE para marzo, abril y mayo, para los demás meses WRF obtiene menores medianas. Aun así, según los box-plots de RMSE, en meses como abril y mayo, el modelo de persistencia, en general, presenta peor rendimiento que WRF, ya que alcanza valores por encima de los 320 W/m^2 ; pero en meses como marzo y agosto los modelos presentan rendimientos muy similares o inclusive la persistencia lo hace mejor.

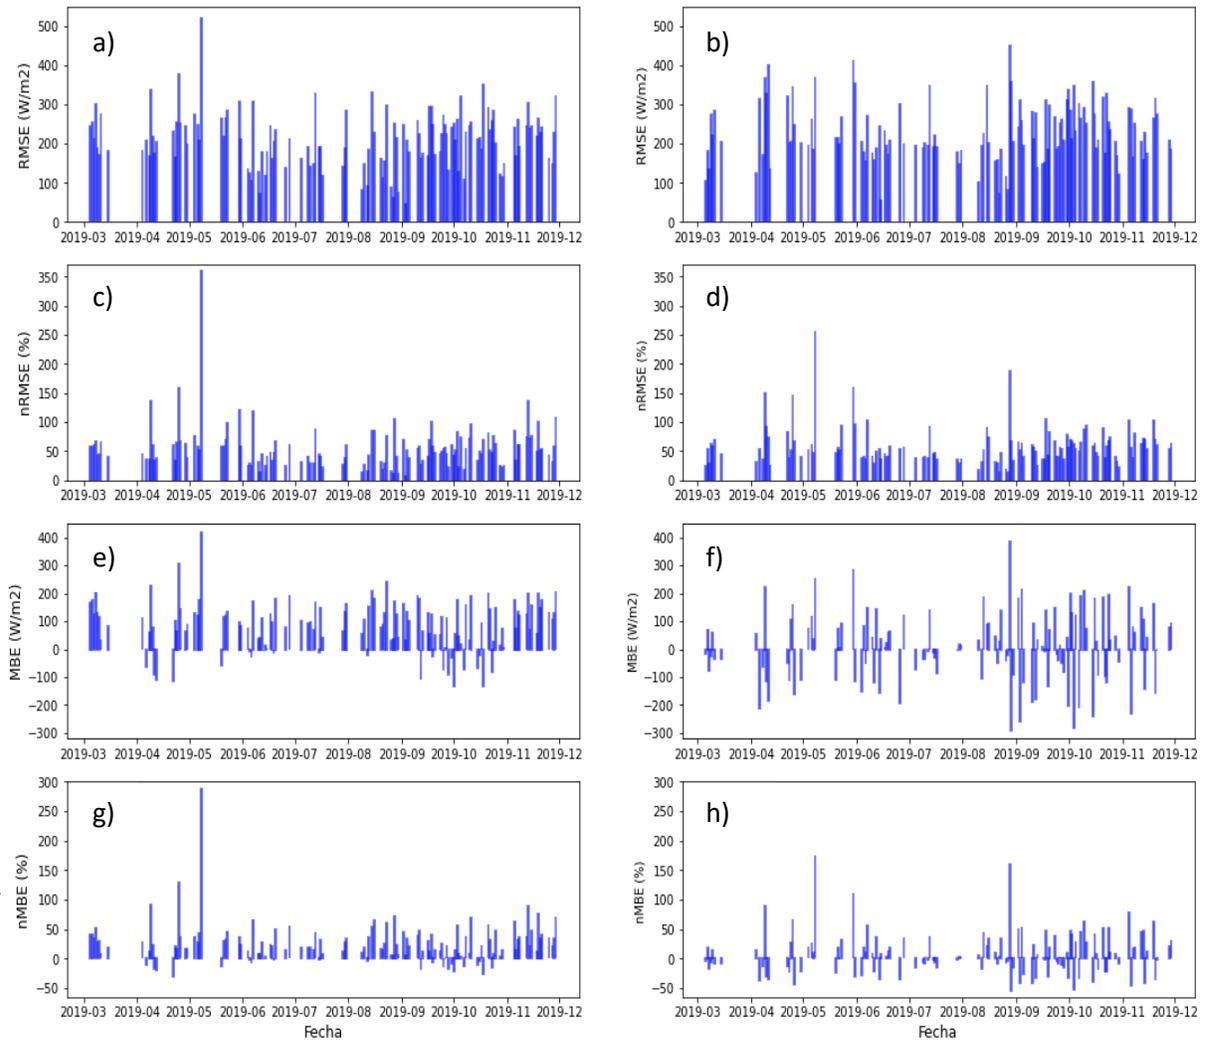


Figura 11. Diagramas de barras para *a) RMSE WRF, b) RMSE persistencia, c) nRMSE WRF, d) nRMSE persistencia, e) MBE WRF, f) MBE persistencia, g) MBE WRF, h) MBE persistencia*

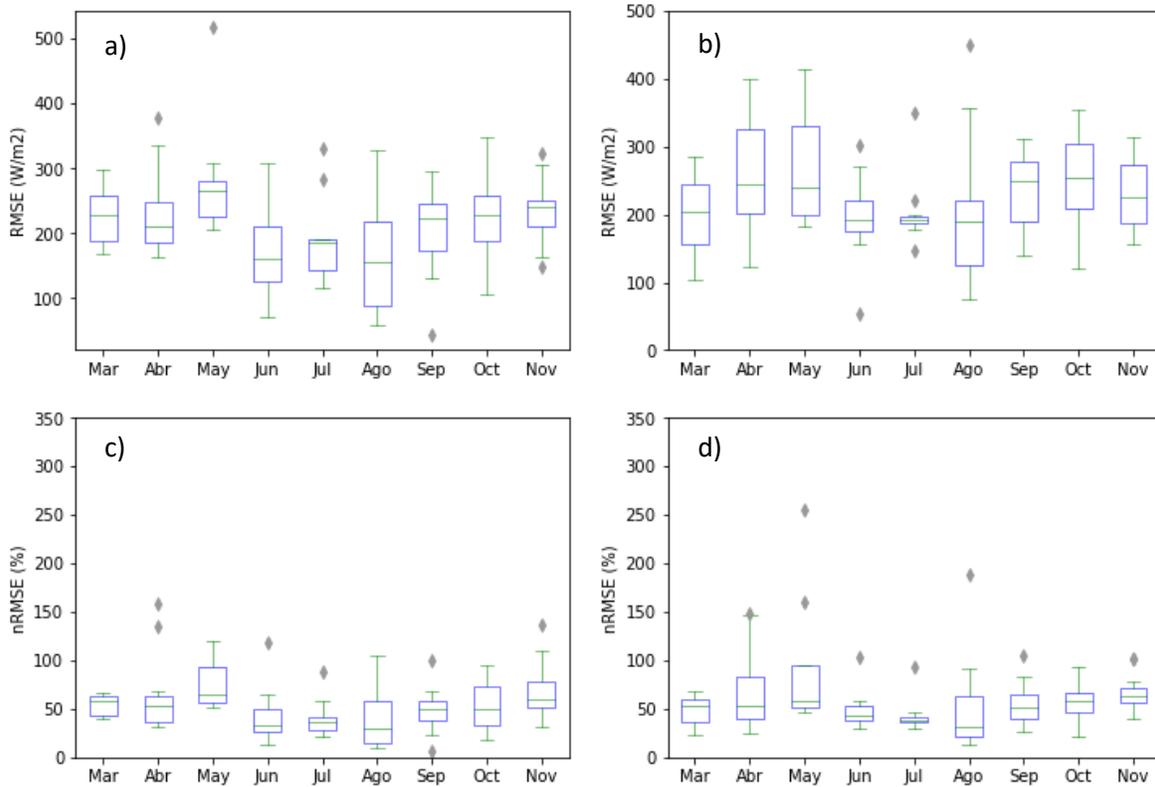


Figura 12. Diagrama de cajas y bigotes de los errores para a.) RMSE WRF, b.) RMSE Persistencia, c.) nRMSE WRF, d.) nRMSE Persistencia

En la **Figura 13** se observan los diagramas de cajas y bigotes para los errores MBE y nMBE, obtenidos de la comparación estadística entre los modelos (WRF y persistencia) y las mediciones in situ del SIATA. Valores positivos del MBE y nMBE indican sobreestimación de las observaciones medias, mientras que valores negativos representan subestimación de las mismas. Teniendo en cuenta lo anterior, en gran parte del periodo de estudio el modelo WRF sobreestimó la radiación solar, pero aún así en algunos días de abril, septiembre y octubre el modelo la subestimó. De la **Figura 13-a** se destacan marzo, mayo y noviembre por ser los meses donde WRF obtuvo las medianas más altas de MBE, con valores de $129,30 \text{ W/m}^2$, $120,80 \text{ W/m}^2$ y $133,04 \text{ W/m}^2$ respectivamente. Por el contrario, octubre exhibe la mediana más pequeña ($35,244 \text{ W/m}^2$), pero tiene una gran variabilidad. La **Figura 13-c** muestra que la gran mayoría de errores obtenidos de WRF se encuentra por debajo del 50% y las medianas en general, no superan el 20%, exceptuando algunos meses como marzo, mayo y noviembre, que presentaron las medianas más altas, 33,56%, 33,95% y 36,28%, respectivamente. Por su parte, octubre, junio y julio presentaron las menores medianas con valores de 7,61%, 13,40% y 19,45%, respectivamente. Aun así, no se ve una inclinación a mayores sobreestimaciones en meses de temporada lluviosa, puesto que según el tamaño de los box-plots, meses de temporada seca como agosto

y junio presentan valores de MBE más grandes que mayo, septiembre y octubre, que son meses pertenecientes a la temporada lluviosa. En general, WRF exhibe errores positivos más grandes que la persistencia, pero errores negativos más pequeños, alcanzando como máximo $-133,84 \text{ W/m}^2$, mientras la persistencia llega a tener errores cercanos a los -300 W/m^2 , es decir, que el modelo de persistencia no exhibe inclinación a sobreestimar la irradiancia solar como lo hace WRF.

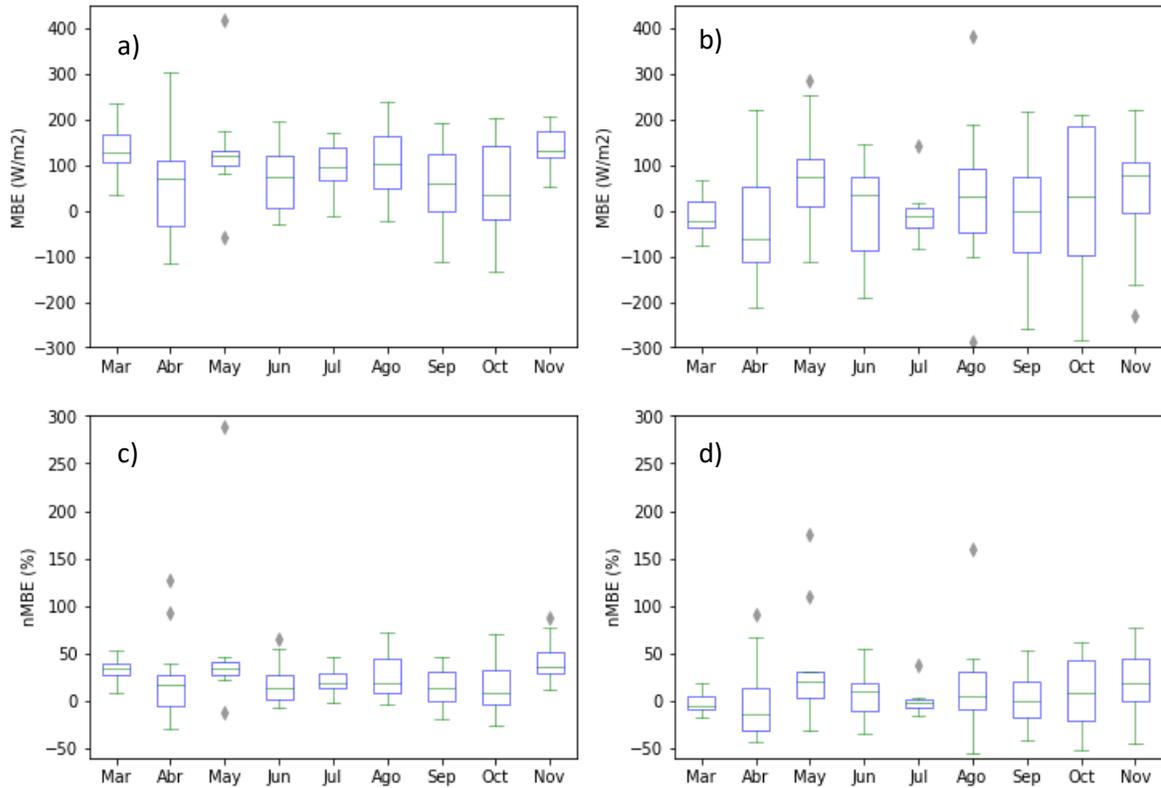


Figura 13. Diagrama de cajas y bigotes de los errores para a.) MBE WRF, b.) MBE Persistencia, c.) nMBE WRF, d.) nMBE Persistencia

4.2.3 Ciclos diurnos de los días con mayor y menor error

La **Figura 14-a** muestra el ciclo diurno del 8 de mayo de 2019, el día donde el modelo WRF tuvo el peor rendimiento, con valores de RMSE, nRMSE, MBE, y nMBE de $519,17 \text{ W/m}^2$, $358,81\%$, $416,85 \text{ W/m}^2$, y 289% , respectivamente. En el mes de mayo de 2019, persistieron dos sistemas de baja presión que apoyaron el desarrollo de precipitaciones en varios departamentos del país incluyendo Antioquia. Además, en el área marítima del occidente del país se evidenció divergencia de vientos lo cual apoyó la ocurrencia de lluvias en la zona occidental y central del país. Asimismo, el IDEAM reportó que en el mes de mayo el Valle de Aburrá obtuvo un índice de precipitación mensual por encima de lo normal (IDEAM, 2019). Lo anterior, podría explicar el bajo rendimiento del modelo para este día, ya que al aumentar las precipitaciones aumenta la nubosidad y el modelo se ha caracterizado por un modelado deficiente de nubes (Mathiesen et al., 2013 , Ruiz-Arias et al., 2016).

