



UNIVERSIDAD
DE LA REPUBLICA
URUGUAY



FACULTAD DE
INGENIERÍA
UDELAR

Evaluación de modelos numéricos globales para la predicción de la radiación solar global en el sureste de Sudamérica

Vívian Teixeira-Branco

Tesis de Maestría presentada Facultad de Ingeniería de la Universidad de la República en cumplimiento parcial de los requisitos necesarios para la obtención del título de Magíster en Ingeniería de la Energía.

Tutores

Dr. Prof. Rodrigo Alonso-Suárez

Dr. Prof. Gabriel Cazes

Tribunal

Dr. Prof. Agustín Laguarda

Dr. Prof. Alejandro Gutiérrez

Dr. Prof. Rafael Terra

Montevideo – Uruguay

Diciembre de 2023



UNIVERSIDAD
DE LA REPUBLICA
URUGUAY



FACULTAD DE
INGENIERÍA
UDELAR

Evaluación de modelos numéricos globales para la predicción de la radiación solar global en el sureste de Sudamérica

Vívian Teixeira-Branco

Tesis de Maestría presentada al Programa de Posgrado en Ingeniería de la Energía, Facultad de Ingeniería de la Universidad de la República, como parte de los requisitos necesarios para la obtención del título de Magíster en Ingeniería de la Energía.

Director:

Dr. Prof. Rodrigo Alonso-Suárez

Codirector:

Dr. Prof. Gabriel Cazes

Montevideo – Uruguay

Diciembre de 2023

Teixeira-Branco, Vívian

Evaluación de modelos numéricos globales para la predicción de la radiación solar global en el sureste de Sudamérica / Vívian Teixeira-Branco. - Montevideo: Universidad de la República, Facultad de Ingeniería, 2023.

X, 92 p.: il.; 29, 7cm.

Director:

Rodrigo Alonso-Suárez

Codirector:

Gabriel Cazes

Tesis de Maestría – Universidad de la República, Programa en Ingeniería de la Energía, 2023.

Referencias bibliográficas: p. 67 – 67.

1. Pronóstico solar, 2. GHI, 3. NWP, 4. Modelos globales. I. Alonso-Suárez, Rodrigo, *et al.* II. Universidad de la República, Programa de Posgrado en Ingeniería de la Energía. III. Título.

INTEGRANTES DEL TRIBUNAL DE DEFENSA DE TESIS

D.Sc. Prof. Agustín Laguarda

D.Sc. Prof. Alejandro Gutiérrez

D.Sc. Prof. Rafael Terra

Montevideo – Uruguay
Diciembre de 2023

Agradecimientos

Quiero agradecer a Dios por haberme concedido la salud para concluir este trabajo. A mis padres y a mis hermanos por el apoyo e incentivo incondicional que me dieron desde el momento en que decidí empezar mi jornada en Uruguay; los valores de nuestra familia son la base de mi vida. A mis tíos, primos y amigos, que dedicaron su tiempo para hacerse presentes y venir a conocer más sobre este país. A mi novio por su paciencia, compañerismo y motivación a lo largo de estos años.

Agradezco a mi tutor, Dr. Rodrigo Alonso-Suárez, por la confianza constante que me ha depositado, por los consejos tanto en el ámbito profesional como en el personal, y por su aporte técnico y científico para que se concretara esta tesis. Su forma de ver y enfrentar los desafíos ha sido un gran ejemplo para mí. Quiero agradecer a mi co-tutor, Dr. Gabriel Cazes, por haber aceptado dirigir este trabajo, por su disponibilidad y por su aporte científico. Su forma de transmitir conocimientos es una inspiración.

Debo agradecer a la Univesidad de la República y a la Facultad de Ingeniería por posibilitar continuar mi formación profesional de forma gratuita. En especial, agradezco al Laboratorio de Energía Solar (LES) por la estructura disponible, a todos sus integrantes por el ambiente amigable construido, y por el apoyo técnico que están siempre dispuestos a compartir. Agradezco también a Agencia Nacional de Investigadores (ANII) por haberme seleccionado como becaria; el apoyo financiero concedido fue fundamental para mantenerme en los primeros años en el país.

Quiero agradecer al Dr. Alejandro Gutiérrez, quien fue el responsable por proporcionar el primer vínculo de colaboración con el LES y que posteriormente, junto con el Dr. Rodrigo Alonso-Suárez, fueron los responsables de mi llegada a Uruguay. Agradezco su amistad y apoyo en los primeros meses de adaptación en el país.

Agradezco a la Universidad Tecnológica del Uruguay, en especial a la coordinación de la carrera de Ingeniería en Energías Renovables y a los compañeros del Laboratorio Solar. Tener el apoyo de ustedes fue muy importante para finalizar esta etapa.

RESUMEN

La precisión de las técnicas de pronóstico de la energía solar fotovoltaica se traduce en una mayor capacidad de gestión del sistema eléctrico para el despacho de energía y administración de las reservas. Dado que el recurso solar es una fuente de energía variable, disponer de pronósticos precisos es necesario para garantizar la integración eficiente de esta fuente de energía en las redes eléctricas. Existen una serie de técnicas para predecir la energía solar, cuya utilidad depende críticamente del horizonte de pronóstico y la resolución espacial requerida. En general, estas técnicas se dividen en cuatro grandes grupos de formas de predicción: cámaras todo-cielo, nowcasting satelital, modelos numéricos de atmósfera (NWP, Numerical Weather Predictions) y pronóstico por la utilización de técnicas estadísticas o de aprendizaje automático.

Esta tesis analiza el desempeño del pronóstico de la radiación solar provisto por diferentes NWP en varios sitios del sureste de Sudamérica durante el periodo de tres años. Se consideran las salidas de las primeras 24 horas del pronóstico de cada modelo, y se utilizan medidas registradas en tierra con calidad controlada como referencia para cuantificar la incertidumbre de predicción de los modelos. Se analiza la incertidumbre de predicción para el acumulado diario y para la escala horaria intra-día, considerando el periodo completo y la discriminación por cada estación del año. Además, en el análisis diario se incluye una evaluación del desempeño de los modelos según las condiciones de nubosidad del cielo.

Los modelos aquí evaluados presentan un mejor desempeño para la región que el procedimiento de referencia de persistencia, tanto a escala horaria como diaria. No se observa variabilidad significativa de desempeño entre los sitios evaluados y tampoco en las diferentes estaciones del año. La discriminación por distintas condiciones de cielo muestra que el desempeño de los modelos empeoran con el aumento de la nubosidad. Entre los modelos NWP evaluados, el ECMWF se destaca por su alto rendimiento en la región, con un desvío cuadrático medio relativo a la media (rRMSD) de 17.0 % a escala diaria. Sin embargo, se observa que subestima el recurso en condiciones de cielo despejado y el acceso a sus pronósticos es de uso restringido. Por otro lado, el modelo ICON también tiene un buen rendimiento y es de dominio público, con un rRMSD diario de 18.0 %. El modelo GFS con re-

solución de 0.5 km presenta resultados un poco peores, con un rRMSD diario de 21.9%. Las predicciones GFS son también de dominio público, pero subestiman en mayor grado que los demás modelos la ocurrencia de nubosidad. Por último, el modelo NEMS30 es de especial interés por ser uno de los pronósticos utilizados en Uruguay para el despacho eléctrico. Este presenta un rRMSD diario de 21.0% y se muestra competitivo en días nublados, aunque se desconoce la técnica de postprocesamiento que utiliza la empresa propietaria.

Palabras claves:

Pronóstico solar, GHI, NWP, Modelos globales.

ABSTRACT

The accuracy of photovoltaic solar energy forecasting techniques translates into enhanced capability for electricity system management, including energy dispatch and reserve handling. Given the variable nature of solar resources, having precise forecasts is essential to ensure the efficient integration of this energy source into power grids. There are various techniques for solar energy prediction, the usefulness of which critically depends on the forecast horizon and required spatial resolution. Generally, these techniques fall into four major groups of prediction methods: all-sky cameras, satellite nowcasting, numerical weather prediction models (NWP), and forecasting using statistical or machine learning techniques

This thesis analyzes the performance of solar radiation forecasting provided by different NWPs at various sites in southeastern South America over a three-year period. The outputs of the first 24 hours of each model's forecast are considered, and quality-controlled ground measurements are used as a reference to quantify the models' prediction uncertainty. The prediction uncertainty is analyzed for daily integrated values and for the intra-day hourly scale, considering the entire period and discrimination by each season of the year. Additionally, the daily analysis includes an evaluation of the models' performance based on sky cloudiness conditions.

The models evaluated here show better performance for the region compared to the reference persistence procedure, both at hourly and daily scales. No significant variability in performance is observed among the assessed sites or across different seasons of the year. Discrimination by different sky conditions shows that model performance deteriorates with increasing cloudiness. Among the evaluated NWPs, ECMWF stands out for its high performance in the region, with a root mean square deviation relative to the mean (rRMSD) of 17.0 % at the daily scale. However, it is noted that it underestimates the resource under clear sky conditions and its forecast access is restricted. On the other hand, the ICON model also exhibits good performance and is publicly available, with a daily rRMSD of 18.0 %. The GFS model with a resolution of 0.5 km shows slightly poorer results, with a daily rRMSD of 21.9 %. GFS predictions are also publicly available but underestimate the occurrence of cloudiness more than other models. Finally, the NEMS30 model is of particular interest as it is one of the forecasts used in Uruguay for electricity dispatch. It

presents a daily rRMSD of 21.0 % and is competitive on cloudy days, although the post-processing technique used by the owning company is unknown.

Keywords:

Solar forecast, GHI, NWP, Global Models.