La **Figura 14-b** muestra el ciclo diurno del 3 de septiembre de 2019, uno de los días donde el modelo obtuvo su mejor rendimiento, con valores de RMSE, nRMSE, MBE, y nMBE de $43,78 \text{ W/m}^2$, $7,05\%$, $28,69 \text{ W/m}^2$ y $4,62\%$, respectivamente. Diferente a mayo, en septiembre de 2019 se reportaron lluvias por debajo de lo normal en la región Andina (IDEAM, 2019), lo que podría explicar el buen rendimiento del modelo para el 3 de septiembre, ya que en ausencia de nubes el modelo suele tener mejores resultados.

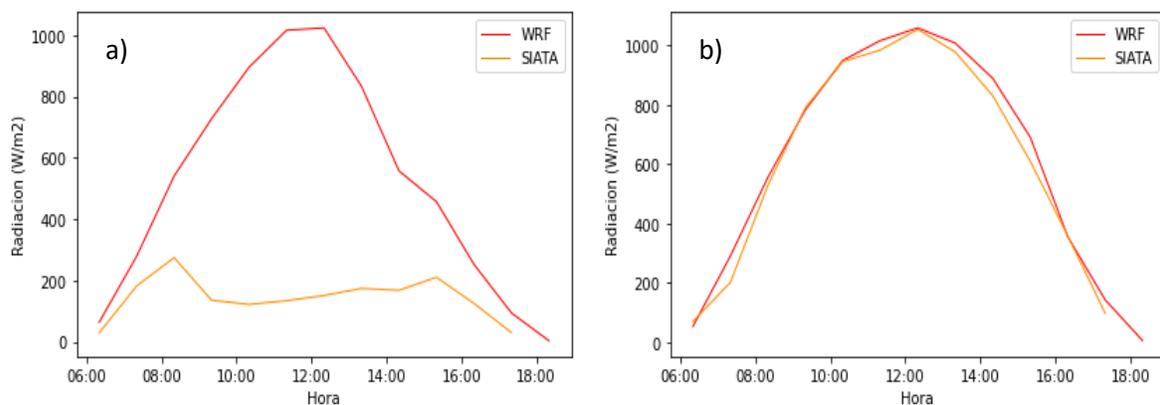


Figura 14. Ciclos diurnos de irradiancia solar. En rojo se muestra el ciclo diurno obtenido por las simulaciones de WRF y en naranja el obtenido por las mediciones in situ, para **a.)** 8 de mayo de 2019, **b.)** 3 de septiembre de 2019

4.2.4 Datos diarios de irradiación solar

En las **Figuras 15, 16 y 17** se encuentran las correlaciones y las distribuciones elaboradas a partir de los promedios diarios de radiación de los registros de Torre SIATA y los modelos. En la **Figura 15-a** se aprecia que WRF presentó correlaciones diarias positivas que van desde 0,02 hasta 0,83. Los meses que exhiben menores correlaciones y mayor dispersión son abril y mayo, mientras que el mes con mayor valor de correlación y menos dispersión fue agosto, el cual hace parte de una de las temporadas secas de la región y fue uno de los meses con menores porcentajes de RMSE. Esto podría ratificar que el modelo WRF presenta mejor rendimiento en condiciones de cielo despejado, ya que en la región de estudio las lluvias en agosto de 2019 se caracterizaron por estar muy por debajo de los valores típicos del mes (IDEAM, 2019). Por otra parte, la **Figura 15-b** muestra que en su totalidad las correlaciones diarias del modelo de persistencia obtuvieron magnitudes más pequeñas que las de WRF; inclusive, 5 meses presentaron correlaciones negativas, lo que indicaría una relación inversa entre la radiación medida in situ y la pronosticada por la persistencia. Sin embargo, no es posible afirmar esta relación, ya que las magnitudes son muy pequeñas, ninguna supera un valor de 0,3, por lo tanto, no pueden ser consideradas sustanciales. Lo anterior se corrobora con los diagramas de dispersión de la **Figura 17**. Todos los meses presentan alta dispersión y no se logra ver claramente alguna relación entre las variables.

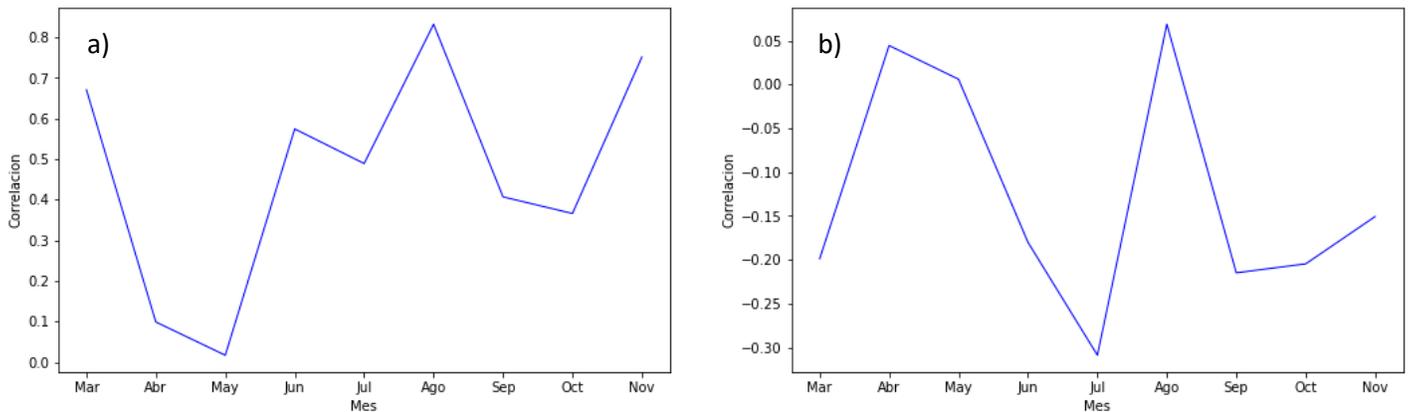


Figura 15. Correlaciones entre valores diarios de irradiación solar entre **a.)** los registros de Torre SIATA y las simulaciones de WRF, **b.)** los registros de Torre SIATA y la persistencia

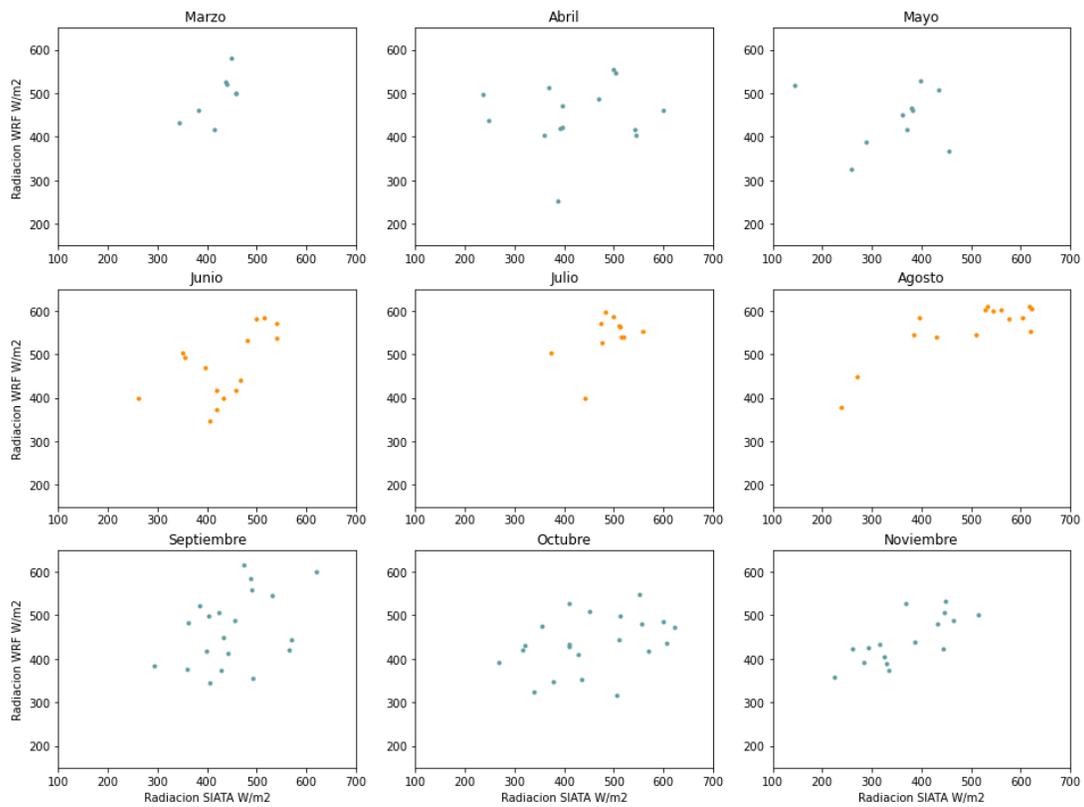


Figura 16. Diagramas de dispersión de los promedios diarios de irradiancia solar para los registros de Torre SIATA y las simulaciones de WRF

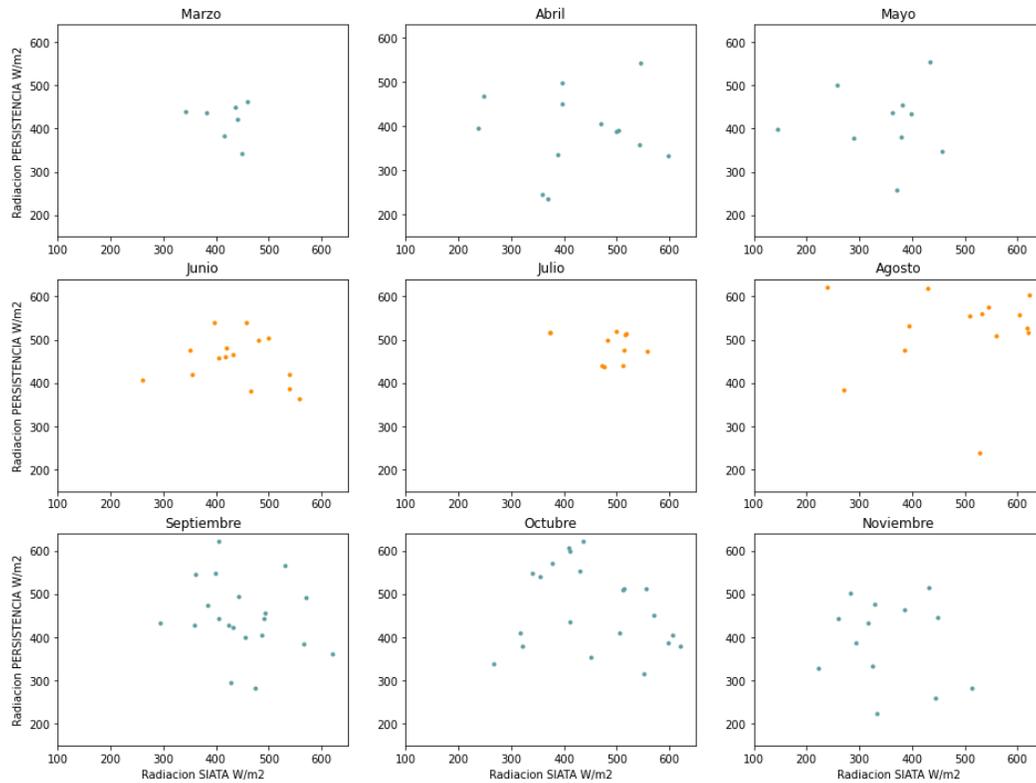


Figura 17. Diagrama de dispersión de los promedios diarios de irradiancia solar para los registros de Torre SIATA y el modelo de persistencia

4.3 Simulaciones WRF con horizonte de 48 horas

En esta sección se presentan los resultados de la comparación estadística entre los registros in situ y el modelo WRF con un horizonte de 48 horas, para el periodo de tiempo comprendido entre marzo de 2020 hasta enero de 2021. Para esto, fue necesario partir las horas de pronóstico en dos. Primero, se tomaron las horas del sol del primer día, las cuales llamaremos D1, y se estudiaron aparte de las horas de sol del segundo día, que llamaremos D2. Por otra parte, se presentan también los resultados del estudio de dos modelos de persistencia: una persistencia D1, la cual será comparable con el D1 de simulaciones de WRF, y una persistencia D2, comparable con el D2 de simulaciones de WRF.

4.3.1 Valores horarios de irradiancia solar

Las distribuciones de los valores horarios, tanto para el modelo WRF (D1 y D2) como para los registros Torre SIATA, se presentan en la **Figura 18**. Los datos tanto para los D1 y D2 de las simulaciones de WRF como para los registros de Torre SIATA exhiben valores de la irradiación horaria desde 0 W/m^2 hasta valores por encima de los 1000 W/m^2 . Las mayores frecuencias para el piranómetro Torre SIATA se presentaron entre los 0 y 100 W/m^2 ; para el resto de valores de irradiancia solar, las frecuencias fueron casi uniformes. Por su parte, las simulaciones de WRF para el D1 mostraron mayores frecuencias para valores más grandes de irradiancia solar, aproximadamente entre 700 y 900 W/m^2 , dependiendo del mes; es decir, que WRF (D1) comparado con los registros in situ, presentó mayores frecuencias para los valores más altos de radiación solar, al igual que lo hacían las simulaciones con horizonte de 24 horas presentadas en la sección 4.2.1. Contrario a los registros in situ y las simulaciones del D1, WRF para el D2 no presentó un patrón marcado de frecuencias altas para el periodo de estudio, es decir, las frecuencias más altas varían de mes a mes, pero, gran cantidad de meses presentaron altas frecuencias para valores de irradiancia entre los 0 W/m^2 y 100 W/m^2 . Lo anterior, da a entender que el D2 de simulaciones no presenta esa tendencia de sobreestimar la irradiancia solar de forma tan marcada como la muestra el D1 y las simulaciones de 24 horas presentadas en la sección 4.2.1.