Tabla de contenidos

1	Introducción	1
1.1	Antecedentes	2
1.2	Sobre esta tesis	3
2	Pronóstico de la irradiación solar	5
2.1	Técnicas de predicción solar	6
2.2	Modelos numéricos de la atmósfera	8
2.2.1	Modelos globales	12
2.2.2	Modelos regionales	13
2.3	Métricas de desempeño	14
2.3.1	Matriz confusión	16
2.4	Desempeño de NWP para irradiación solar	18
3	Base de información	23
3.1	Medidas en tierra	23
3.2	Modelos numéricos utilizados	25
3.2.1	ECMWF	26
3.2.2	GFS	27
3.2.3	ICON	28
3.2.4	NEMS30	29
3.3	Característica de los datos	29
4	Evaluación del pronóstico intra-diario	33
4.1	Periodo anual	33
4.2	Periodo estacional	38
5	Evaluación del pronóstico diario	43
5.1	Periodo anual	43

5.2	Periodo estacional	46
5.3	Desempeño según condición de cielo	49
5.3.1	Discriminación en categorías de cielo	49
5.3.2	Relación entre RMSD y índice de cielo claro	54
5.3.3	Desempeño según la matriz de confusión	58
6	Conclusiones	61
	Lista de figuras	65
	Lista de tablas	66
	Apéndices	67
	Apéndice 1 Conceptos básicos de radiación solar.	68
	Anexos	71
	Anexo 1 Desempeño anual intra-diario por sitio	72
	Anexo 2 Desempeño estacional intra-diario por sitio	80
	Anexo 3 Indicadores de desempeño diario por sitio	83
	Anexo 4 Matriz confusión por sitio	88
	Anexo 5 Matriz confusión normalizada por sitio	91

Capítulo 1

Introducción

La energía solar fotovoltaica es la fuente de energía que más crece y recibe inversiones a nivel mundial, superando en la actualidad incluso la energía eólica (IEA, 2022). Debido a este crecimiento se ha alcanzado la importante cifra de 1.2 TW de capacidad instalada en todo el mundo en 2022, lo que muestra la relevancia actual de esta fuente de energía para lograr los objetivos climáticos globales. El desarrollo en mayor escalada de esta tecnología implica nuevos desafíos para la red eléctrica. La integración de esta fuente intermitente requiere mayor flexibilidad y capacidad de administración de la red, siendo ésta una de las principales barreras para el incremento significativo de la generación solar fotovoltaica en las próximas tres décadas (IRENA, 2019). En este contexto, el desarrollo de herramientas que puedan anticipar las fluctuaciones generadas por el recurso solar es fundamental para que los operadores del sistema eléctrico realicen una gestión inteligente del despacho de la energía, las reservas del sistema y la comercialización de la electricidad (Lorenz et al., 2009; Yang et al., 2020).

Pronosticar la generación solar fotovoltaica requiere como paso inicial predecir la irradiación solar global en un plano horizontal a nivel de superficie (GHI, Global Horizontal Irradiation). Para su pronóstico existen distintas técnicas que están divididas en cuatro grandes grupos: cámaras todo-cielo, nowcasting satelital, modelos numéricos de atmósfera (NWP, Numerical Weather Predictions) y pronóstico por técnicas estadísticas o de aprendizaje automático. Los modelos numéricos de atmósfera, objeto de esta tesis, son capaces de predecir desde 1 hora hasta varios días en adelante, resolviendo numéricamente las ecuaciones físicas que gobiernan los procesos en la atmósfera. La resolución de las ecuaciones físicas que modelan la dinámica de la atmósfera más un conjunto de condiciones iniciales, resulta en

un pronóstico del estado futuro de la atmósfera. Los NWP pueden ser clasificados como globales (GFS, ECMWF, entre otros), o regionales o de mesoescala (WRF, NAM, entre otros), según su dominio espacial de resolución.

El objetivo de esta tesis es evaluar y comparar el desempeño de la predicción de diferentes modelos numéricos de la atmósfera del tipo global, como un paso base para el desarrollo robusto de mejores herramientas de predicción solar en el sureste de Sudamérica.

1.1. Antecedentes

En los últimos cinco años el Laboratorio de Energía Solar (LES)¹ de la Universidad de la República (Udelar) ha dedicado esfuerzos sistemáticos para desarrollar herramientas de pronóstico adaptadas localmente para facilitar el avance del sector solar en la región. Para lograr este objetivo, se han implementado diversas etapas, que incluyen el desarrollo de modelos propios de predicción satelital, la validación de las técnicas de pronóstico existentes a nivel local, y la optimización local para reducir la incertidumbre de las predicciones. Actualmente la técnica de pronóstico de la energía solar con mayor desarrollo científico en la región es predicción basada en imágenes de satélite. Algunas contribuciones en esta área específica se encuentran documentadas en: Aicardi et al. (2022), Alonso-Suárez et al. (2020), Alonso-Suárez et al. (2021), Giacosa y Alonso-Suárez (2018), Marchesoni-Acland y Alonso-Suárez (2020) y Marchesoni-Acland et al. (2023).

En lo que se refiere a los modelos numéricos de la atmósfera, los primeros desarrollos aplicados al pronóstico de la energía solar se realizaron en el Instituto de Mecánica de los Fluidos e Ingeniería Ambiental (IMFIA) de la Facultad de Ingeniería (FING/Udelar). Este grupo implementó y evaluó las salidas de radiación solar del modelo operativo que se utilizaba para el pronóstico de energía eólica en Uruguay (Porrini, 2017; Porrini et al., 2015). Este pronóstico operacional estaba basado en el modelo de mesoescala WRF (Weather Research and Forecasting Model) con condiciones iniciales y de borde tomadas del GFS (Global Forecast System). En 2016, el Banco de Desarrollo de Latinoamérica (CAF) y la Administración del Mercado Eléctrico (ADME, Uruguay) acuerda la realización del proyecto PRO-NOS, que contó con la participación del IMFIA y el LES. La componente solar de este proyecto estuvo coordinada por el LES, y marcó el inicio del trabajo sistemá-

¹<https://http://les.edu.uy>

tico de este grupo en pronóstico solar. Desde entonces, ambos grupos (IMFIA y LES) colaboran en el desarrollo de conocimiento local/regional sobre el desempeño y funcionamiento de modelos NWP.

Los resultados encontrados en las primeras evaluaciones del pronóstico de la energía solar a partir de modelos numéricos demostraron que esta técnica es superior a metodologías básicas, como la persistencia. Sin embargo, las configuraciones probadas del modelo, que en ese momento estaban operativas para el pronóstico eólica, presentaron desvíos relativamente altos para el pronóstico de la energía solar, y requerían la aplicación de técnicas de postproceso para reducir la incertidumbre (Porrini, 2017; Porrini et al., 2015; Teixeira-Branco et al., 2018). Estos primeros análisis dejaron claro la necesidad de realizar estudios más detallados para mejorar el entendimiento de las características de específicas de los modelos NWP utilizados en el pronóstico de la energía solar.

1.2. Sobre esta tesis

Este trabajo documenta la primera intercomparación de desempeño de cinco diferentes modelos numéricos de la atmósfera para el pronóstico de las primeras 24h de la radiación solar (lo que se conoce como predicción day-ahead) en la región. Los modelos seleccionados para este análisis son los más relevantes o de uso más extendido en el área: ECMWF, ICON y el GFS con dos resoluciones espaciales (de 0.25° y 0.50° equiespaciado en latitud y longitud). También se incluye la evaluación del modelo NEMS30, que corresponde a los pronósticos de la empresa contratada por ADME. La evaluación se basa en una estadística de tres años de pronósticos globales en siete sitios distribuidos en el territorio uruguayo. Se utilizan como referencia las mediciones terrestres de calidad controlada registradas por el LES para el mismo periodo. En el análisis se consideran los tres años consecutivos de pronóstico para identificar el desempeño general del modelo. Además, se evalúan las diferentes estaciones del año, en el mismo periodo, para examinar las variaciones a lo largo del tiempo.

A partir de esta tesis se realizaron las publicaciones (Teixeira-Branco et al. 2022, 2021, 2018), las cuales reportan distintas partes de este trabajo. Las principales contribuciones de esta tesis fueron: (i) caracterización detallada de la incertidumbre de los principales modelos globales de pronóstico en la región, ante la variabilidad meteorológica local; (ii) comparación del desempeño de estos modelos, diagnosticando sus principales fortalezas y debilidades, e identificando aquellos de mejor

prestación en la región; y (iii) identificación de los espacio de mejora para las capacidades locales de pronóstico de la radiación solar.

Este texto se organiza de la siguiente manera. En el Capítulo 2, se describe el estado del arte de las técnicas de pronóstico de la irradiación solar, con especial énfasis en los modelos numéricos de la atmósfera. En el Capítulo 3, se describen en detalle las características de la base de información utilizada, la cual incluye medidas en tierra y las predicciones de los modelos de pronóstico utilizados. En el Capítulo 4 y Capítulo 5, se presentan los resultados de desempeño de los modelos a lo largo de los tres años evaluados y también en las diferentes estaciones de este mismo periodo. En ambos capítulos se incluye una evaluación de referencia basada en la técnica de persistencia. El Capítulo 4 se enfoca en la presentación de los resultados del pronóstico intra-diario, mientras que el Capítulo 5 detalla la evaluación a escala diaria. Además, en este último se realiza una evaluación con discriminación diaria según el índice de cielo claro. Finalmente, en el Capítulo 6, se presentan las conclusiones de la tesis y las perspectivas de trabajos futuros.

Capítulo 2

Pronóstico de la irradiación solar

El recurso solar es de naturaleza fluctuante. Anticipar estas fluctuaciones es necesario para garantizar la gestión inteligente del despacho de la energía eléctrica de origen solar y su comercialización, especialmente en el escenario actual de expansión de la energía solar fotovoltaica (PV) en varias partes del mundo. Con el avance continuo y reducción de costos de esta tecnología, la tendencia para las próximas décadas es de crecimiento acelerado. A pesar de esto, algunos modelos de prospectiva indican que una de las razones para que la contribución solar pueda verse desacelerada en las próximas décadas son las restricciones en su penetración en la red eléctrica debido a su intermitencia y escasa predictibilidad (Victoria et al., 2021). Un sistema de pronóstico solar confiable, en otras palabras, con menor incertidumbre, está en la base del desarrollo de sistemas eléctricos sostenibles, sin fallas, y con costo mínimo de operación (Bird et al., 2013; Katiraei & Agüero, 2011).

La variabilidad del recurso solar a nivel de la superficie terrestre puede ser explicada por varios factores, como el movimiento aparente del sol, cuya posición cambia a lo largo del día y del año, y la variabilidad de los constituyentes de la atmósfera, entre los cuáles destaca la nubosidad por su efecto significativo sobre la radiación solar (Mills et al., 2009). La variabilidad producida por el movimiento aparente del sol es perfectamente predecible y está relacionada con ecuaciones físicas y geométricas del movimiento relativo entre la Tierra y el Sol. Sin embargo, las fluctuaciones generadas por la nubosidad debido a sus procesos de formación, deformación, traslación y extinción son difíciles de predecir. Estos procesos están relacionados con complejos fenómenos físicos que ocurren en la atmósfera y cuya predicción con baja incertidumbre sigue siendo un desafío científico-tecnológico.

Existe una serie de técnicas para pronosticar la irradiación solar, cuya utilidad

depende críticamente del horizonte de pronóstico y la resolución espacial requerida (Diagne et al., 2013). El estado del arte en este respecto se describe en la Sección 2.1. Luego, la Sección 2.2 está centrada en el pronóstico por modelos numéricos de atmósfera, brindando un breve marco histórico, algunos conceptos centrales y su clasificación. La Sección 2.3 define las principales métricas utilizadas para evaluar el desempeño de los modelos de predicción. La Sección 2.4 presenta una revisión del desempeño de predicciones de la radiación solar partir de modelos numéricos de la atmósfera.