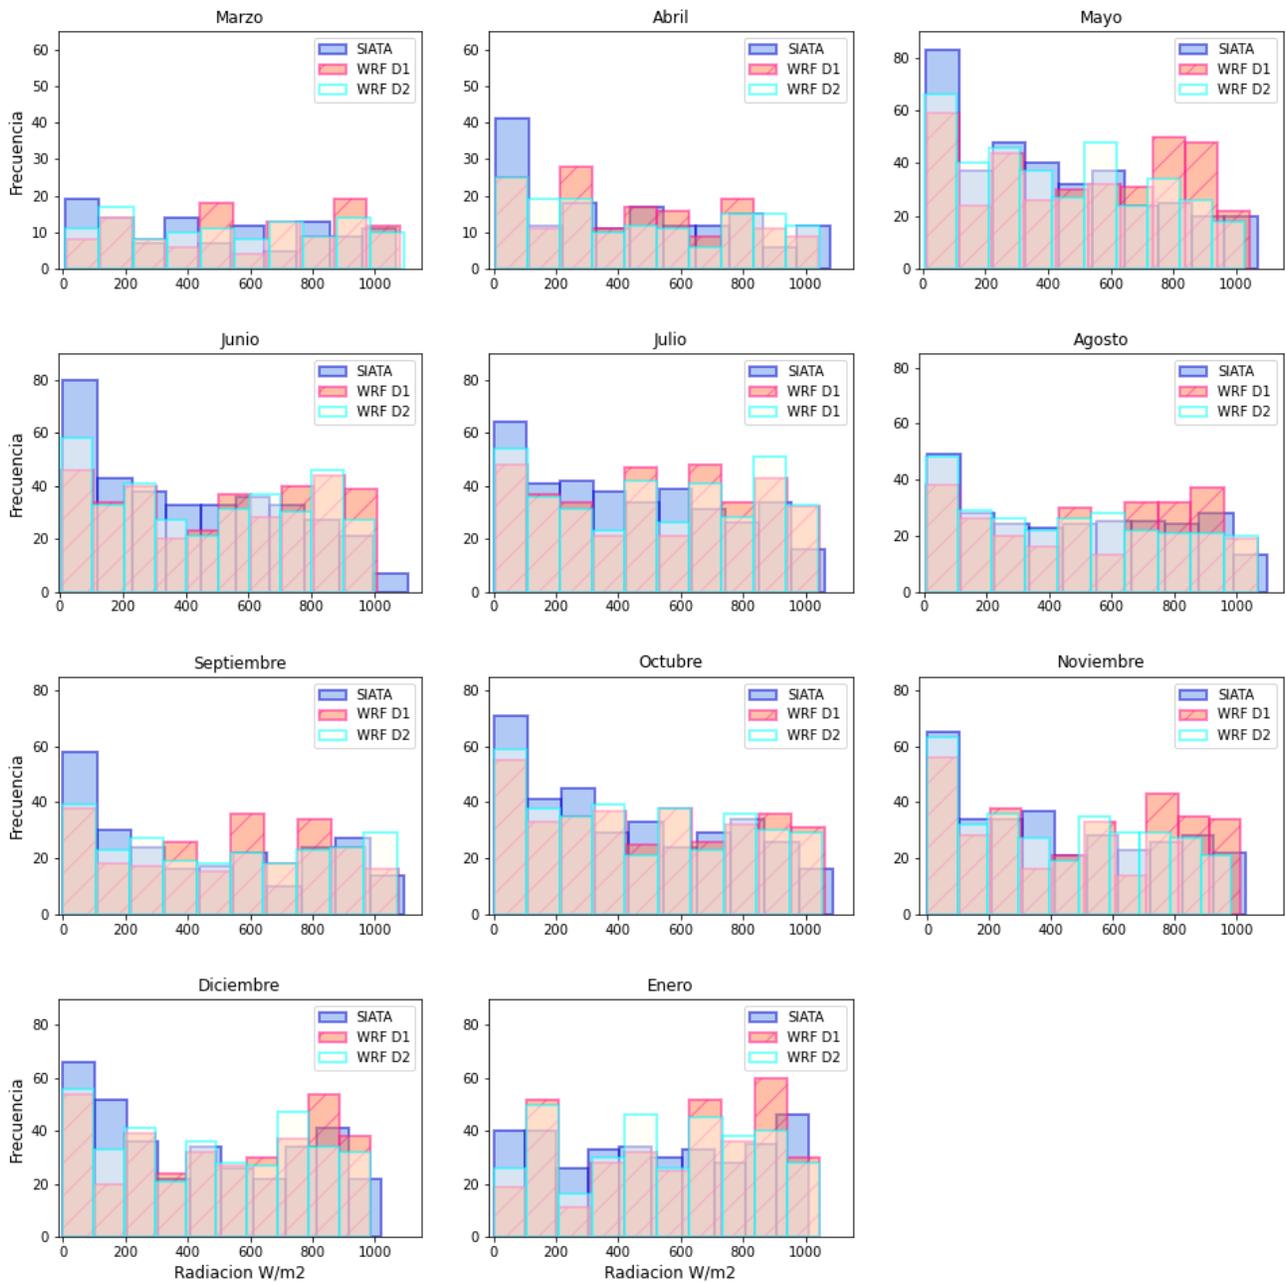


Figura 18. Histogramas de los valores horarios tanto para el D1 y el D2 de WRF, como para los registros de Torre SIATA

La **Figura 19** muestra los diagramas de dispersión y la correlación entre los valores horarios de las simulaciones WRF D1 y los valores horarios de las mediciones in situ del piranómetro Torre SIATA. En general, todos los meses presentaron correlaciones sustanciales, positivas, mayores a 0,74. Además los scatter-plots mostraron poca dispersión, lo que indica una relación directa entre las simulaciones y las mediciones

in situ. Es importante tener en cuenta que estos valores altos de correlación están mediados por el ciclo diurno, como se mencionó anteriormente en la sección 4.2.1. Los meses con correlaciones más altas fueron enero, junio, julio, agosto, octubre y diciembre, todos estos meses hacen parte de las temporadas secas de la región de estudio, exceptuando el mes de octubre.

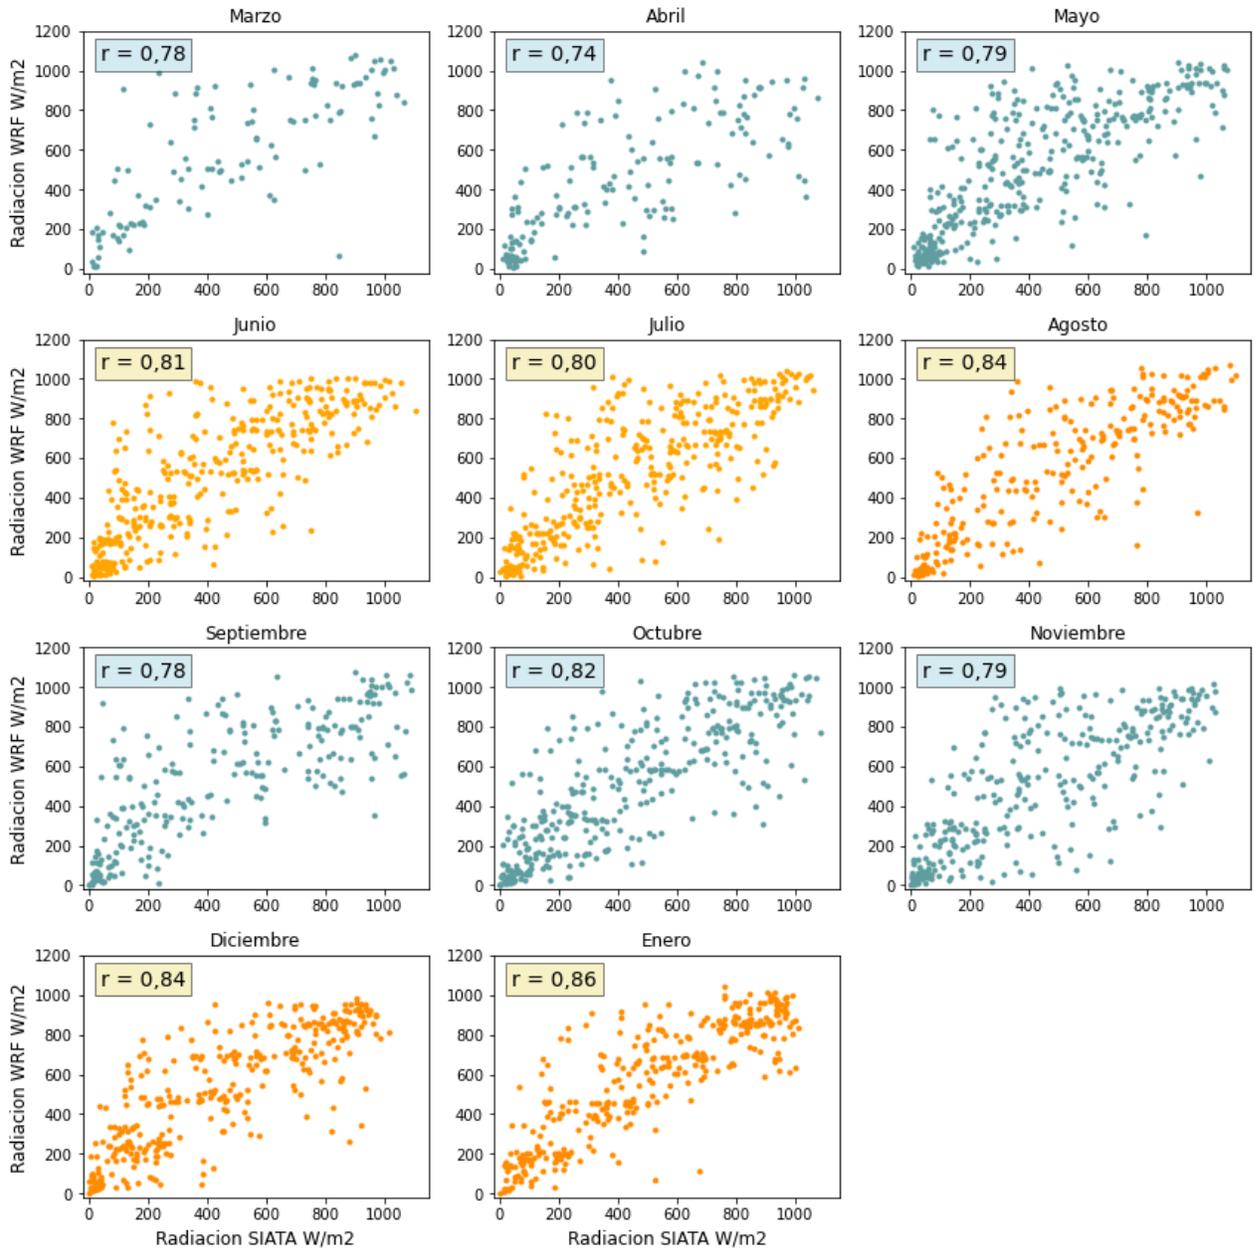


Figura 19. Diagramas de dispersión y correlaciones para el D1 de las simulaciones WRF

En la **Tabla 2** se presentan las correlaciones de los valores horarios de irradiancia solar entre los modelos (D1, D2, persistencia del D1 y persistencia del D2) y las mediciones in situ. Los diagramas de dispersión para las persistencias y el D2, se encuentran en los anexos. Todas las correlaciones consignadas en la **Tabla 2** fueron significativas con un nivel de confianza de 0.05. En general, las correlaciones para el D1 fueron mayores que las correlaciones para el D2, salvo para los meses de septiembre y diciembre, y fueron mayores que las correlaciones de ambas persistencias en todos los meses. El D2 también presentó correlaciones más altas que su respectiva persistencia. Por otra parte, al igual que para el D1, el D2 mostró correlaciones más altas en los meses pertenecientes a las temporadas secas de la región, exceptuando de nuevo octubre. La persistencia del D1 presentó correlaciones más altas (por encima de 0,70) para abril, julio, agosto, noviembre, diciembre y enero. La persistencia del D2 presentó correlaciones con los valores más altos, los meses de mayo, julio, agosto, noviembre, diciembre y enero; lo que indica, que al igual que las simulaciones de WRF, la persistencia para ambos días presentó las mayores correlaciones en los meses de temporada seca, salvo para abril, (persistencia del D1) mayo (persistencia D2) y noviembre (ambas persistencias), que son meses pertenecientes a la temporada lluviosa de la región de estudio.

Tabla 2 Correlaciones de los valores horarios de irradiancia solar para los modelos

Mes	Correlación			
	D1	D2	Persistencia D1	Persistencia D2
Marzo	0,78	0,74	0,63	0,61
Abril	0,74	0,68	0,71	0,68
Mayo	0,79	0,76	0,60	0,70
Junio	0,81	0,78	0,63	0,60
Julio	0,80	0,80	0,75	0,72
Agosto	0,84	0,80	0,76	0,77
Septiembre	0,78	0,79	0,64	0,67
Octubre	0,82	0,80	0,66	0,67
Noviembre	0,79	0,78	0,74	0,70
Diciembre	0,84	0,85	0,79	0,80
Enero	0,86	0,85	0,78	0,74

En las **Figuras 20 y 21** se muestran los diagramas de dispersión de las anomalías con respecto al ciclo diurno entre las simulaciones de WRF (D1, D2) y las mediciones del piranómetro Torre SIATA. En general, las correlaciones para ambos horizontes de pronóstico exhiben valores positivos, menores a 0,4, exceptuando junio para el D1, que obtuvo una correlación de 0,42, y octubre para el D1 y el D2, que obtuvo una correlación de 0,44 y 0,41, respectivamente. Es decir que el modelo no representa muy bien las fluctuaciones atípicas de irradiancia horaria, ya que, al remover el ciclo diurno, las correlaciones entre el modelo y las mediciones in situ descienden considerablemente.