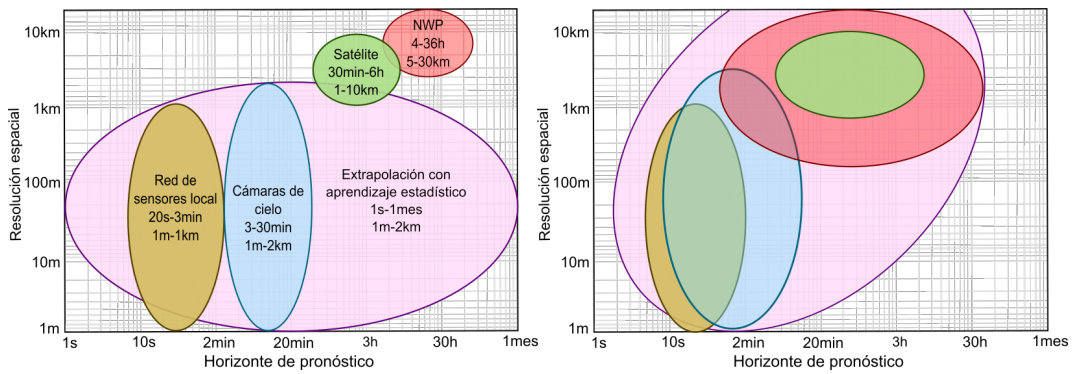
Los conceptos básicos y cálculos geométricos fundamentales de radiación solar se encuentran definidos y explicados al detalle en textos clásicos (Duffie & Beckman, 2013; Iqbal, 1983) y/o notas de cursos (Abal et al., 2020). Por tanto, aquí incluimos sólo un pequeño resumen en el Apéndice 1. Se utilizará fluidamente en lo que sigue magnitudes geométricas corrientes, como por ejemplo el coseno del ángulo cenital ($\cos \theta_z$), la altura y azimuth solar (α_s y γ_s , respectivamente), y otras variables como el índice de claridad (k_t) y el índice de cielo claro (k_c). El lector es referido al Apéndice 1 o a los textos mencionados por más detalles.

Esta tesis trabaja con predicciones de valores horarios y diarios, por lo que se utilizará en lo que sigue el término irradiación (energía radiativa incidente en un intervalo de tiempo) solar, abreviado por GHI y denotado en forma general por G_h .

2.1. Técnicas de predicción solar

El pronóstico de la energía solar busca anticipar el comportamiento futuro de la irradiación solar. En la literatura científica del área se pueden encontrar trabajos de predicción haciendo uso de enfoques físicos, estadísticos e híbridos, y con diferente información base para generar las predicciones. La relación entre la resolución espacial y horizontes de pronóstico alcanzables por las predicciones, divide las técnicas de pronóstico en cuatro grandes grupos: cámaras todo-cielo, imágenes satelitales, técnicas de aprendizaje automático o series temporales, y pronóstico por modelos numéricos de la atmósfera (Diagne et al., 2013; Inman et al., 2013). Las experiencias y avances en el área han posibilitado una actualización en la percepción de la escala espacio-temporal de estas diferentes técnicas. Yang et al. (2022) resume estos avances de manera gráfica conforme se muestra en la Figura 2.1. El cambio más notable se observa en los métodos de aprendizaje estadístico y aprendizaje automático, que actualmente funcionan como herramientas de mejora y post-procesamiento. Además los modelos numéricos de la atmósfera (NWP, Numerical Weather Predict)

de muy alta resolución han ganado competitividad en la predicción de horizontes temporales más cortos y áreas de interés más extensas.



(a) Propuesta de Inman et al. (2013). (b) Propuesta actualizada por Yang et al. (2022).

Figura 2.1: Relación entre horizonte temporal de pronóstico y resolución espacial. Adaptado de Yang et al. (2022).

Los modelos NWP es el objeto principal de esta tesis, por esto las demás técnicas se describen a continuación brevemente como contexto de la predicción solar.

El pronóstico por cámaras de todo-cielo consiste en cámaras instaladas en tierra para predicción en sitios específicos. Las imágenes de alta resolución espacial y temporal (30 a 60 segundos) permiten observar la nubosidad desde la tierra y se aplican para la predicción a muy corto plazo, es decir, de escala minutil hasta 3 minutos hacia adelante, con funcionalidad para anticipar variaciones repentinas del recurso solar, también conocidos como eventos de rampa (Caldas & Alonso-Suárez, 2019; Chu et al., 2013; Marquez & Coimbra, 2013). Los avances y usos de esta técnica parecen ir por detrás de otros métodos tanto en la práctica como en la investigación, posiblemente por su complejidad, desempeño y su limitación al horizonte de pronóstico intra-horario (Feng et al., 2022).

La técnica de pronóstico por imágenes de satélite busca, a partir de una secuencia de imágenes anteriores (con resolución espacial de 0.5–1 km y cadencia temporal de 10–30 minutos), pronosticar las siguientes imágenes hacia el futuro. A partir de dos o tres imágenes consecutivas se estiman los vectores de movimiento de las nubes (CMV, Cloud Motion Vector). Dicha estimación se extrapola hacia el futuro para generar los pronósticos de nubosidad y GHI para las siguientes horas. Su aplicación es para pronósticos intradiarios que varían de 10 minutos hasta 6 horas hacia al futuro, horizontes que son de interés del operador del sistema eléctrico debido a la planificación horaria (Aicardi et al., 2022; Alonso-Suárez et al., 2021; Coimbra & Pedro, 2013; Giacosa, 2020; Kühnert et al., 2013; Lorenz et al., 2004;

Perez et al., 2010).

Las técnicas pronóstico por series temporales se basan en procedimientos estadísticos como modelos de series temporales o técnicas de aprendizaje automático. Éstas buscan aprender de la información histórica, como medidas en tierra, imágenes satelitales o información de otras fuentes de pronóstico, para generar hacia el futuro la predicción más probable (Das et al., 2018; Ghimire et al., 2019; Reikard, 2009). La información elegida como entrada para los modelos determina el alcance del horizonte temporal de pronóstico. Aunque estas técnicas son de sencilla implementación actual y presentan un buen desempeño local, pueden carecer de generalización espacial, debiendo ser ajustados para cada sitio específico (Qin et al., 2022).

Los modelos numéricos de la atmósfera (NWP, Numerical Weather Predict) describen el proceso de evolución futura de la atmósfera a partir de las ecuaciones físicas que gobiernan su dinámica. Estos modelos requieren como condiciones iniciales datos sobre el estado inicial de la atmósfera, generalmente obtenidos mediante estrategias de teledetección (datos medidos en redes de campo, sondeos atmosféricos, información satelital, etc.). La predicción de la irradiación solar a partir de los NWP presenta un desempeño destacado frente a otras técnicas de pronóstico para horizontes temporales superiores a las 4-5 horas en adelante, incluyendo algunos días en adelante (Antonanzas et al., 2016; Diagne et al., 2013; Perez et al., 2013). Estos horizontes temporales son útiles para la planificación diaria y semanal de la red eléctrica y también para el mercado de energía. Sin embargo, es de amplio conocimiento que los pronósticos más largos tienden a aumentar los errores, especialmente en condiciones climáticas inestables, y sus desvíos son aún elevados. Los NWP se clasifican en dos categorías según su escala espacial: globales y regionales. En la Sección 2.2 se describe con mayor profundidad estos modelos, presentando un resumen de su historia, algunos conceptos importantes y su clasificación según el dominio espacial.

2.2. Modelos numéricos de la atmósfera

La predicción por modelos numéricos es esencialmente un problema físico-matemático de condiciones iniciales. La historia de los modelos numéricos de la atmósfera empieza con el científico noruego Vilhelm Bjerknes, en el año de 1895, después de un estudio realizado por meteorólogo estadounidense Cleveland Abbe, donde propone a los científicos atmosféricos un enfoque de modelado matemático

de la predicción atmosférica. Desde un punto de vista científico, Bjerknes estableció el desarrollo de la técnica en dos etapas: diagnóstico y pronóstico. En la etapa de diagnóstico se determina el estado inicial de la atmósfera mediante observaciones. Inicialmente las variables evaluadas por Bjerknes fueron presión, temperatura, densidad, humedad y las tres componentes de la velocidad de viento. En la etapa de pronóstico se utilizan las leyes físicas para elaborar ecuaciones que relacionan dinámicamente estas variables y se utilizan para calcular como evolucionarán en el tiempo. Las ecuaciones identificadas por el autor fueron las ecuaciones hidrodinámicas de movimiento, la ecuación de continuidad, la ecuación de estado y una ecuación que involucra las leyes de la termodinámica. En la época el propio Bjerknes no veía viable sus ideas, ya que la solución propuesta implicaba resolver las ecuaciones a partir de un método cuantitativo gráfico, dado que no podía resolverlas numéricamente y la solución analítica era imposible. No obstante, fue basado en las ecuaciones desarrolladas por Bjerknes que años más tarde, en 1913, el científico inglés Lewis Fry Richardson, propuso una solución con un sistema de ecuaciones matemáticas resueltas numéricamente a partir del método de diferencias finitas (Richardson, 1922). Para esto, Richardson utilizó grillas para simular la evolución de las escalas sinópticas (patrones meteorológicos cuya escala excede los 2000 km). En resumen, el pronóstico de Richardson fue una versión precisa y detallada de la propuesta de Bjerknes (Lynch, 2008). Desafortunadamente, sus resultados fueron poco acertivos, desluciendo la verdadera importancia del trabajo, dado que en la época no era evidente la complejidad computacional de su propuesta. Aunque los resultados hayan por años desalentado los estudios con NWP, la propuesta de Richardson, hoy en día, es la base de la construcción del pronóstico a partir de modelos numéricos de la atmósfera.

A principio de los años 30, un matemático científico que emigró de Alemania llamado John von Neumann, llega a Estados Unidos y se incorpora al Instituto de Estudios Avanzados (IAS, Institute for Advanced Studies) de la Universidad de Princeton¹ (Macrae, 2019). Fue von Neumann junto a los meteorólogos Jule Charney y Agnar Fjørtoff que publicaron un artículo revolucionario informando la implementación del primer pronóstico de tiempo por computadora electrónica (Charney et al., 1950). Debido a las limitaciones de capacidad de cómputo de la época, los autores necesitaron aproximadamente 24 horas de cálculo para pronosticar un horizonte de 24 horas hacia adelante, es decir, solo pudieron seguir el ritmo de la

¹Una década después se tornó un importante consultor de proyectos gubernamentales, como por ejemplo: la bomba atómica y en el desarrollo de la primera computadora electrónica.

atmósfera. En un entorno operativo, las primeras predicciones numéricas fueron realizadas por el Centro Nacional Meteorológico de Washington (Shuman & Hovermale, 1968) y por el Met Office del Reino Unido, en los años de 1966 y 1972 respectivamente. El avance computacional y el desarrollo de varias áreas, como ejemplo, ciencias de la atmósfera, técnicas de observación y medida, entre otros, han permitido una amplia variedad de modelos numéricos operacionales que tratan de predecir los procesos físicos que ocurren en la atmósfera, todos basados en aprendizajes de estudios realizados en el pasado (Kalnay, 2002).

Los procesos físicos de la atmósfera se dividen en tres clases: (i) aquellos que ocurren en escalas más pequeñas que la resolución del modelo, pero que ejercen un efecto acumulativo que se observa en escalas resolubles, como por ejemplo, las nubes aisladas del tipo cumuliformes; (ii) aquellos que involucran intercambios de energía, agua y cantidad de movimiento entre la atmósfera y fuentes externas (por ejemplo, radiación solar y procesos superficiales terrestres y marinos) y (iii) microfísica de nubes y precipitaciones, que tienen como ejemplo la formación de cristales de hielo en nubes altas que pueden afectar la radiación solar absorbida y reflejada. Estos procesos son representados leyes de conservación aplicada a parcelas individuales del aire, que han sido presentadas y mejoradas paulatinamente en la literatura (Kalnay, 2002; Kurihara, 1965; Wang, 2021). Para representar y calcular las cantidades físicas involucradas, los NWP utilizan un sistema de grillas o mallas. Existen varias configuraciones de grillas que se muestran a continuación en la Figura 2.2.

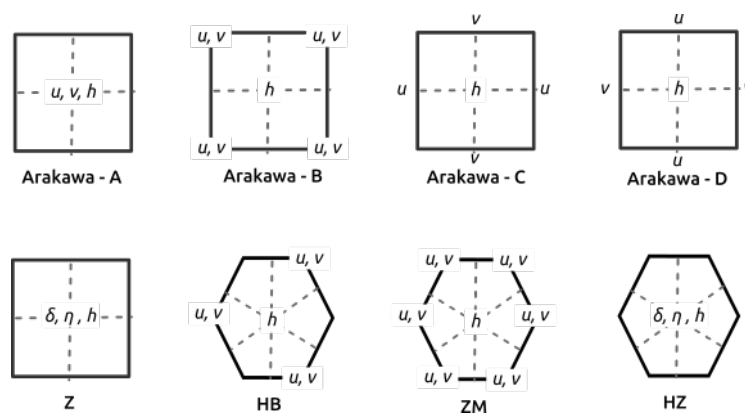


Figura 2.2: Clasificación de las grillas de NWP. Adaptado de Wang (2021).

En la Figura 2.2 se muestran las variables u (viento hacia el este), v (viento hacia el norte), h (coordenada en la vertical). Los distintos tipos de grillas se diferencian por la forma en que los modelos distribuyen los conjuntos de variables a pronosti-

car. Las grillas con todas variables de pronóstico concentradas en un mismo punto se denominan no-escalonadas (Arakawa–A, por ejemplo). Las grillas con las variables de pronóstico en más de un punto, se denominan como escalonadas (Arakawa–B, por ejemplo). Todas las configuraciones presentan sus ventajas y desventajas (Kalnay, 2002). En la grilla A por ejemplo, el principal beneficio es sencillez, debido a que todas las variables están disponibles en todos los puntos de la cuadrícula, pero su desventaja es que todas las diferencias ocurren en distancias $2d$, donde d es la distancia entre los puntos de cuadrícula más cercanos de la misma clase. En términos operativos la mayoría de los modelos de mesoescala no-hidrostáticos utilizan la Arakawa–C, que calcula las velocidades en el punto medio entre las celdas de la cuadrícula y h se calcula en las esquinas (o intersecciones de las celdas de la grilla). Por otro lado, la grilla Arakawa–D no ha sido adoptada en ninguno de los principales modelos conocidos porque no ofrece ningún beneficio adicional cuando comparado con la grilla C.

La estructura vertical de los modelos NWP tiene igual importancia que las grillas. Seleccionar un sistema de coordenadas adecuado para representar apropiadamente la estructura vertical de la atmósfera es fundamental, dado que su función es generar una representación escalonada de los distintos niveles en la atmósfera. La mayoría de los modelos operativos adoptan una estructura vertical discreta, es decir, los resultados pronosticados representan un promedio de una capa atmosférica entre las superficies de las coordenadas verticales. La resolución horizontal de los modelos numéricos está relacionada con la distancia entre los puntos de la grilla horizontal, y cuanto más cercanos uno del otro, mejor el modelo representará la atmósfera. La resolución vertical depende del número de capas cerca del suelo, y una mayor cantidad de capas permite identificar mejor los procesos de la superficie. El aumento de la resolución implica un aumento del costo computacional requerido para la ejecución del modelo. La potencia informática disponible limita la resolución de los modelos.

Algunos de los procesos importantes de la atmósfera, como por ejemplo la convección, la transferencia radiativa o la formación de nubes, ocurren en escalas menores que la resolución de los modelos globales actuales. Para resolver estos procesos, también conocidos como procesos sub-grilla, los modelos utilizan parametrizaciones. Las parametrizaciones son una forma de simplificar y aproximar los fenómenos físicos de menor escala (Milton & Wilson, 1996; Stensrud, 2007). En términos generales son divididas en cinco grupos: microfísica, cumulus, física de la superficie, física de la radiación atmosférica y física de la capa límite planetaria

(Skamarock et al., 2008).

La ejecución operacional de los modelos numéricos se divide en tres etapas generales: recolección de datos, análisis (asimilación) y pronóstico (Buizza, 2021). En el ciclo de recolección se recompilan los datos globales de diversas fuentes y también la salida del pronóstico anterior. Esta etapa juega un papel importante en la precisión del modelo, ya que mientras mayor es la cantidad y calidad de datos observados, mejor será la descripción del estado de la atmósfera actual y futuro (Collard et al., 2011; Daley, 1991; Kalnay, 2002). Una vez recompilada esta información, se realiza la etapa de análisis a partir de la técnica de asimilación de datos, encargada de estimar las condiciones iniciales que mejor representen el estado de los fenómenos atmosféricos de interés. A partir de estas estimaciones y utilizando modelos dinámicos, se generan los pronósticos. Este proceso es secuencial, se compara el pronóstico anterior con las observaciones recién recibidas, se actualiza el estado del modelo para reflejar las observaciones, se inicia un nuevo pronóstico y así sucesivamente. En resumen, a cada interacción un nuevo conjunto de información actualiza el estado inicial y mejora las predicciones. Estos pasos se repiten en intervalos regulares dos veces al día (00 y 12 UTC) o cuatro veces en el día (00, 06, 12, 18 UTC), dependiendo de la versión computacional de cada modelo.

2.2.1. Modelos globales

Los modelos globales pronostican el estado futuro de la atmósfera de todo el planeta, pudiendo generar pronósticos de hasta 16 días hacia el futuro con resolución espacial que varía entre 9-50 km y granularidad temporal horaria o tri-horaria. Debido a su complejidad y exigencia computacional, pocos centros meteorológicos en el mundo disponen de la capacidad para ejecutar en forma operativa este tipo de modelo. En la actualidad, son 15 los modelos globales operativos en el mundo, y no han crecido en la última década (Diagne et al., 2014; Visser et al., 2022). En la Tabla 2.1 se presenta algunos de los modelos operativos. Las principales características que los diferencian son la resolución espacial, parámetros de entrada, y lo más importante, los modelos físicos subyacentes.

La resolución espacial de algunos de los modelos globales puede variar según la región o el horizonte de pronóstico. La información brindada en la Tabla 2.1, abarca la resolución espacial nominal de los modelos, así como su proceso de inicialización y la frecuencia de las salidas pronosticadas, las cuales también muestran variaciones en función del modelo. Los modelos IFS, GFS, ICON, ARPEGE, y UM (siglas en

la Tabla 2.1), se inicializan cuatro veces al día (00, 06, 12, 18 UTC), mientras los modelos GEM, T639, SL y GSM se inicializan dos veces al día, a las 00 y 12 UTC y a las 06 y 18 UTC, respectivamente. Los modelos globales producen en general salidas pronosticadas cada 3 o 6 horas (Visser et al., 2022). El modelo IFS, también conocido como ECMWF, es el único que dispone de salidas horarias para un horizonte de hasta 3 días hacia adelante. En este trabajo, se opta por referirse a este modelo como ECMWF. En términos de utilización, los modelos globales ECMWF y GFS están entre los de mayor utilización en el mundo. El modelo ECMWF es actualmente el sistema de pronóstico global de mayor resolución espacial del mundo (Hólm et al., 2016).

Tabla 2.1: Modelos globales operativos en el mundo.

Modelo NWP	Organización	Resolución espacial (km)	Nivel vertical	Horizonte de pronóstico (días)
IFS (Integrated Forecast System)	European Centre for Medium-Range Weather Forecasts (ECMWF)	9	137	10
GFS, (Global Forecast System)	NOAA (USA)	28	127	16
ICON, (Icosahedral Nonhydrostatic)	DWD (Alemania)	13	90	7
GSM, (Global Spectral Model)	JMA (Japón)	20	128	5
GEM, (Global Environmental Multiscale Model)	CMC (Canada)	15	84	10
ARPEGE, (Action de Recherche Petite Echelle Grande Echelle)	Météo-France (Francia)	16	105	4
UM, (Unified Model)	MetOffice (Reino Unido)	25	70	6
T639	CMDC (China)	30	60	10
SL	GPC Moscú (Rusia)	23	51	5

Además de la predicción determinística (es decir, pronosticar el valor puntual futuro con la mayor precisión posible), algunos modelos globales asocian una aproximación probabilística a la predicción numérica, conocida como ensembles. Los ensembles son un conjunto de predicciones del modelo que se generan a partir de a partir de perturbaciones en las condiciones iniciales o en los propios modelos. Los pronósticos de este tipo se utilizan ampliamente para cuantificar las incertidumbres de los modelos (Li & Zhang, 2020). Todos los modelos de la Tabla 2.1 disponen de pronósticos con ensembles, y se diferencian por la técnica adoptada para la perturbación de las condiciones iniciales y por el número de miembros del conjunto de

pronóstico (Buizza et al., 2005).

2.2.2. Modelos regionales

Los modelos regionales simulan la evolución de la atmósfera en una parte del planeta con alta resolución espacial y horizontes temporales de hasta tres días hacia adelante, lo que resulta en un alto costo computacional. Los modelos regionales también son conocidos como modelos de área limitada (LAMs, Limited-Area Model) o de mesoescala. La resolución espacial de esta categoría de NWP puede llegar hasta 1 km, sin embargo, los servicios meteorológicos suelen operar modelos de mesoescala con una resolución espacial en el rango de 5 a 20 km (David & Lauret, 2018). La alta resolución es una ventaja de los modelos regionales, lo que les permite reproducir fenómenos de menor escala. Por otro lado, los modelos regionales no son autónomos ya que además de requerir condiciones iniciales, necesitan de información de contorno lateral en los límites del dominio horizontal para su funcionamiento. La precisión de las condiciones de contorno y de borde, restringen fuertemente en el desempeño de estos modelos (Kalnay, 2002). En general, esta información es proporcionada por las salidas pronosticadas por modelos globales utilizando una técnica (downscaling) que permite al modelo regional considerar los fenómenos que ocurren en baja resolución (escala global).