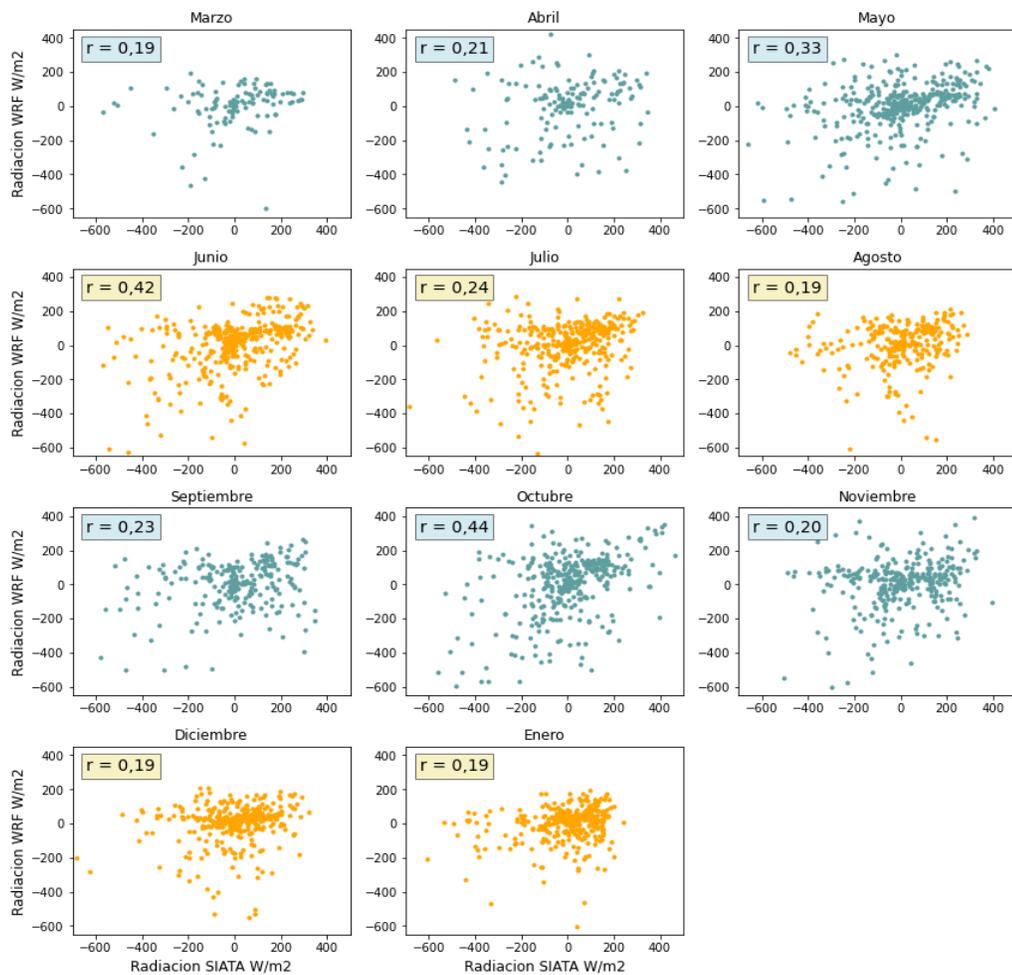


Figura 20. Anomalías con respecto al ciclo diurno para el D1 de simulaciones de WRF

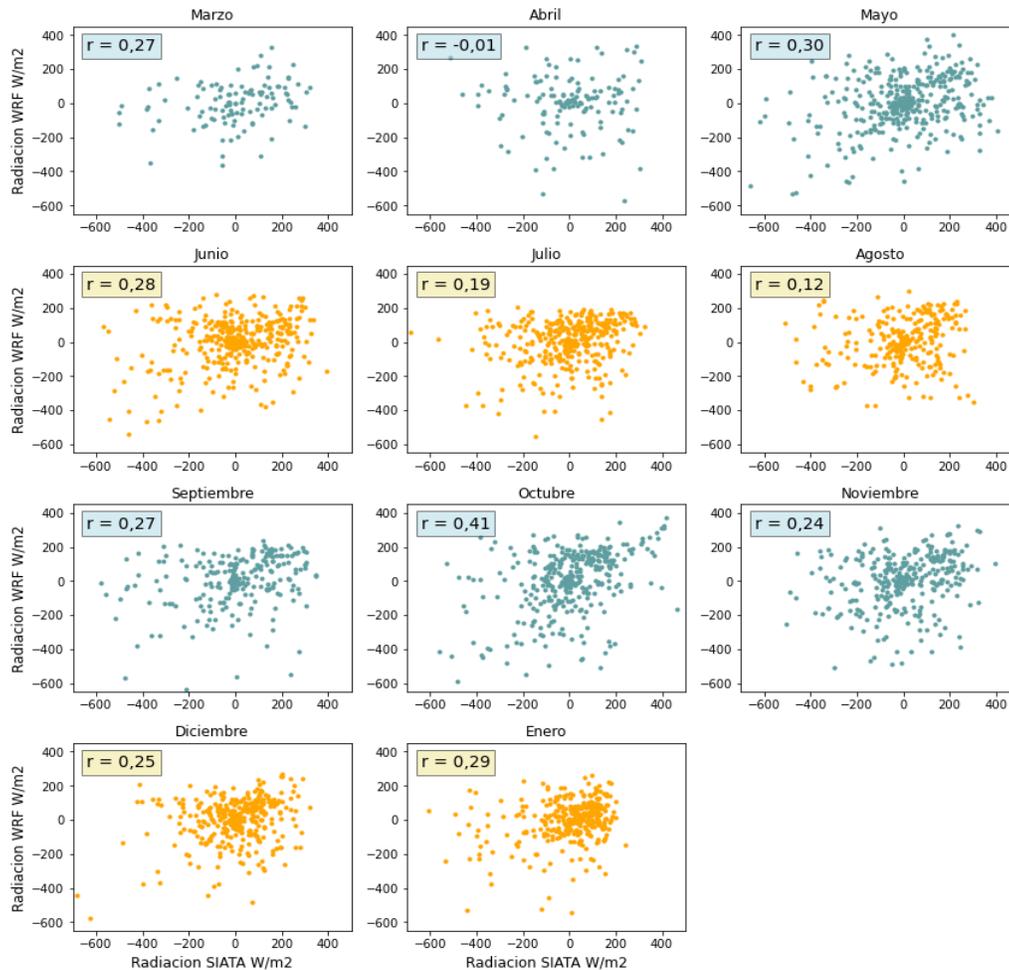


Figura 21. Anomalías respecto al ciclo diurno para el D2 de simulaciones de WRF

Las **Figuras 22 y 23** muestran los diagramas de dispersión de las anomalías respecto al ciclo diurno entre los modelos de persistencia (D1 y D2) y las mediciones del piranómetro Torre SIATA. Las correlaciones entre el modelo de persistencia D1 y las mediciones in situ fueron valores muy cercanos a cero y en su totalidad menores a las correlaciones de las anomalías entre simulaciones WRF del D1 y los registros del SIATA (**Figura 20**). Lo mismo sucedió con las correlaciones de las anomalías entre el modelo de persistencia D2 y las mediciones in situ: fueron correlaciones muy bajas, menores a las presentadas entre el D2 de WRF y los registros in situ (**Figura 21**). Es decir, que, aunque WRF no representó de modo óptimo las anomalías de irradiación horaria respecto al ciclo diurno, la persistencia representó aún más deficientemente las anomalías, al igual que se mostró para las simulaciones de 24 horas en la sección 4.2.1.

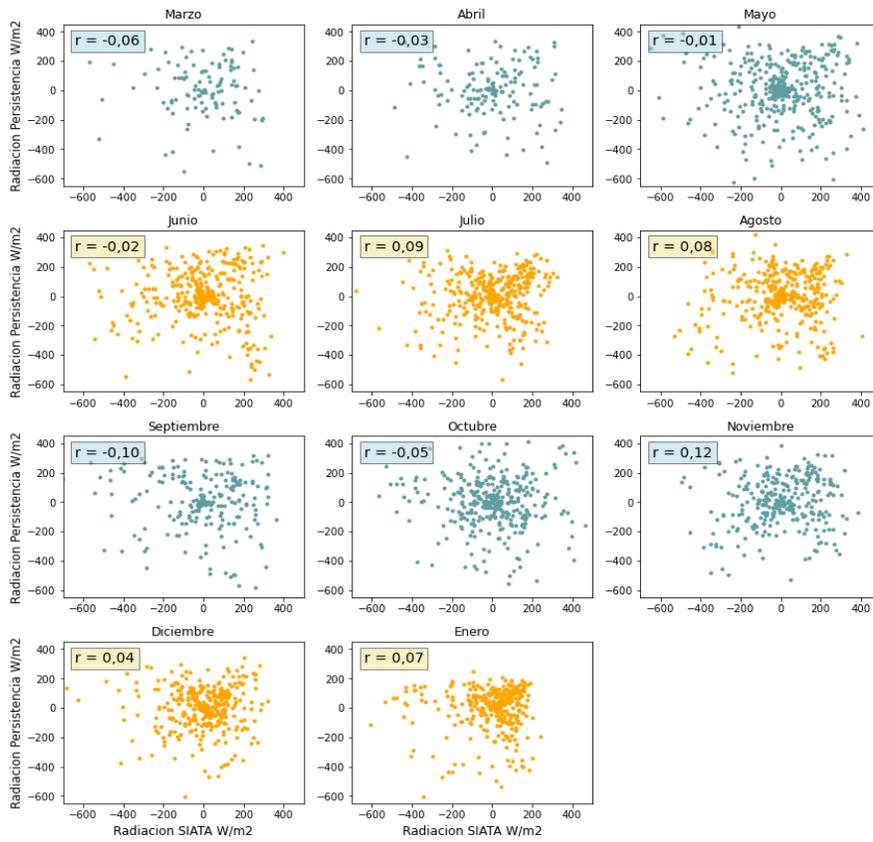


Figura 22. Anomalías con respecto al ciclo diurno para la persistencia del D1

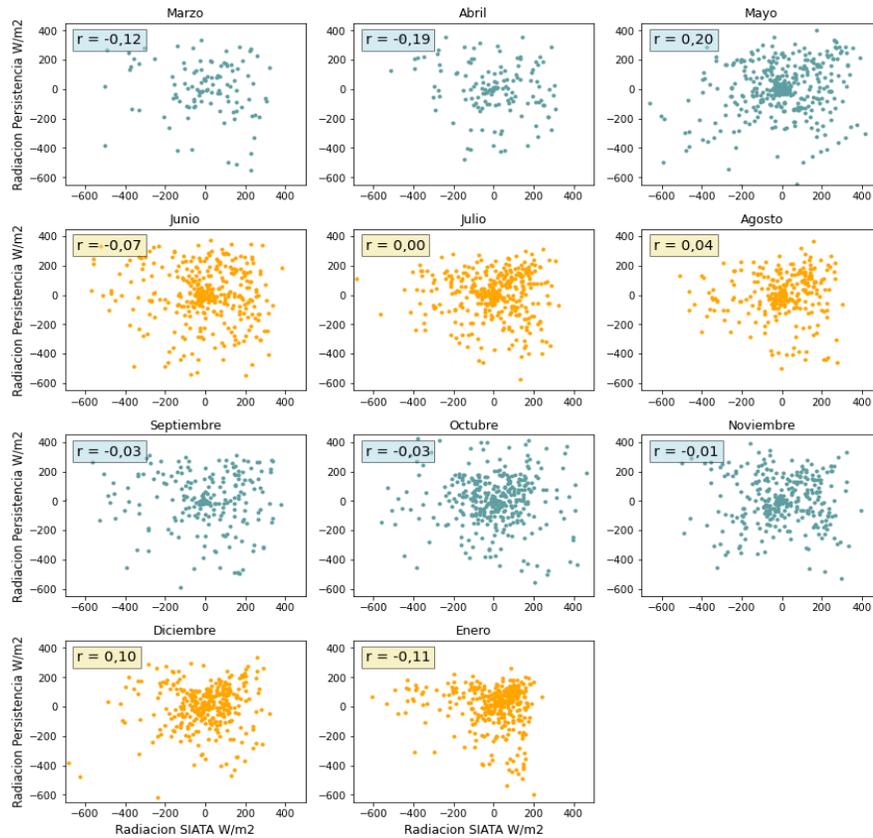


Figura 23. Anomalías con respecto al ciclo diurno para la persistencia D2

4.3.2 Errores

En la **Figura 24** se presentan los box-plots de los errores RMSE para el D1, el D2, la persistencia D1 y la persistencia D2. Desde una perspectiva meteorológica, la calidad de los pronósticos desciende al aumentar el horizonte (Diagne et al., 2014). Sin embargo, comparando los errores del D1 con los del D2, no se nota una tendencia clara del RMSE a aumentar con el horizonte de pronóstico. Algunos meses del WRF-D1, como marzo y abril, obtuvieron menores errores que para el WRF-D2; pero en algunos meses como diciembre el D2 presentó errores más bajos que el D1. El D1 mostró el valor máximo de RMSE en mayo ($420,09 \text{ W/m}^2$), el D2 lo presentó en marzo, ($394,97 \text{ W/m}^2$), la persistencia del D1 en junio ($511,72 \text{ W/m}^2$) y la persistencia del D2 en septiembre ($437,40 \text{ W/m}^2$). El D1 presentó un valor mínimo de $37,83 \text{ W/m}^2$ en diciembre, el D2 de $39,01 \text{ W/m}^2$ en agosto, la persistencia D1 de $30,17 \text{ W/m}^2$ en enero y la persistencia D2 de $45,01 \text{ W/m}^2$ en enero. Lo anterior indica, que para todos los modelos los máximos de RMSE se alcanzaron en meses de temporada lluviosa, exceptuando para la persistencia D1; y los mínimos de RMSE se alcanzaron en meses de temporada seca. En general, se observó inclinación de los modelos a presentar errores más bajos en los meses de temporada seca; para los D1 y de D2 de las simulaciones de WRF, esto podría estar relacionado con la nubosidad, como se ha venido mencionando, ya que, el rendimiento del modelo disminuye en los meses donde suele aumentar la nubosidad por las lluvias.