A diferencia de los modelos globales, en las últimas décadas varios centros meteorológicos han desarrollado sus propios modelos regionales (Dudhia, 2014). En el informe de la Organización Mundial de Meteorología se presenta el crecimiento continuo de esta categoría de NWP en el mundo, con más de noventa países ejecutando sus propios modelos regionales de pronóstico (WMO, 2020). Todos los centros meteorológicos mencionados en la Tabla 2.1 disponen de modelos regionales para sus países. Para Alemania está el ICON-D2 de la DWD. Para América del Norte están disponibles los modelos NAM (North American Mesoscale Model) y ETA (Eta-coordinate model) de la NOAA. Este último, es también utilizado en otras regiones del mundo, como por ejemplo, en Brasil por el Centro de Previsão de Tempo e Estudos Climáticos (CPTEC). El CPTEC también disponen del modelo regional propio, el BRAMS (Brazilian Regional Atmospheric Modeling System). Entre los más utilizados está el modelo WRF (Weather Research and Forecasting Model), desarrollado por el centro nacional de investigación en ciencia de la atmósfera del gobierno americano (NCEP/NCAR), en conjunto con otros institutos y universidades. El WRF es público y de código libre, lo que posibilita que una

gran comunidad de usuarios e investigadores estén continuamente mejorando esta herramienta (Diagne et al., 2013).

2.3. Métricas de desempeño

La ejecución de los modelos de predicción numérica del tiempo produce una gran cantidad de datos e información. Interpretar y evaluar la precisión de estos resultados es fundamental para identificar debilidades en la simulación de los procesos atmosféricos. Las métricas más comunes para cuantificar el desempeño del pronóstico determinístico de GHI derivan directamente de la diferencia entre las observaciones en tierra y las predicciones (Yang et al., 2018). Para medir el sesgo sistemático del modelo se utiliza el desvío medio (MBD). La dispersión del modelo, se cuantifica a partir del desvío medio absoluto (MAD) y del desvío cuadrático medio (RMSD), que se diferencian por las ponderaciones de los desvíos más elevados. Las métricas MBD, MAD y RMSD se definen en las Ecs. 2.1, 2.2, 2.3, respectivamente:

$$\text{MBD} = \frac{1}{N} \sum_{i=1}^N (\hat{y}(i) - y(i)), \quad (2.1)$$

$$\text{MAD} = \frac{1}{N} \sum_{i=1}^N |\hat{y}(i) - y(i)|, \quad (2.2)$$

$$\text{RMSD} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}(i) - y(i))^2}, \quad (2.3)$$

donde \hat{y} son los valores pronosticados, y son valores medidos en tierra, y N es la cantidad de muestras para la comparación. Los valores relativos de estas cantidades se expresan como un porcentaje del promedio de las medidas en tierra. Desde el punto de vista operacional, el RMSD es más sensible a grandes desvíos de la predicción, lo que lo hace más relevante para las aplicaciones de pronóstico con enfoque en el mercado energético y la gestión de la red (Lorenz et al., 2016).

Para cuantificar la ganancia de un modelo de predicción respecto a un modelo de referencia, que en este caso es la persistencia, se utiliza la habilidad de pronóstico (FS, Forecast Skill). Esta métrica se calcula a partir de la relación entre los RMSD del modelo de predicción y de la persistencia (Ec. 2.4). Su resultado permite intercomparar el desempeño de la predicción en diferentes sitios, ante condiciones distintas de variabilidad del recurso (Coimbra et al., 2013). El pronóstico perfecto

tiene un $FS = 1$. Un pronóstico con $FS \leq 0$ indica que su desempeño es igual o peor que el de la persistencia, y viceversa si $FS \geq 0$.

$$FS = 1 - \frac{RMSD_{for}}{RMSD_{per}} \quad (2.4)$$

La persistencia implica considerar que las condiciones atmosféricas se mantendrán aproximadamente estacionarias respecto al paso temporal anterior. Yang (2020) recomienda el uso de la persistencia del índice de cielo despejado. Los datos de cielo despejado de GHI ($G_{h,cks}$), necesarios para calcular los valores de este índice, provienen de modelos localmente implementados o de modelos disponibles para descarga en sitios especializados en internet. Aquí se utilizarán los datos de la irradiación de cielo claro proporcionada por el Servicio Copernicus de Monitoreo de la Atmósfera (CAM5), dado que se han establecido como el modelo de referencia para asistir estudios de predicción de la radiación solar (Lauret et al., 2022; Yang, 2020). Este servicio web proporciona estimaciones gratuitas de irradiación en cielo despejado, obtenidas por el modelo McClear (Lefèvre et al., 2013). Además, la precisión de este modelo es conocida en la región. En el estudio de Laguarda et al. (2020), se informó un rMBD del 1 % y un rRMSD de aproximadamente 3 %, valores similares a los encontrados en otro estudio realizado por (Lusi et al., 2023), donde se registró un rRMSD del 2 %. Finalmente, la persistencia se calcula como:

$$\hat{G}_h^{per}(t + \Delta t) = k_c(t) G_{h,cks}(t + \Delta t) \quad (2.5)$$

A escala diaria (para el valor de irradiación diaria) se supone que el índice de cielo despejado diario se mantiene constante respecto al día anterior. A escala intradiaria, como se trata de un pronóstico horario de 24 hs inicializado al principio del día, se toma el mismo valor hora a hora del día anterior. Esta consideración busca asegurar consistencia, teniendo en cuenta que esta información estará siempre disponible.

2.3.1. Matriz confusión

Las métricas mencionadas anteriormente permiten cuantificar la incertidumbre de modelos en pronosticar todas las condiciones de cielo. En cambio, la matriz confusión proporciona otro tipo de evaluación, que permite determinar cuántos eventos o clases fueron correctamente predichas y cuántos no. En el pronóstico de irradiación solar, estos eventos pueden estar relacionados, por ejemplo, con eventos de

rampa generados por la variabilidad del recurso solar (Erdener et al., 2022; Fabel et al., 2022; Logothetis et al., 2022).

La Figura 2.3 muestra un ejemplo de matriz confusión de tres clases (a, b, c). Las columnas representan las clases verdaderas, que pueden ser, por ejemplo, medidas en tierra, y las filas representan las clases predichas por un modelo de pronóstico. Las entradas del cuadro en la diagonal representan las predicciones establecidas correctamente en estas tres categorías conceptuales, mientras que los elementos fuera de la diagonal son errores de categorías pronosticadas. A partir de la matriz se pueden extraer cuatro características de la clasificación binaria (positivo/negativo) de cada clase: verdadero positivo, verdadero negativo, falso positivo y falso negativo. El verdadero positivo (VP) indica la cantidad de veces predichas correctamente, es decir, el modelo predijo como positiva y en la realidad es positiva. Un verdadero negativo (VN) es cuando el modelo y la realidad están de acuerdo que la clase no es verdadera. El falso positivo (FP) ocurre cuando el modelo predice como positiva y en la realidad es negativa. El falso negativo (FN) representa el número de veces que el modelo no identifica como positiva. Tomamos como ejemplo el caso de la “Clase a”, los verdaderos positivos son 5, los verdaderos negativos corresponden a 1093 (540+21+96+436), los falsos positivos son 40 (23+17) y los falsos negativos son 126 (10+116).

		ACTUAL			Total
		Clases	a	b	
PRONÓSTICO	a	5	23	17	45
	b	10	540	21	571
	c	116	96	436	648
	Total	131	659	474	1267

Figura 2.3: Ejemplo de una matriz confusión 3x3

Las métricas más comunes calculadas de estos valores son: la exactitud, la precisión, la recuperación y el F-Score (Congalton, 1991; Heydarian et al., 2022). En los casos de matriz confusión de clases múltiples, las métricas de precisión y el F-Score son las más utilizadas (Pereira et al., 2018). La precisión del modelo (A_{cc}) se define como el número de casos clasificados correctamente dividido por el número total de casos, que se calcula como muestra la Ec. 2.6.

$$A_{cc} = \frac{VP + VN}{VP + FN + FP + VN} \quad (2.6)$$

En casos donde las muestras no están balanceadas, como es el caso de la matriz confusión de la Figura 2.3, se recomienda el uso de la Ec. 2.7, que es la precisión balanceada (BA). La precisión balanceada es esencialmente un promedio de la tasa de verdaderos positivos (T_{VP}) de cada clase de la matriz confusión ($VP/(VP+FN)$), donde C es el número total de clases. En condiciones donde las muestras están equilibradas, los valores de la precisión y de la precisión equilibrada tienden a converger hacia el mismo valor (Grandini et al., 2020).

$$BA = \frac{1}{C} \sum_{i=1}^C T_{VP} \quad (2.7)$$

Por otro lado, la precisión balanceada representa bien un resultado siempre que las muestras tengan la misma importancia, de lo contrario, se puede dar más peso a las instancias procedentes de clases minoritarias y/o puede favorecer a la clase mayoritaria. La matriz confusión de la Figura 2.3 es un ejemplo de este tipo de caso. En situaciones como esta, se recomienda el uso de precisión balanceada ponderada (Gupta et al., 2020). En la precisión balanceada ponderada (BAW) se agrega una ponderación por la frecuencia de cada clase, conforme muestra la Ec. 2.8,

$$BAW = \frac{1}{N_p} \sum_g N_g BA_g \quad (2.8)$$

donde N_g es el número de muestras positivas en el g^{th} grupo y N_p es la suma de todos los N_g . Esta métrica determina la precisión global del modelo y permite conocer los rendimientos separados de las diferentes clases, de modo que podamos rastrear qué clase causa un desempeño deficiente (Grandini et al., 2020).

2.4. Desempeño de NWP para irradiación solar

Esta sección brinda una revisión del desempeño para irradiación solar de los modelos NWP reportados por distintos trabajos en la literatura. La evaluación de estos modelos tiende a estar concentrada en Europa y América del Norte, con algunos estudios en Sudamérica (Brasil y Uruguay). Cabe destacar que la presente tesis resulta un aporte significativo en la evaluación de modelos de este tipo en nuestra región, dados los pocos antecedentes que existen en nuestro continente. La Tabla 2.2 presenta un resumen de trabajos que evalúan el pronóstico de la GHI a partir de modelos numéricos y reportan un indicador común, el RMSD relativo. A pesar

de predecir la misma variable atmosférica, la irradiación solar en plano horizontal, cada estudio tiene su particularidad.

En el trabajo de Remund et al. (2008) se presenta una comparación de rendimiento del modelo global ECMWF con el modelo de mesoescala WRF, utilizando condiciones iniciales y de borde del GFS (configuración aquí nombrada como GFS+WRF), en tres sitios de los Estados Unidos (EE.UU). El rango de RMSD relativo representan la variabilidad intra-sitios. Los resultados mostraron que el modelo ECMWF tuvo un mejor rendimiento en todos los sitios evaluados. El desempeño del acumulado diario de las primeras 24h de pronóstico, reportaron un RMSD entre 18–40 % para el ECMWF y entre 18–50 % para el GFS. Cabe destacar, que los resultados obtenidos indican una fuerte dependencia del clima de cada sitio, en especial, del régimen de nubosidad local y su variabilidad, en el desempeño de los modelos evaluados.

Tabla 2.2: Review de desempeño de modelos NWP para pronóstico de la GHI.

Modelo	Localidad	Horizonte de pronóstico (días)	Escala de evaluación	RMSD (%)	Referencia
ECMWF	EE.UU	1	Diaria	18–40	Remund et al. (2008)
GFS+WRF	EE.UU	1	Diaria	18–50	
ECMWF	Francia	1	Diaria	29–42	Lauret et al. (2016)
GFS	Uruguay	1	Intra-diaria	27–39	Teixeira-Branco et al. (2022)
		1	Diaria	21–23	
GFS+WRF	Brasil	1	Diaria	21–67	Lima et al. (2016)
WRF-dudhia	Singapur	1	Intra-diaria	50	Verbois et al. (2018)
WRF-rrtmg				54	
WRF-solar				50	
GFS				56	
ECMWF	EE.UU	1-3	Diaria	21–45	Perez et al. (2013)
GEM	EE.UU	1-2		21–40	
WRF-AWS	EE.UU	1-2		25–59	
ECMWF	Canada	1-2		31–38	
GEM	Canada	1-2		31–38	
WRF-ASRC	Canada	1-2		40–45	
ECMWF	España	1-3		20–29	
WRF-UJAEN	España	1-3		25–30	
GEM	America del Norte	1-2	Horaria	25–35	Pelland et al. (2013)
GFS+WRF	Uruguay	1-2	Intra-diaria	39–46	Porrini (2017)
		1-2	Diaria	27–39	
GFS+WRF	España	1-3	Diaria	29–41	Lara-Fanego et al. (2012)
GFS+WRF	Uruguay	1-3	Diaria	30–36	Teixeira-Branco et al. (2018)
ECMWF	Uruguay	1-3	Intra-diaria	25–32	Teixeira-Branco et al. (2021)
		1-3	Diaria	17–21	

En un enfoque similar, Perez et al. (2013), presenta resultados comparando diferentes modelos numéricos de pronósticos, incluido los modelos globales ECMWF, GEM y distintas versiones de GFS+WRF (WRF-AWS, WRF-ASRC, WRF-UJAEN), en la región de EE.UU, Europa y Canadá. Los autores encontraron, al igual que Remund et al. (2008), que el desempeño de los modelos es variable en los sitios de EE.UU. En la Tabla 2.2 se muestran un resumen de los rangos de RMSD relativo en los diferentes sitios y diferentes horizontes evaluados. En particular, la incertidumbre del ECMWF puede variar un 24 % de un sitio para otro, mientras que la del GEM puede alcanzar un 19 % y la del WRF+GFS puede alcanzar hasta 34 %. Este mismo comportamiento no se observó en los sitios evaluados en España y Canadá, donde el RMSD varió un 9 % y 7 % entre sitios, respectivamente. En la Isla de Reunión (Francia), una región en el océano Índico con orografía compleja y numerosos microclimas, la incertidumbre variable entre los sitios también fue diagnosticada en la evaluación de las predicciones del ECMWF (Lauret et al., 2016). Dicho estudio, reporta que el RMSD del pronóstico integrado en el día oscila entre 29–42 % entre sitios. Los estudios presentados evidencian que la variabilidad de desempeño de los modelos está muy relacionado con las características climáticas y geográficas de cada región, por lo tanto deben siempre ser analizadas con detalle en diferentes sitios.

En Lara-Fanego et al. (2012) se evaluó el pronóstico de irradiación solar global con horizonte de tres días de antelación utilizando el modelo de mesoescala GFS+WRF para el sur de España. Los resultados incluyen el análisis anual, estacional y de diferentes condiciones de cielo (despejado, parcialmente nublado y nublado). Para los valores integrados diarios, se reporta una tendencia creciente de RMSD promedio entre los sitios con valores entre 29 % y 41 % para el horizonte de 1 a 3 días de antelación, respectivamente (Tabla 2.2). Los autores detectaron la dependencia estacional del modelo, que presenta mejor desempeño en el verano, seguido de la primavera. Los valores RMSD se incrementan con la nubosidad. Para condiciones de cielo despejado están por debajo del 20 %, para condiciones nubladas el RMSD se encuentra por encima de 100 %, y para cielo parcialmente nublado osciló entre 45–48 %. El modelo se mostró superior a la técnica de persistencia para las condiciones de cielo despejado y parcialmente nublado. Para condiciones nubladas el modelo es similar a la persistencia.

En Singapur, Verbois et al. (2018) evaluó el desempeño del modelo global GFS y de distintas versiones del modelo de mesoescala GFS+WRF en la predicción de la irradiación solar horaria del día siguiente. Los resultados demostraron que el

modelo WRF sin técnica de posproceso tuvo desempeño ligeramente superior al del GFS, con una ganancia máxima del 6 % para las versiones WRF-dudhia y WRF-solar (Tabla 2.2). En este contexto, los trabajos de Perez et al. (2013) y Remund et al. (2008) también destacaron el desempeño similar de los modelos globales (ECMWF y GEM) con el modelo de mesoescala (WRF+GFS). La ausencia de ganancia de desempeño se atribuye a las deficiencias en los esquemas físicos del modelo de mesoescala, así como a la necesidad de manejar las condiciones de contorno lateral en la inicialización de los modelos.

En Sudamérica, Lima et al. (2016) evaluó el desempeño de las primeras 24h de pronóstico del modelo GFS+WRF y varias técnicas de post-proceso para la región del Nordeste de Brasil, en temporada lluviosa y de sequía. Los resultados mostraron que en la temporada de lluvia el RMSD del modelo WRF varía entre 39–67 % y en temporada seca oscila entre 20–58 %, según la región (Tabla 2.2). Los resultados posterior al post-proceso demostraron la eficiencia de la técnica que disminuye cerca de 10 % la incertidumbre de las salidas del modelo.

En Uruguay, el primer acercamiento al pronóstico de la GHI a partir de modelos numéricos fue realizado por Porrini (2017) y Teixeira-Branco et al. (2018). En los dos trabajos se utilizaron el modelo de mesoescala GFS+WRF con diferentes parametrizaciones. Porrini (2017) proporciona una evaluación intra-diaria y diaria en temporadas de verano de los años de 2014-2017, con horizonte de hasta 2 días de antelación. Los rangos de RMSD relativo reportados en la Tabla 2.2 representan la variabilidad entre los sitios evaluados. Los resultados previos al post-proceso reportó el rRMSD intra-horario cerca del mediodía solar en torno a 27–33 % para el día 1 y 32–39 % para el día 2 de pronóstico. El rRMSD del acumulado diario oscilaron entre 27–33 % para el día 1 y variaron entre 32–39 % para el día 2 de pronóstico. Teixeira-Branco et al. (2018) brinda el análisis con solo un año de pronóstico del acumulado diario del día 1 de pronóstico. El RMSD encontrado es similar a lo reportado por Porrini (2017) para el día 1 de pronóstico, con valor entre 30–36 % (Tabla 2.2). A pesar de las diferentes configuraciones y periodo de análisis, los resultados fueron similares en estos estudios. Además ambos indican que no observan una dependencia estacional en el desempeño del modelo en la región. Sin embargo, se requiere una mayor profundización en esta discusión para poder llegar a conclusiones más sólidas.

La primera evaluación de un modelo global en la región se realizó por Teixeira-Branco et al. (2021), que evaluó el desempeño del ECMWF con horizonte de tres días de antelación en diferentes sitios de Uruguay. El modelo presentó un mejor

desempeño en las horas centrales del día, con RMSD que oscilaron entre 25 % y 32 % (Tabla 2.2). La evaluación del acumulado diario de cada día pronosticado reportó un RMSD entre 17 % y 21 % con una tendencia creciente para los horizontes hasta tres días de antelación. Estos resultados demostraron el mejor desempeño del ECMWF cuando comparados con otro estudio que evaluó el desempeño del modelo GFS en la misma región y encontró un rRMSD de 21–23 % (Teixeira-Branco et al., 2022). La realización de esta tesis permite ampliar y profundizar la discusión acerca de la predicción de radiación solar a partir de modelos numéricos de atmósfera nuestra región.

Capítulo 3

Base de información

Los datos utilizados en este trabajo se dividen en dos categorías: (i) medidas en superficie de irradiancia solar global en plano horizontal de calidad controlada y (ii) salidas de pronósticos de GHI de diferentes modelos numéricos de atmósfera del tipo global. En la Sección 3.1 se brinda información sobre los sitios de medida y los datos utilizados en este estudio. La Sección 3.2 describe los diferentes modelos de pronóstico evaluados. Por último, la Sección 3.3 describe las características del conjunto de datos utilizados en esta tesis.

3.1. Medidas en tierra

Las observaciones de referencia para este trabajo son medidas de irradiancia solar global en plano horizontal realizadas en tierra. Los sitios utilizados están distribuidos en localidades rurales o semi-rurales del territorio uruguayo y forman parte de la red nacional de medida administrada por el LES (<http://les.edu.uy/>) conforme muestra la Tabla 3.1.

Tabla 3.1: Ubicación de las estaciones de medida en tierra utilizadas.

Sitio	Cod	Lat. (deg)	Lon. (deg)	Alt (m)
Salto	LE	-31.28	-57.92	42
Artigas	AR	-30.40	-56.51	136
Tacuarembó	TA	-31.71	-55.83	140
Canelones	LB	-34.67	-56.34	32
Rocha	RC	-34.49	-56.17	24
Colonia	ZU	-34.34	-57.69	81
Treinta y Tres	PP	-33.26	-54.49	58

El clima en la región se caracteriza como templado y húmedo, y según la clasifi-

cación actualizada de Köppen Geiger pertenece a la clase Cfa (Peel et al., 2007). En lo que se refiere a la intermitencia a corto plazo del recurso solar, la región presenta una variabilidad solar intermedia (Alonso-Suárez et al., 2020).