El sector eléctrico del país depende principalmente de la hidroelectricidad, lo que lo hace vulnerable en las temporadas secas, puesto que la escasez de agua puede traer problemas para operar el sistema. Los recursos solares han demostrado complementar el sector hidroeléctrico en estaciones secas del ciclo climatológico anual y también en eventos ENSO, ya que cuando las entradas de agua al sistema eléctrico disminuyen, los recursos solares aumentan (Henaó, 2020). Asimismo, las simulaciones de WRF, podrían contribuir a complementar el sistema, ya que han demostrado tener mejor rendimiento en las temporadas secas, donde es precisamente que las hidroeléctricas puede llegar a presentar disminución en la producción de energía.

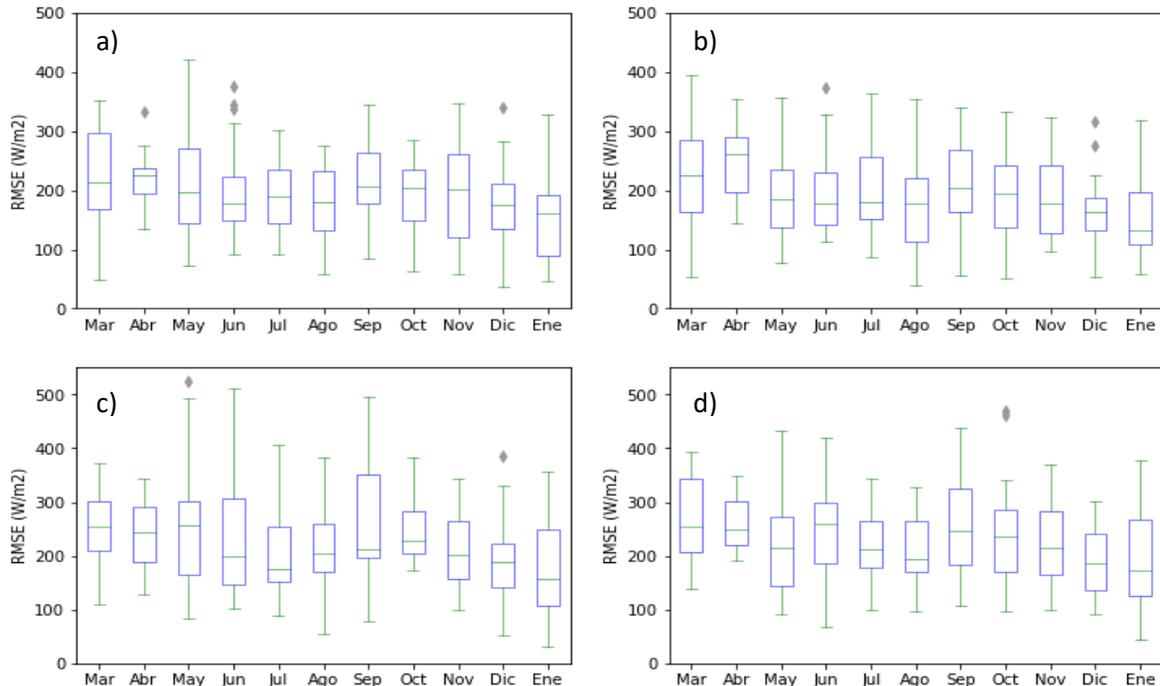


Figura 24. Diagrama de cajas y bigotes de los errores para a.) RMSE WRF D1, b.) RMSE WRF D2, c.) RMSE Persistencia D1, d.) RMSE Persistencia D2

Por otra parte, la persistencia D1 alcanzó en su mayoría, valores más altos de RMSE que el D1 de simulaciones de WRF, exceptuando el mes de enero donde el tamaño de los box-plots fue muy similar para ambos modelos. Por su parte, la persistencia D2 presentó 7 meses con errores RMSE más altos que WRF-D2 y en los otros 4 meses restantes los errores presentaron un comportamiento similar para ambos modelos.

En la **Figura 25** se muestran los box-plots de los errores RMSE estandarizados para el D1, el D2, la persistencia D1 y la persistencia D2. En general, tanto WRF como la persistencia presentaron errores por debajo del 100%, solo unos pocos meses sobrepasan este valor, esto sin tener en cuenta los datos atípicos. Comparado con el RMSE, el nRMSE muestra que la persistencia D1 mejora su rendimiento, ya que de los 11 meses analizados el D1 solo obtuvo 3 meses con mejor rendimiento que la persistencia y de los otros 8 meses restantes, 7 meses presentaron rendimiento similar y en un mes la persistencia presentó errores más bajos. Por su parte, la persistencia D2 presentó 3 meses con errores más bajos y 5 meses con errores más altos que el D2 de simulaciones de WRF, en los 3 meses restantes, los errores presentaron magnitudes similares para ambos modelos. Por otra parte, los box-plots muestran que, el D1 presentó un nRMSE máximo en mayo de 132.37 % y un mínimo de 6.5% en diciembre, el D2 presentó un máximo en marzo de 119.50% y un mínimo en agosto de 6.35%, la persistencia D1 mostró un máximo en mayo de 157.29% y un mínimo de 4.91% en enero, la persistencia D2 tuvo un máximo de 113.98% en junio y un mínimo de 7.73% en enero.

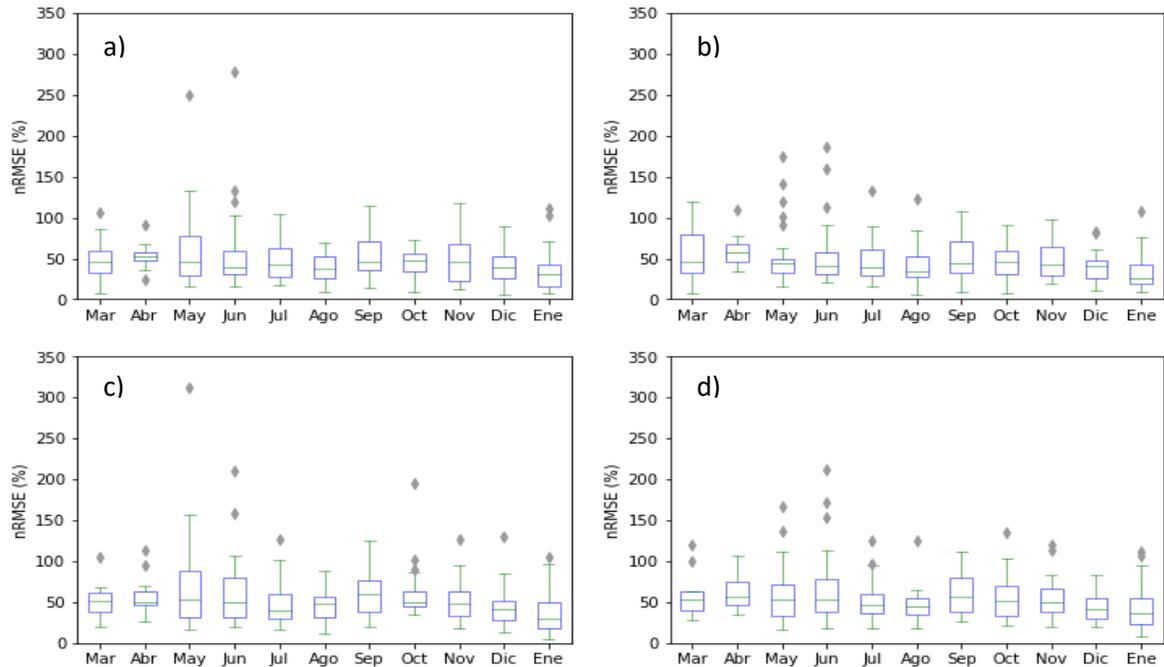


Figura 25. Diagrama de cajas y bigotes de los errores para a.) nRMSE WRF D1, b.) nRMSE WRF D2, c.) nRMSE Persistencia D1, d.) nRMSE Persistencia D2

En la **Figura 26** se presentan los box-plots de los errores MBE para el D1, el D2, la persistencia D1 y la persistencia D2. El D1 presentó errores de MBE entre -173.43 W/m^2 y 363.17 W/m^2 , el D2 entre -225.17 W/m^2 y 294.24 W/m^2 , la persistencia del D1 entre -419.76 W/m^2 y 245.85 W/m^2 , y la persistencia del D2 entre -285.91 W/m^2 y 304.36 W/m^2 .

En todos los meses de las simulaciones del D1 de WRF, aproximadamente el 75 % de los errores MBE están por encima de 0%, es decir, el D1 mostró una gran inclinación a sobreestimar la irradiancia solar. El D2, también presentó algunos meses donde aproximadamente el 75% de los errores están por encima de cero, como es el caso de junio, julio, septiembre, octubre, diciembre y enero; sin embargo, también presentó meses donde alrededor del 50% de los errores están por debajo de cero, como lo son, abril, mayo, agosto y noviembre. Lo anterior confirma, que el D1 tiene una inclinación más marcada a sobreestimar la irradiancia solar, que el D2, como se mostró en la sección 4.3.1. Por su parte, la persistencia para ambos días, no mostraron propensión a la sobreestimación o a la subestimación, ya que, en general, los meses muestran que alrededor del 50% de los errores de MBE son negativos, y por lo tanto el otro 50% restante toma valores positivos; sin embargo, el tamaño de los box-plots muestra que la persistencia puede tomar valores de MBE muy grandes o pequeños.

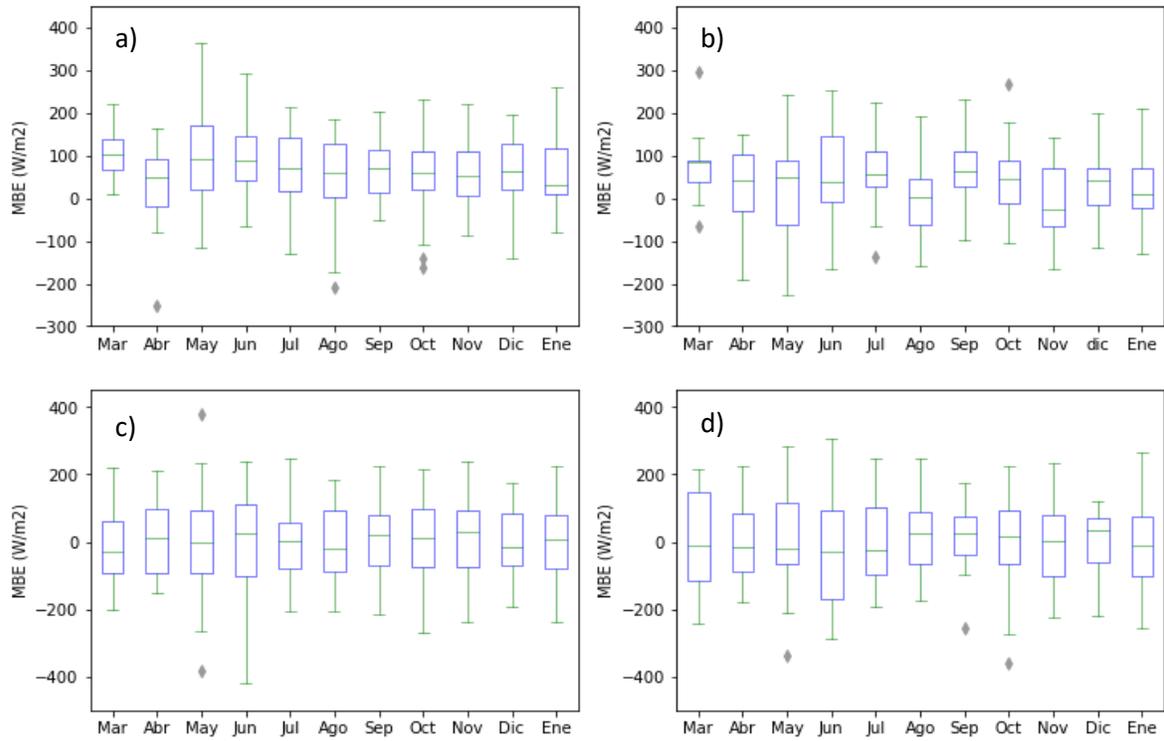


Figura 26. Diagrama de cajas y bigotes de los errores para a.) MBE WRF D1, b.) MBE WRF D2, c.) MBE Persistencia D1, d.) MBE Persistencia D2