Las estaciones de medida están equipadas con piranómetros Kipp & Zonen de clase A o B según la norma ISO 9060:2018. Estos equipos son calibrados a cada dos años bajo la norma ISO-9847:1992, contra un estándar secundario con trazabilidad al patrón primario mundial en el World Radiation Center (Davos, Suiza). En lo que se refiere a mantenimiento, la estación LE recibe mantenimiento semanal por estar en las instalaciones del LES, en Salto. Los demás sitios de medida, reciben mantenimiento mensual por personal en sitio, rondas de mantenimiento anual o bi-anual por personal experto, o visitas esporádicas cuando se detectan fallas en las medidas. Los adquirentes registran las medidas en un intervalo de 1 minuto como promedio de medidas instantáneas cada 15 segundos, a partir de las cuales se calculan los promedios horarios. En condiciones óptimas de operación y mantenimiento, la incertidumbre asignada por el fabricante a los equipos que se utilizan es del 2–3 % en escala diaria. Dado el mantenimiento de rutina mensual y inspecciones periódicas a los sitios de medición, se asigna una incertidumbre efectiva ligeramente mayor, entre 4–5 % (Laguarda et al., 2020). Este valor es significativamente menor que la incertidumbre del pronóstico a evaluar.

Se utilizaron tres años de medidas de GHI registradas en los siete sitios de la Tabla 3.1. El control de calidad de las medidas se realiza a partir de chequeos básicos basados en el índice de claridad y filtros de la BSRN (Baseline Surface Radiation Network). En la Figura 3.1 se presenta información horaria de la estación de Salto en el periodo de 01/2017 hasta 12/2020.

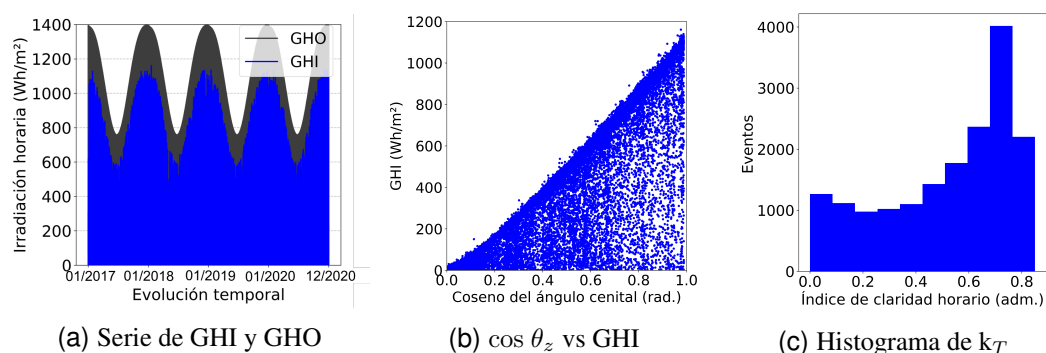


Figura 3.1: Datos horarios de la estación LE (01/2017–12/2020).

La Figura 3.1a muestra la evolución temporal de GHI medido en tierra (en azul) y la irradiación que incide en un plano horizontal en el tope de la atmósfera (GHO,

en negro), calculada a partir de la definición del Apéndice 1. La relación entre la medida de GHI y el coseno del ángulo cenital se muestra en 3.1b. Por ultimo, en la Figura 3.1c se presenta el histograma eventos del índice de claridad, definido en el Apéndice 1. En la observación de los diagramas correspondientes a cada sitio, se tiene que las muestras, luego de aplicar los controles de calidad, presentan un comportamiento cualitativo satisfactorio. La cantidad de datos validos se presentan más adelante en este capítulo.

3.2. Modelos numéricos utilizados

En esta sección se presentan las características básicas de los modelos, que aquí se consideran: la hora de inicialización, el horizonte de pronóstico y el paso temporal de predicción. Las características específicas de los modelos se detallan en forma separada en las sub-secciones siguientes. Éstas abarcarán la resolución del modelo y la metodología de predicción de la GHI.

La Tabla 3.2 presenta un resumen de la configuración de los NWP utilizados, siendo estos: ECMWF, GFS en dos resoluciones distintas, ICON y el NEMS30.

Tabla 3.2: Resumen de la configuración de los modelos de pronóstico utilizados.

Característica	ECMWF	ICON	GFS		NEMS30
			0.5°	0.25°	
Resolución espacial	~14 km	~13 km	~55 km	~27 km	~30 km
Nivel vertical	137	90	64	64	60
Modelo de transferencia radiativa	ecRad	RRTMG	RRTMG_SW (v2.3)		–
Nombre de la variable GHI	SSRD	ASOB_S	DSWRF		–
Paso temporal de la predicción	1 h	3 h	3 h		1 h
Periodo de estudio	2017–2019	2018–2020	2017–2019		2017–2019

En este estudio los modelos utilizados se inicializan a las 00 UTC y se evalúa el horizonte de pronóstico de las primeras 24 horas. Sin embargo, existen diferencias en los pasos temporales de las salidas de las predicciones de cada modelo. Los modelos ICON, GFS–0.5° y GFS–0.25° tienen de pronósticos tri-horarios, mientras que los modelos ECMWF y NEMS30 tienen salidas horarias (Tabla 3.2).

Los pronósticos con intervalos de 3h se interpolan a partir de las recomendaciones de Verzijlbergh et al. (2015), que utiliza las estimaciones de cielo despejado ($G_{h,cks}$) proporcionada por el modelo McClear (Lefèvre et al., 2013) y descargadas de la web del CAMS. A partir de esta información, se calcula el índice de cielo despejado cada 3 horas, $\langle k_c \rangle_{3h}$, que se utilizará como objeto de la interpolación. El índice se define como:

$$\langle k_c \rangle_{3h} = \frac{\langle G_{h,for} \rangle_{3h}}{\langle G_{h,cks} \rangle_{3h}}, \quad (3.1)$$

donde $\langle G_{h,for} \rangle_{3h}$ es la salida del pronóstico cada 3h y $\langle G_{h,cks} \rangle_{3h}$ es la irradiancia de cielo claro instantánea cada 3h. Luego, se aplica la interpolación lineal simple en el índice de cielo despejado, debido a que en esta variable no están presentes las dependencias geométricas que tiene la irradiancia solar. A partir del índice de cielo despejado horario, $\langle k_c \rangle_{1h}$, se calcula la irradiancia promedio horaria como:

$$\langle G_{h,for} \rangle_{1h} = \langle k_c \rangle_{1h} \langle G_{h,cks} \rangle_{1h} \quad (3.2)$$

La Figura 3.2 muestra tres días seleccionados de la predicción horaria de los diferentes modelos evaluados, junto con la medida de GHI en la estación LE.




Figura 3.2: Serie temporal diaria de GHI pronosticada por los modelos globales para días seleccionados.

Las características específicas de cada modelo y el comportamiento característico del periodo pronosticado se detallan en las subsecciones siguientes.

3.2.1. ECMWF

El modelo ECMWF, desarrollado por el Centro Europeo de Pronósticos Meteorológicos a Medio Plazo¹, actualmente es uno de los modelos con mejor desempeño

¹Es una organización intergubernamental independiente respaldada por 35 países. El ECMWF es a la vez un instituto de investigación y un servicio operacional que produce y difunde predicciones meteorológicas numéricas a sus países miembros y ofrece un catálogo de datos de pronóstico que pueden comprar empresas de todo el mundo y otros clientes comerciales.

en el mundo (Sianturi et al., 2021). Se trata de un modelo no-hidrostático, lo que significa que puede considerar las variaciones de presión en la vertical, con una mayor resolución. Esta característica permite aumentar la precisión en la simulación de la influencia del terreno en las condiciones climáticas, mejorar la eficacia en la predicción procesos de escala pequeña, aunque conlleva un incremento en el tiempo de ejecución. Sus pronósticos, a pesar de ser de acceso restringido, se generan para todo el mundo con resolución espacial nominal de 0.125° , tanto en latitud como en longitud, y resolución temporal de 1h para los primeros 4 días de pronóstico, y luego de 3h para los días 5 a 10 de pronóstico. En esta tesis se evalúa el primer día de pronóstico, en los años de 2017–2019. La resolución espacial en nuestra región es de aproximadamente 14 km.

Específicamente para la predicción de la radiación solar, el modelo ECMWF se refiere a GHI como el producto “SSRD” (en inglés, Surface Solar Radiation Downward), disponible dos veces al día, 00 y 12 UTC. Las predicciones son generadas por el modelo de transferencia radioativa denominado “ecRad” (Tabla 3.2). Este modelo entró en funcionamiento en el año 2017 y cuenta con avances importantes como propiedades ópticas de gas muy precisas en onda corta y en onda larga del modelo de transferencia radiativa rápida para modelos de circulación general (RRTM-G), la aproximación de columna independiente de Monte Carlo (McICA) para el tratamiento eficiente de nubes y la reducción del tiempo de ejecución en 31 % debido al uso de estrategias de cómputo avanzadas. Más información sobre las bases del funcionamiento del modelo operativo está documentado en Hogan y Bozzo (2018).

3.2.2. GFS

El modelo GFS fue desarrollado por NCEP (en inglés, National Centers for Environmental Prediction) y es administrado por el gobierno de EE.UU a través de la NOAA (en inglés, National Oceanic and Atmospheric Administration). El GFS es un modelo hidrostático, es decir, asume que la aceleración vertical debido a la gravedad y la variación de la presión son equilibradas, lo que simplifica las ecuaciones. Esta característica se traduce en un menor tiempo de ejecución, pero al mismo tiempo, implica una representación menos precisa de la topografía del terreno, lo que como consecuencia, afecta negativamente la capacidad de predecir fenómenos atmosféricos locales. Sus pronósticos globales están disponibles gratuitamente cada 6 horas (00, 06, 12, 18 UTC) para horizontes de pronóstico tri-horarios desde 3

hasta 180 horas hacia el futuro. El GFS dispone de resolución espacial de 1° , 0.5° y 0.25° . En esta tesis se evalúan las primeras 24h del pronóstico de la GHI con resolución de 0.5 y 0.25 grados, inicializado a las 00 UTC (Tabla 3.2). Recientemente, el GFS pasó por una importante actualización en los niveles verticales, que antes eran de 64 capas, y desde febrero de 2021, pasaron a ser 127 capas verticales. El periodo de análisis de la tesis, enero de 2017 hasta diciembre de 2019, no contempla esta actualización del modelo.

El producto que define la GHI en el modelo GFS es denominado “DSWRF” (en inglés, Downward Short-Wave Radiation Flux). Los pronósticos de la variable se generan con el modelo de transferencia radiativa rápida para modelos de circulación general, “RRTMG_SW v2.3”, conforme muestra la Tabla 3.2. Este modelo se origina del modelo RRTM desarrollado por Mlawer et al. (1997) para radiación de onda larga (LW) y onda corta (SW). Después de sucesivas mejoras y adaptaciones han llegado en la versión actualmente utilizada por el GFS (Clough et al., 2005; Iacono et al., 2008; Iacono et al., 2000). En otras palabras, el modelo RRTM se ha modificado para producir el RRTMG. Los dos modelos comparten la misma física básica y coeficientes de absorción, con la diferencia que el RRTMG incorpora varias modificaciones para mejorar la eficiencia computacional, actualizar el formato del código para una aplicación más sencilla a los modelos de circulación general (GCM) y representar la variabilidad de la nube a escala de subcuadrícula (Iacono et al., 2008).