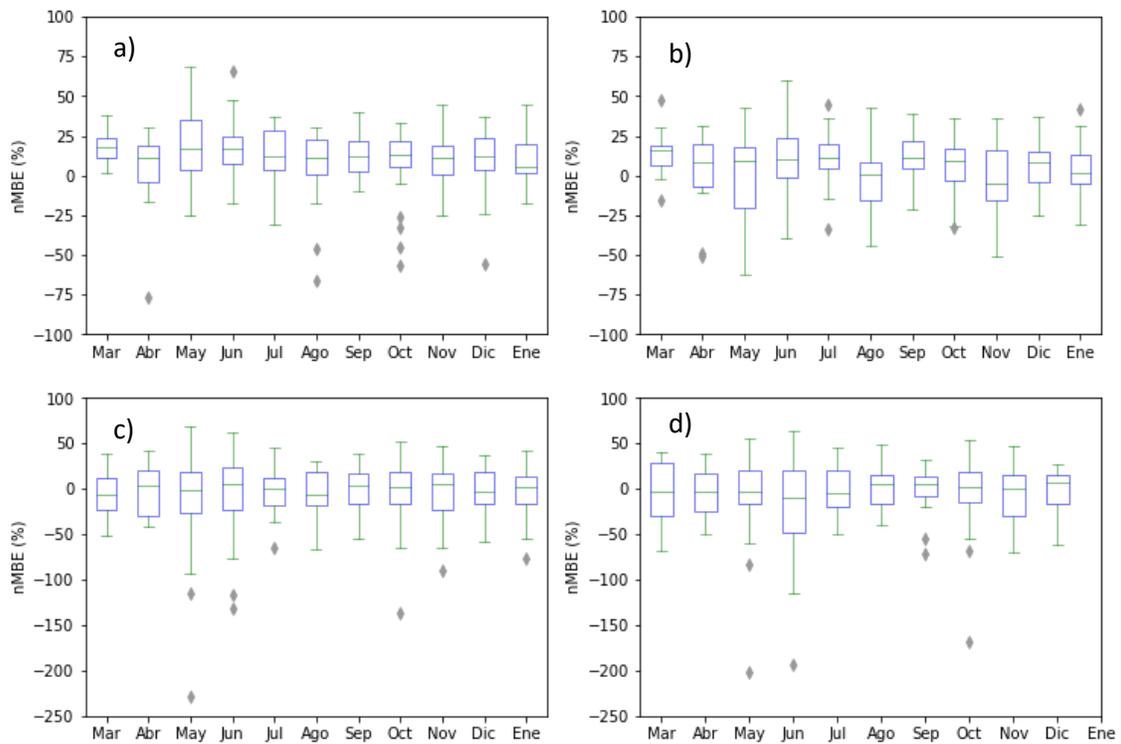


Figura 27. Diagrama de cajas y bigotes de los errores para a.) nMBE WRF D1, b.) nMBE WRF D2, c.) nMBE Persistencia D1, d.) nMBE Persistencia D2

Los box-plots de los errores MBE estandarizados para el D1, el D2, la persistencia D1 y la persistencia D2 se muestran en la **Figura 27**. Los errores del D1 se encuentran aproximadamente entre -30% y 70%, pero la mayoría de los meses mostraron nMBEs menores al 40%; además, alrededor del 75% de los errores de cada mes, exhiben sobreestimación, ya que están por encima de cero. Por otra parte, la persistencia D1 presentó errores entre aproximadamente -100% y 70% y en general, tuvo errores más grandes que el D1 de simulaciones de WRF. Por su parte, el D2 exhibe errores entre -70% y 70%; y al igual que el D1, la mayoría de errores no superaron el 40%. El D2 alcanzó errores negativos más altos que el D1, y es posible encontrar meses donde aproximadamente el 50% de los errores fueron negativos (mayo, agosto y noviembre). Por su parte, la persistencia D2 presentó errores alrededor del -100% y el 65%, y en general, los errores fueron ligeramente menores o muy similares al D2 de simulaciones de WRF.

En la **Figura 28** se muestran las medianas de los errores RMSE, nRMSE, MBE, nMBE, para el D1, el D2, la persistencia D1 y la persistencia D2. En las **Figuras 28-a y 28-b**, se aprecia que en general, las persistencias presentaron medianas de RMSE y nRMSE más altas que las simulaciones de WRF. Por otra parte, las medianas del RMSE y del nRMSE de WRF y de los modelos de persistencia siguen un comportamiento bimodal, donde las medianas más grandes las presentaron los meses de temporada lluviosa de la región de estudio y en la temporada seca se aprecian las más pequeñas. Para el D1 y el D2, los meses de temporada seca mostraron medianas de nRMSE entre aproximadamente el 25% y el 40%, es decir, que el 50% de los errores estuvieron por debajo de estos valores, mientras que, para los meses de temporada lluviosa las medianas de los errores estuvieron alrededor del 40% y 55%. El D2 presentó las menores medianas de RMSE y nRMSE para casi todos los meses, exceptuando la de marzo y la de abril para el RMSE y la de marzo, abril, junio y diciembre para el nRMSE, donde las menores medianas las obtuvo el D1.

En la **Figura 28-c y 28-d**, se aprecia que para todos los meses el D1 y el D2 presentaron medianas positivas de MBE y nMBE, exceptuando el mes de noviembre para el D2, donde las medianas presentaron valores de aproximadamente -20 W/m² (RMSE) y -5% (nRMSE), mientras la persistencia D1 presentó medianas negativas en 6 meses y la persistencia D2 en 3 meses.

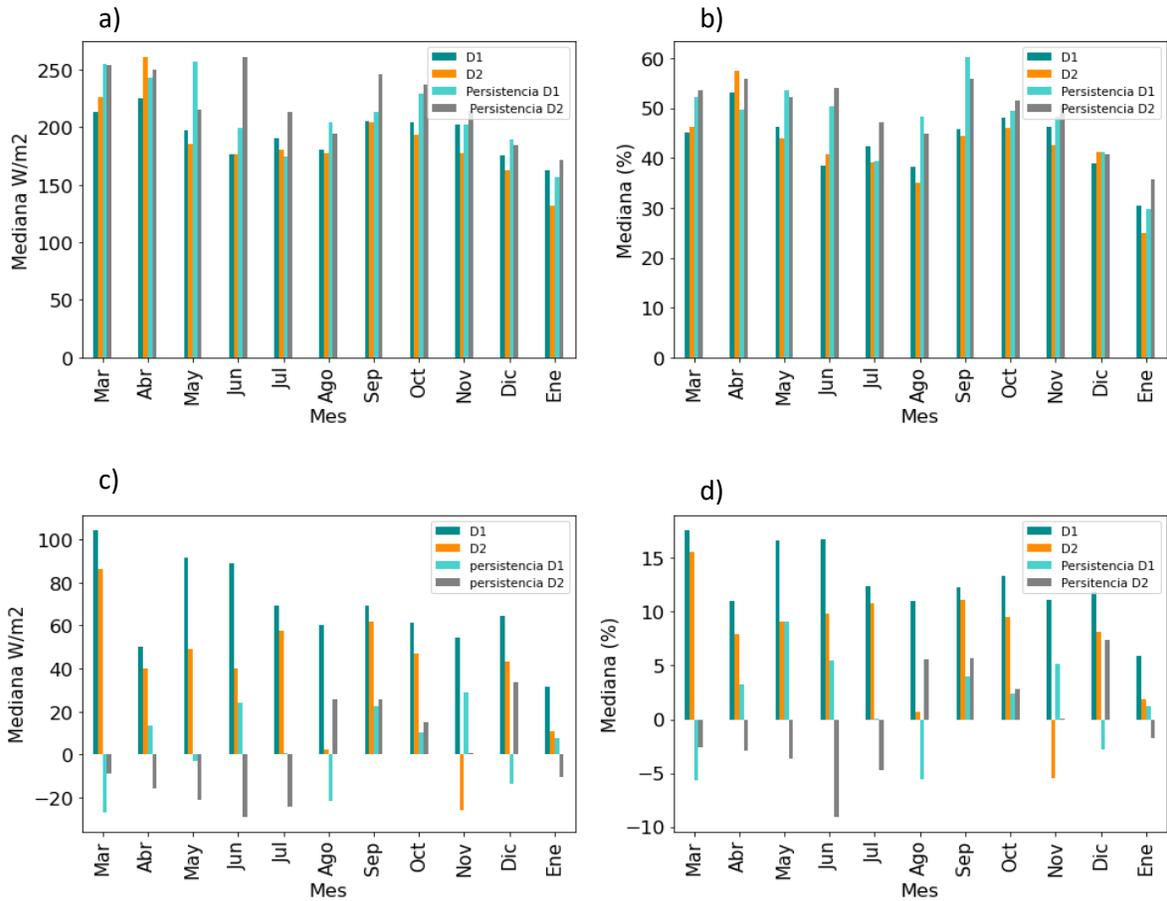


Figura 28. Medianas de los errores para a.) RMSE, b.) nRMSE, c.) MBE, d.) nMBE para el D1, D2 de simulaciones de WRF y la persistencia D1 y D2

Los ciclos diarios de los errores RMSE y nRMSE para el D1 y el D2 se encuentran en las **Figuras 29 y 30**. Se puede observar que los errores RMSE tanto para el D1 como para el D2, empiezan a crecer a partir de las 6:00 a.m., luego disminuyen en horas cercanas al medio día, entre las 10:00 a.m. y las 2:00 p.m., finalmente el RMSE vuelve a incrementar en las horas de la tarde reportando, en general, valores más altos que los de la mañana.

La mayoría de los meses de temporada seca no superaron RMSEs de 300 W/m^2 , mientras que en alguna hora del día los meses de temporada lluviosa los superaron. Por otra parte, en mayo, julio, diciembre y enero, el D2 exhibe errores RMSE más pequeños que el D1, en el resto de meses varía bastante de hora a hora.

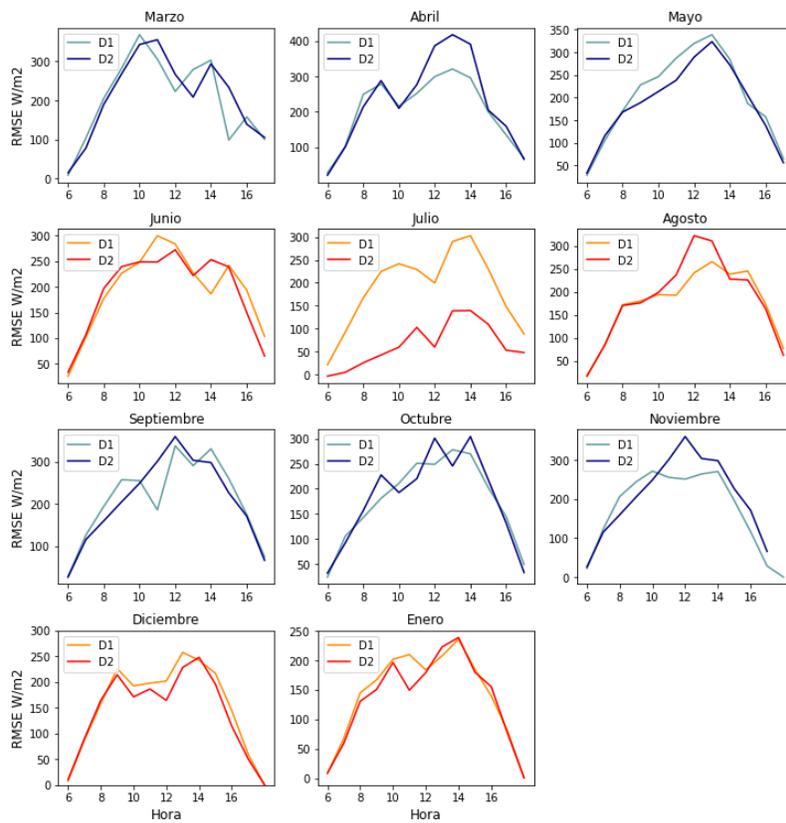


Figura 29. Ciclos diarios del RMSE

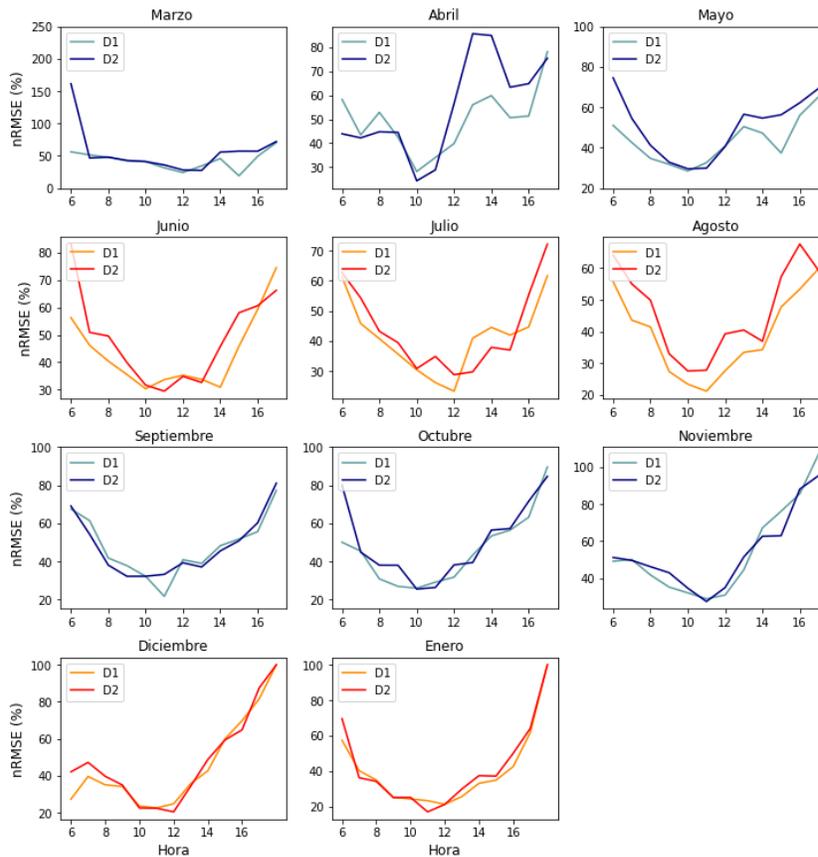


Figura 30. Ciclos diarios del nRMSE

El ciclo diario de nRMSE, tanto para el D1 como para el D2, exhibe errores muy grandes en las horas de la mañana (6:00 a.m.), luego estos empiezan a disminuir hasta un valor cercano al mediodía, y de ahí vuelven a incrementar, hasta las 5:00 p.m., es decir, que el ciclo diario de nRMSE presentó dos picos, uno cercano a las 6:00 a.m. y otro alrededor de las 5:00 p.m. El comportamiento del ciclo diario del nRMSE puede estar asociado a la presencia de nubes, ya que en un estudio del Valle de Aburrá (Correa, 2020), se encontró que el ciclo diario de la frecuencia de nubes tiene un comportamiento similar a lo encontrado en la **Figura 30**, es decir, que las horas que presentan errores más grandes, también muestran el porcentaje de frecuencia de nubes más grande (ver **Figura 31**). Aun así, este comportamiento puede estar principalmente mediado por el denominador, el cual es más pequeño en las horas donde la radiación es poca, principalmente a las 6:00 a.m y las 5:00 pm, lo que causaría incrementos en los valores de nRMSE, así que el error puede ser grande simplemente a causa del denominador y no por la presencia de nubes.

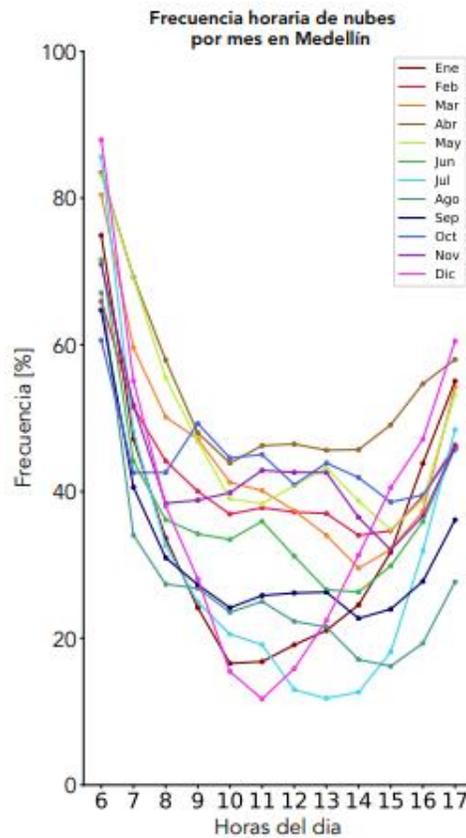


Figura 31. Frecuencia de nubes por mes en Medellín. Tomado de Correa (2020)

En las **Figuras 32 y 33** se observan los ciclos diarios del MBE y en nMBE para el D1 y el D2. El ciclo diario del MBE tiene un comportamiento similar al del RMSE, el MBE empieza a incrementar en las horas de la mañana, luego desciende alrededor del mediodía y finalmente vuelve a aumentar.

El D1, mostró inclinación a sobreestimar la radiación en casi todas las horas de los diferentes meses, mientras el D2, presentó más errores negativos de MBE y nMBE. Por otra parte, al estandarizar el MBE, se observa que las horas de la tarde presentaron valores muy altos, esto podría darse por lo mencionado anteriormente, en la tarde los valores de radiación son bajos, y al dividir el MBE por promedios de radiación bajos, incrementa el error (nMBE).

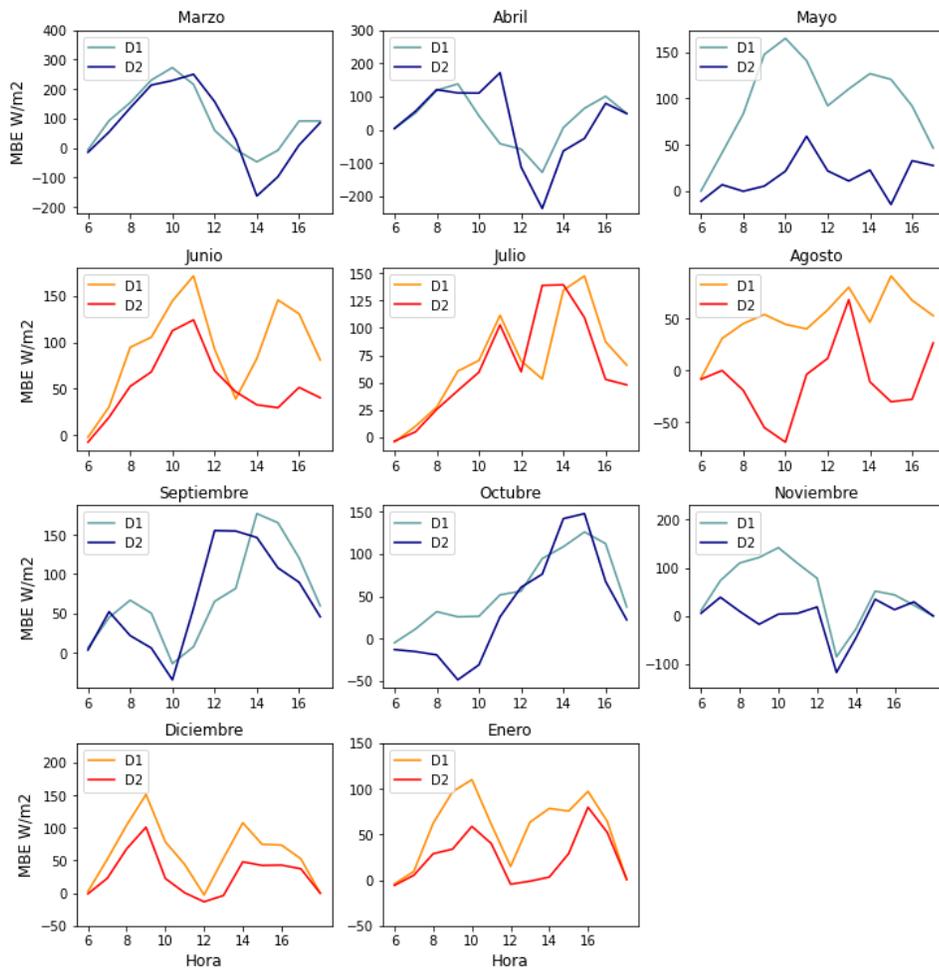


Figura 32. Ciclos diarios del MBE

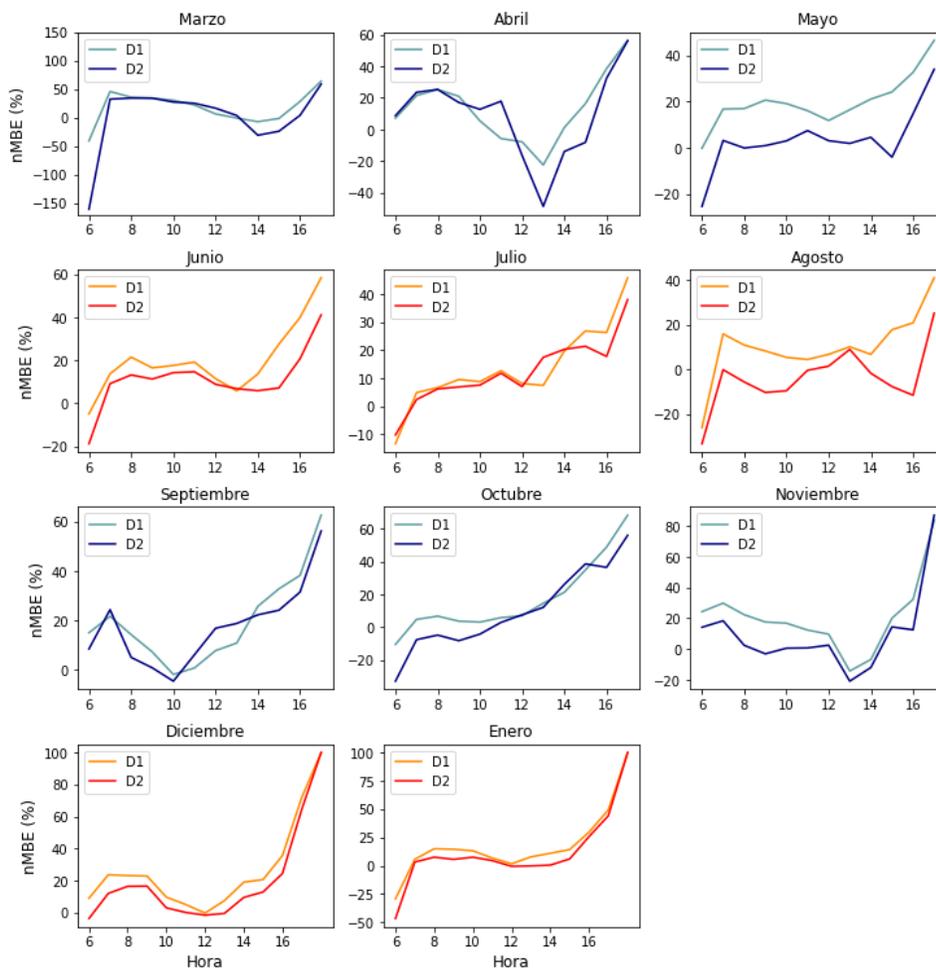


Figura 33. Ciclos diarios del nMBE

4.3.3 Valores diarios de irradiancia solar

En la **Tabla 2** y en la **Figura 34** se presentan las correlaciones entre los promedios diarios de irradiancia solar de los modelos (D1, D2, la persistencia D1, la persistencia D2) y los promedios diarios de las mediciones in situ del piranómetro de Torre SIATA.

El D1 de simulaciones de WRF presentó correlaciones significativas para todos los meses exceptuando para abril y agosto. En general, el D2 también exhibe correlaciones significativas, salvo para marzo y abril. Por el contrario, ambas persistencias presentaron correlaciones muy bajas, menos para julio (persistencia D1) y para septiembre (persistencia D2). Es decir, que las persistencias mostraron problemas para predecir el promedio diario de irradiancia solar, mientras WRF, mostró mejor capacidad para hacerlo. Se esperaría que el D1 presente correlaciones más altas que el D2, aun así, el D2 presentó 6 meses de los 11 analizados con correlaciones más altas que el D1. Por otra parte, las correlaciones de los valores diarios no presentaron valores más altos para las temporadas secas de la región,

inclinación que sí muestran las correlaciones de los valores horarios en la sección 4.3.1.

Tabla 3. Correlaciones entre promedios diarios de irradiancia solar de las mediciones in situ y los modelos (D1 y D2 de WRF, persistencia D1 y persistencia D2)

Mes	Correlación			
	D1	D2	Persistencia D1	Persistencia D2
Marzo	0,72	0,47	0,08	-0,33
Abril	0,10	-0,28	0,06	0,01
Mayo	0,47	0,49	0,09	0,25
Junio	0,69	0,40	0,12	-0,01
Julio	0,53	0,56	0,41	-0,01
Agosto	0,26	0,53	0,26	0,08
Septiembre	0,62	0,52	0,01	0,54
Octubre	0,71	0,81	0,27	0,12
Noviembre	0,67	0,57	0,28	0,21
Diciembre	0,45	0,54	0,05	0,11
Enero	0,42	0,56	0,24	-0,02

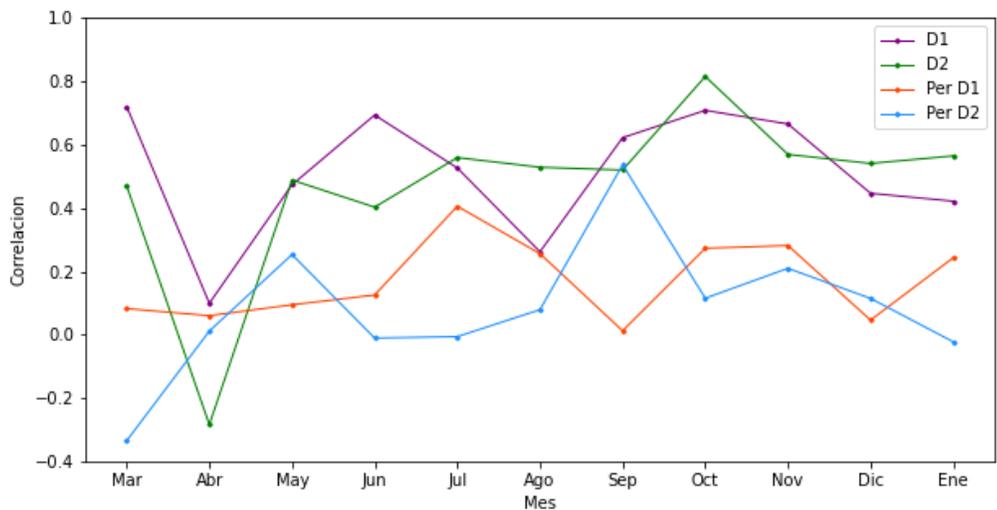


Figura 34. Correlaciones entre promedios diarios de irradiancia solar de las mediciones in situ y los modelos (D1 y D2 de WRF, persistencia D1 y persistencia D2)

5. Conclusiones

Colombia le está apostando a la diversificación de su matriz eléctrica, incluyendo las energías renovables. Una de las energías renovables a las que se le apuesta es a la energía solar, puesto que el país cuenta con una irradiación promedio mayor a la del promedio mundial (UPME, 2015). Debido a la gran variabilidad de la irradiancia solar, apostar a proyectos de energía solar implica contar con pronósticos de generación confiables para la operación de la red, lo que podría ayudar a los operadores a reducir costos y a hacer una buena planificación del recurso.

Por lo anterior, este estudio buscó evaluar el modelo WRF en el pronóstico de la irradiancia solar en el Valle de Aburrá, con pronósticos de 24 y 48 horas de antelación (D1 y D2). Los resultados mostraron que todas las simulaciones en general presentaron errores nMBE con medianas por debajo de aproximadamente el 20% y según el comportamiento de este error, WRF tiende a sobreestimar la radiación solar en todos los meses de estudio tanto para las simulaciones de 24 horas y para el D1 y D2 de las simulaciones de 48 horas, mostrando el D1 una inclinación más fuerte a la sobreestimación que el D2, ya que en varios meses tanto de temporada lluviosa como de temporada seca se encontró que el D1 puede alcanzar mayores sobreestimaciones que el D2, llegando a presentar valores máximos de MBE de hasta aproximadamente 150 W/m² más altos. Al contrario de lo encontrado en la bibliografía, la sobreestimación no muestra dependencia de la temporada, es decir, los meses de temporada lluviosa, no siempre evidenciaron mayores valores de MBE positivos que los meses de temporada seca. En cuanto al nRMSE, el modelo presentó porcentajes de error más altos, pero en su mayoría las medianas están por debajo del 50%. Al contrario del MBE, el RMSE presentó dependencia estacional, es decir, los errores más altos los presentaron los meses de temporada lluviosa de la región de estudio, lo que podría estar relacionado al deficiente modelado de nubes, puesto que, en estudios anteriores se ha encontrado que el modelo se caracteriza por presentar mayores errores en días nublados; además, los ciclos diarios del RMSE mostraron valles en horas cercanas al mediodía, que son justamente las horas donde la región de estudio muestra menor presencia de nubes. Lo anterior sumado a que las correlaciones horarias entre WRF y las mediciones in situ son casi en totalidad más altas en los meses de temporada seca, indica que el modelo presenta pronósticos más precisos para estos meses.

Las simulaciones de WRF presentaron, en general, mejor rendimiento que el modelo más simple encontrado en la predicción de irradiancia solar, la persistencia, ya que son más los meses en los que WRF presentó errores RMSE menores a la persistencia, aun así, se encontraron meses donde los modelos obtuvieron errores muy similares. Asimismo, la persistencia obtuvo MBEs positivos similares, pero negativos mucho más grandes en magnitud. Además, los promedios horarios y diarios de WRF mostraron correlaciones más altas con las mediciones in situ que las presentadas por el modelo de persistencia; WRF para ambos horizontes de tiempo mostró correlaciones horarias cercanas a 0.80 y diarias alrededor

de 0.60, mientras que la persistencia presentó correlaciones horarias próximas a 0.70 y diarias cercanas a 0.2. En cuanto a las correlaciones de las anomalías horarias respecto al ciclo diurno con las mediciones in situ, comparado con la persistencia, WRF obtuvo correlaciones más altas en todos los meses; sin embargo, ninguno de los modelos presentó correlaciones significativas, es decir, ni WRF ni la persistencia tienen capacidad para reproducir las fluctuaciones atípicas, lo que indicaría que el pronóstico de WRF es mucho mejor para valores diarios que para anomalías horarias.

Contrario a lo que se esperaba el rendimiento del modelo no disminuyó con el horizonte de tiempo, ya que las simulaciones del D2-WRF presentaron medianas de MBE y nMBE en su totalidad menores a las del D1-WRF; además, este último puede alcanzar medianas positivas hasta aproximadamente 45 W/m² más altas que las del D2-WRF, y las distribuciones de los valores horarios, mostraron meses como mayo, agosto y noviembre, donde el D1-WRF presentó mayores frecuencias que el D2-WRF en los valores altos de irradiancia solar. Asimismo, en general, las medianas de RMSE y nRMSE son menores para el D2-WRF que para el D1-WRF, exceptuando marzo y abril para el RMSE y marzo, abril, junio y diciembre para el nRMSE. Sin embargo, el D1-WRF representó de mejor manera otras propiedades, como las correlaciones horarias con las mediciones in situ, ya que 9 de los 11 meses analizados mostraron correlaciones más altas para el D1 que para el D2, y en cuanto a las correlaciones diarias, el D2 presentó 6 meses con correlaciones más altas. Teniendo en cuenta que los pronósticos para el D2 presentaron en general medianas más pequeñas de los diferentes errores que los del D1, se puede sugerir que el modelo necesita mayor tiempo para estabilizarse, es decir, un spin up mayor a las 6 horas que tradicionalmente se utilizan. Sin embargo, esto también podría estar explicado por el tiempo de evaluación del modelo. En estudios anteriores (Lara-Fanego et al., 2012) encontraron resultados similares y concluyeron que los errores de pronóstico de simulaciones con horizontes más grandes son similares o en algunos casos mejores a los de horizontes más cortos porque probablemente el tiempo de evaluación del modelo fue relativamente corto, lo que podría explicar también que el rendimiento del modelo de persistencia está cerca del rendimiento del modelo WRF en algunos periodos de estudio, tal como se evidenció en este estudio.

En general, la magnitud de los errores encontrados para WRF concuerdan con errores encontrados en la literatura, sin tener en cuenta los pocos días extremos que superan el 100%. En este trabajo se encontraron gran cantidad de valores de nMBE menores al 20% y de nRMSE menores al 50%. En Turquía, se encontraron valores de nMBE entre el 17% y el 30% para condiciones nubladas y del 10% y el 18% para condiciones despejadas, también se encontraron valores de nRMSE para condiciones nubladas entre el 41 y el 70% y para condiciones despejadas entre el 20 y el 39% (Incecik et al., 2019). Otros autores han encontrado magnitudes de errores más bajas, en España, se encontraron valores de nMBE del 2% para cielos despejados y del 18% para condiciones nublados y nRMSE del 10% en cielos despejados y el 50% en condiciones nubladas (Lara-Fanego et al., 2012); y en la Isla

Reunión, algunos autores encontraron un nRMSE de hasta 57,3% y nMBE de 16,08% (Diagne et al., 2014).

En trabajos futuros se propone avanzar en una corrección de sesgo de las simulaciones brindadas por WRF, buscando mejorar los valores de los diferentes errores y así mejorar la precisión de los pronósticos.

Bibliografía

Arango, M.C. (2019). Panorama energético de Colombia. Bancolombia S.A.

Arbizu-Barrena, C., Ruiz-Arias, J. A., Rodríguez-Benítez, F. J., Pozo-Vázquez, D., & Tovar-Pescador, J. (2017). Short-term solar radiation forecasting by advecting and diffusing MSG cloud index. *Solar Energy*, 155, 1092-1103.

Aryaputera, A. W., Yang, D., & Walsh, W. M. (2015). Day-Ahead Solar Irradiance Forecasting in a Tropical Environment. *Journal of Solar Energy Engineering*, 137(5), 051009. <https://doi.org/10.1115/1.4030231>

Bernal Manrique, Natalia. (2019). Análisis de condiciones meteorológicas superficiales en el Valle de Aburrá y sus posibles efectos sobre la calidad del aire. [Tesis de pregrado, Universidad de Antioquia]

Checa, F. E., & De La Cruz, O. E. (2015). Potencial natural para el desarrollo fotovoltaico en Colombia. *Libros Editorial UNIMAR*.

Chambi, L. (2018). Estudio y análisis de la actividad solar, radiación solar global y radiación uv en la ciudad de Arequipa. Universidad Nacional de San Agustín de Arequipa. Arequipa, Perú.

Colombia Energía. (2020). Estado del mercado solar colombiano.

Correa Sánchez, N. (2020). Caracterización de la radiación solar para la estimación del potencial de energía fotovoltaica en entornos urbanos, caso de estudio: Valle de Aburrá.

Cuervo & Mendez (2011). Energía solar fotovoltaica. FC Editorial.

Diagne, M., David, M., Boland, J., Schmutz, N., & Lauret, P. (2014). Post-processing of solar irradiance forecasts from WRF model at Reunion Island. *Solar Energy*, 105, 99-108.

D'Isidoro, M., Briganti, G., Vitali, L., Righini, G., Adani, M., Guarnieri, G., ... y Zanini, G. (2020). Estimación de los recursos de energía solar y eólica en Lesotho y su complementariedad mediante simulación anual de WRF en alta resolución. *Energía renovable*.

Engeland, K., Borga, M., Creutin, J. D., François, B., Ramos, M. H., & Vidal, J. P. (2017). Space-time variability of climate variables and intermittent renewable electricity production—A review. *Renewable and Sustainable Energy Reviews*, 79, 600-617.

González, J. F. B., Sepúlveda, A. L., & Aponte, K. T. (2014). *Zonas no interconectadas eléctricamente en Colombia: problemas y perspectiva* (No. 012817). Universidad Nacional de Colombia-FCE-CID.

Henao, F., Viteri, J. P., Rodríguez, Y., Gómez, J., & Dyner, I. (2020). Annual and interannual complementarities of renewable energy sources in Colombia. *Renewable and Sustainable Energy Reviews*, 134, 110318.

Hocaoglu , Ö.N. Gerek , M. Kurban. (2009). Un nuevo procedimiento de dimensionamiento de sistemas híbridos (eólicos-fotovoltaicos). *Energía solar*, 83 (11), págs.2019- 2028.

Hocaoğlu, F. O. (2011). Stochastic approach for daily solar radiation modeling. *Solar Energy*, 85(2), 278-287.

Huva, R., Verbois, H. y Walsh, W. (2020). Comparaciones de la previsión solar al día siguiente para Singapur utilizando enfoques de asimilación de datos 3DVAR y 4DVAR con el modelo WRF. *Energía renovable*, 147, 663-671.

IDEAM. (s.f). Importancia de la radiación solar.

IDEAM. (s.f). CARÁCTERÍSTICAS CLIMATOLÓGICAS DE CIUDADES PRINCIPALES Y MUNICIPIOS TURÍSTICOS.

IDEAM, & UNAL. (2018). La Variabilidad Climática y el Cambio Climático en Colombia.

IDEAM. (2019). Boletín Climatológico.

Incecik, S., Sakarya, S., Tilev, S., Kahraman, A., Aksoy, B., Caliskan, E., ... & Odman, M. T. (2019). Evaluation of WRF parameterizations for global horizontal irradiation forecasts: A study for Turkey. *Atmósfera*, 32(2), 143-158.

IPCC, 2014: Cambio climático 2014: Informe de síntesis. Contribución de los Grupos de trabajo I, II y III al Quinto Informe de Evaluación del Grupo Intergubernamental de Expertos sobre el Cambio Climático [Equipo principal de redacción, R.K. Pachauri y L.A. Meyer (eds.)]. IPCC, Ginebra, Suiza, 157 págs

Lago, J., De Brabandere, K., De Ridder, F., & De Schutter, B. (2018). Short-term forecasting of solar irradiance without local telemetry: A generalized model using satellite data. *Solar Energy*, 173, 566-577.

Lara-Fanego, V., Ruiz-Arias, J. A., Pozo-Vázquez, D., Santos-Alamillos, F. J., & Tovar-Pescador, J. (2012). Evaluation of the WRF model solar irradiance forecasts in Andalusia (southern Spain). *Solar Energy*, 86(8), 2200-2217.

Lima, F. J., Martins, F. R., Pereira, E. B., Lorenz, E., & Heinemann, D. (2016). Forecast for surface solar irradiance at the Brazilian Northeastern region using NWP model and artificial neural networks. *Renewable Energy*, 87, 807-818.

Mathiesen, P., Collier, C., & Kleissl, J. (2013). A high-resolution, cloud-assimilating numerical weather prediction model for solar irradiance forecasting. *Solar Energy*, 92, 47-6.

Miniambiente. (s.f). Causas del cambio climático.

Mostafavi, E. S., Ramiyani, S. S., Sarvar, R., Moud, H. I., & Mousavi, S. M. (2013). A hybrid computational approach to estimate solar global radiation: an empirical evidence from Iran. *Energy*, 49, 204-210.

Olarte, M. S. T. (2017). *Nuevos modelos de predicción a corto plazo de la generación eléctrica en plantas basadas en energía solar fotovoltaica*. Doctoral dissertation, Universidad de La Rioja.

Peña, M. (2018). Predicción de la irradiancia solar con un sistema de visión artificial para horizontes de tiempos cortos “Nowcasting”. Centro de investigaciones en óptica, A.C. Aguascalientes, México.

Pérez, D. & Silva, M. A. (2007). Procedimiento de mantenimiento y calibración de estación radiométrica. Universidad de Sevilla.

Reikard, G. (2020). Comment on Verification of deterministic solar forecasts: Choice of models, and estimation procedure. *Solar Energy*.

Ruiz-Arias, J. A., Arbizu-Barrena, C., Santos-Alamillos, F. J., Tovar-Pescador, J., & Pozo-Vázquez, D. (2016). Assessing the surface solar radiation budget in the WRF model: A spatiotemporal analysis of the bias and its causes. *Monthly Weather Review*, 144(2), 703-711

Superservicios. (2017). ZONAS NO INTERCONECTADAS - ZNI Diagnóstico de la prestación del servicio de energía eléctrica 2017

Tzoumanikas, P., Nikitidou, E., Bais, A. F., & Kazantzidis, A. (2016). The effect of clouds on surface solar irradiance, based on data from an all-sky imaging system. *Renewable Energy*, 95, 314-322.

UPME. (2015). Integración de las energías renovables no convencionales en Colombia. In Ministerio de Minas y Energía. <https://doi.org/10.1021/ja304618v>

Urrego, J. (2019). Estimate of the global horizontal irradiance for the site of Medellín-Colombia using a stochastic

Vanegas Chamorro, M., Villicaña Ortíz, E., & Arrieta Viana, L. (2015). Quantification and characterization of solar radiation at the department of La Guajira-Colombia by calculating atmospheric transmissivity. *Prospectiva*, 13(2), 54-63.

Vázquez Axotla, M. d. (Febrero de 2014). Medición de parametros indicadores de actividad solar. Puebla: Benemérita Universidad Autónoma de Puebla, Facultad de Ciencias Fisico-Matemáticas.

Verbois, H., Huva, R., Rusydi, A., & Walsh, W. (2018). Solar irradiance forecasting in the tropics using numerical weather prediction and statistical learning. *Solar Energy*, 162, 265-277.

Wallace, J. M., & Hobbs, P. V. (2006). Atmospheric science: an introductory survey. Elsevier.

Zamora, R. J., Dutton, E. G., Trainer, M., McKeen, S. A., Wilczak, J. M., & Hou, Y. T. (2005). The accuracy of solar irradiance calculations used in mesoscale numerical weather prediction. *Monthly weather review*, 133(4), 783-792.

Zang, H., Liu, L., Sun, L., Cheng, L., Wei, Z., & Sun, G. (2020). Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations. *Renewable Energy*.

Zhang, J., Zhao, L., Deng, S., Xu, W., & Zhang, Y. (2017). A critical review of the models used to estimate solar radiation. *Renewable and Sustainable Energy Reviews*, 70, 314-329.