3.2.3. ICON

El modelo ICON forma parte del conjunto de modelos del servicio meteorológico nacional alemán (DWD, Deutscher Wetterdienst). Al igual que el GFS, el ICON es un modelo hidrostático y sus pronósticos están disponibles gratuitamente. Su resolución espacial es de 13 km, y en la vertical define 90 niveles atmosféricos. La ejecución del modelo se realiza cuatro ejecuciones en el día (00, 06, 12 y 18 UTC), con pronósticos de hasta 180 horas de antelación. En este estudio se evalúa las primeras 24h del pronóstico tri-horario del modelo ejecutado a las 00 UTC en el periodo de enero de 2018 hasta diciembre de 2020.

La variable GHI pronosticada por el ICON se define como producto “ASOB_S” y se obtiene a partir del modelo RRTMG (Clough et al., 2005; Iacono et al., 2008; Iacono et al., 2000; Mlawer et al., 1997), conforme muestra la Tabla 3.2. En una reciente actualización, operativa desde abril de 2021, el modelo ICON pasó a

utilizar el esquema de transferencia radioactiva del ECMWF (“ecRad”). Un reporte con la implementación de esta nueva versión se realiza por Rieger et al. (2019). Dicha actualización no influencia el período utilizado en esta tesis.

3.2.4. NEMS30

El modelo NEMS30, es un modelo meteorológico de dominio global de la empresa Meteoblue¹. El modelo se basa en la tecnología NMM con mejoras y desarrollos patentados por la empresa. La tecnología NMM (en inglés, Nonhydrostatic Multiscale Model) fue desarrollada por la NOAA y se utiliza en el marco del NEMS (en inglés, Environmental Modeling System). El NEMS es un modelo totalmente acoplado capaz de predecir fenómenos en una variedad de escalas de tiempo. En otras palabras, el NEMS dispone de infraestructura que posibilita la comunicación y el intercambio de información entre modelos. Esta característica permite que el modelo ejecute múltiples escalas, desde dominios globales hasta locales. En Meteoblue (2011) se ha documentado que los modelos NMM y NEMS en dominio local presentan mejoras significativas en sus esquemas de nubes y precipitaciones en comparación con el modelo WRF.

En esta tesis el análisis del NEMS30 tiene motivación local, dado que los pronósticos de Meteoblue son contratados por la Administración del Mercado Eléctrico de Uruguay. Los pronósticos evaluados se obtuvieron a partir de colaboración científica con Meteoblue. La resolución espacial del NEMS30 es de 30 km, con 60 niveles verticales atmosféricos y resolución temporal de 1h. El horizonte temporal evaluado fueron las primeras 24h, en el periodo de tres años (2017–2019). Para más información acerca del modelo, se recomienda acceder al reporte técnico de la empresa, disponible en: <https://docs.meteoblue.com/en/meteo/data-sources/datasets#nems>.

3.3. Característica de los datos

Los datos utilizados en la evaluación de desempeño de los modelos globales corresponden al periodo de tres años completos. El periodo analizado de los modelos ECMWF, GFS-0.5 y GFS-0.25 y NEMS30 es desde enero de 2017 hasta el diciembre de 2019, mientras que para el ICON se analiza el periodo desde enero de 2018 hasta diciembre de 2020. En la Tabla 3.3 y la Tabla 3.4 brinda la misma

¹<https://content.meteoblue.com/en>

información para los dos períodos involucrados. En la primera columna se presenta la media horaria de GHI medida en tierra, y en las columnas siguientes la cantidad de datos diurnos disponibles y la media horaria de GHI para cada modelo, en cada sitio para este periodo. Se consideran validos los datos medidos que pasaron por el control de calidad y los datos con altura solar mínima de $\alpha_s > 3^\circ$ (o $\cos \theta_z > 0.05$). Esta condición elimina el error coseno que se produce con la disminución de la intensidad de la radiación solar al incidir en ángulos oblicuos sobre los instrumentos de medición, especialmente al inicio y al final del día. Se brindan estos datos como contexto general. En particular, interesa observar que la media de las medidas varía en menos de un 2 % entre ambos periodos considerados.

Tabla 3.3: Promedio horario de GHI medida y pronosticada de 01/2017–12/2019.

Cod.	Medida	ECMWF		GFS-0.5		GFS-0.25		NEMS30	
	Wh/m ²	horas	Wh/m ²	horas	Wh/m ²	horas	Wh/m ²	horas	Wh/m ²
LE	411.1	12671	406.4	12664	430.0	12696	441.5	12699	410.0
AR	417.8	12623	412.9	12619	435.2	12648	444.3	12651	409.0
TA	407.1	12530	404.3	12525	429.7	12555	436.5	12558	396.5
LB	403.1	12527	405.6	12520	419.4	12552	427.0	12555	393.6
RC	393.7	12425	393.7	12418	416.0	12450	423.9	12453	380.5
ZU	407.5	12602	416.6	12595	418.5	12627	431.9	12630	400.2
PP	403.6	12419	398.1	12411	418.5	12444	434.3	12447	389.3
prom.	406.3	–	405.4	–	423.9	–	434.2	–	397.0

Tabla 3.4: Promedio horario de GHI medida y pronosticada de 01/2018–12/2020.

Cod.	Medida	ICON	
	Wh/m ²	horas	Wh/m ²
LE	421.3	12608	430.9
AR	425.5	12561	439.8
TA	415.5	12466	433.6
LB	409.9	12463	436.6
RC	390.0	12364	422.7
ZU	420.1	12541	437.2
PP	408.0	12358	425.8
prom.	412.9	–	432.4

Analizando con más detalle los promedios entre los sitios de GHI horario, se observa que los valores de los pronósticos son similares a los valores medidos en tierra, independiente del período evaluado (Tabla 3.3 y la Tabla 3.4). El modelo ECMWF es el modelo que más se acerca al promedio de la medida en tierra, con una diferencia muy pequeña hacia la subestimación de aproximadamente 0.9 Wh/m². El NEMS30 también presenta valores por debajo del promedio de la medida, pero

de mayor entidad, cerca de 9.3 Wh/m^2 . En forma diferente, los modelos GFS-0.5, GFS-0.25, e ICON presentan valores medios superiores, correspondiente a sobreestimaciones de mayor valor absoluto que las anteriores, de 17.6 Wh/m^2 , 27.9 Wh/m^2 y 19.5 Wh/m^2 , respectivamente.

El pronóstico diario del primer día de GHI se construye a partir del acumulado de las primeras 24h de predicción. La Tabla 3.5 presenta la cantidad de días validos en cada modelo y sitio. Se observa que el número de muestras es similar entre los sitios y los modelos, independientemente del período considerado, lo que demuestra que la estadística utilizada es razonablemente uniforme.

Tabla 3.5: Cantidad de días evaluados.


	LE días	AR días	TA días	LB días	RC días	ZU días	PP días
Período 01/2017–12/2019							
Medida	1074	1016	1089	1089	1083	1087	1080
ECMWF	1073	1014	1087	1087	1081	1085	1078
GFS-0.5	1071	1013	1086	1086	1080	1084	1078
GFS-0.25	1074	1016	1089	1089	1083	1087	1080
NEMS30	1074	1016	1089	1089	1083	1087	1080
Período 01/2018–12/2020							
Medida	1079	995	1091	1090	1017	1086	1091
ICON	1073	988	1085	1084	1011	1080	1085

La Tabla 3.6 presenta los promedios mensuales de GHI medidos y pronosticados por cada modelo durante los periodos evaluados. Los valores obtenidos corresponden al promedio entre los diferentes sitios. La conocida estacionalidad de la GHI se observa claramente para todos los modelos y ambos periodos. Se observa que las predicciones están en mejor acuerdo en los meses de junio y julio, y las diferencias crecen hacia el verano. En estos períodos, las máximas diferencias en las mediciones alcanzan un cerca de 9.0% en diciembre (modelo GFS-0.25) y aproximadamente 4.0% en julio (modelo GFS-0.5).

La coherencia de los datos de la Tabla 3.6, se muestra en las graficas de Figura 3.3, la cual contrasta dicha información con la estacionalidad mensual en Uruguay reportada en el Mapa Solar Versión 2 (MSUv2) según Alonso-Suárez et al. (2014). La comparación realizada en la Figura 3.3, no muestra ninguna anomalía cualitativa apreciable en los datos medidos y pronosticados por los diferentes modelos. Se observa la diferencia entre la medida y el mapa solar en los meses de verano. Esto puede atribuirse a la característica de elaboración del mapa solar, el cual se construyó a partir de un histórico de estimaciones de más de 15 años en la región.

Tabla 3.6: Estacionalidad de la GHI en los sitios de estudio (en MJ/m²).

	Mes del año											
	ene	feb	mar	abr	may	jun	jul	ago	set	oct	nov	dic
Período 01/2017–12/2019												
Medida	23.9	23.1	19.3	13.5	8.8	8.4	8.4	11.8	15.1	19.1	24.8	26.3
ECMWF	24.3	22.9	18.7	13.4	9.2	8.5	8.4	11.6	14.7	18.9	25.0	26.4
GFS-0.5	25.6	24.5	20.2	14.1	9.3	8.5	8.1	12.1	15.3	20.1	25.9	27.1
GFS-0.25	26.2	24.9	20.7	14.5	9.7	8.8	8.5	12.5	15.9	20.6	26.2	27.7
NEMS30	22.8	22.0	18.6	13.4	9.2	8.8	8.4	12.1	14.6	18.4	24.3	25.3
Período 01/2018–12/2020												
Medida	24.3	24.3	19.3	13.7	9.6	7.9	8.6	12.2	16.2	19.5	24.6	26.6
ICON	25.6	25.6	20.1	14.4	10.0	8.2	8.4	12.4	16.5	20.5	26.1	27.9



(a) Periodo 01/2017–12/2019

(b) Periodo 01/2018–12/2020

Figura 3.3: Estacionalidad mensual de GHI medida y pronosticada.

Capítulo 4

Evaluación del pronóstico intra-diario

En este capítulo se presenta la descripción y discusión de los resultados de la evaluación anual y estacional del pronóstico intra-diario. Los indicadores aquí presentados se refieren al valor promedio entre los sitios, ya que no se ha observado una variación significativa en el desempeño entre ellos a nivel espacial. Para conocer los indicadores de desempeño de cada sitio, se pueden consultar los detalles en el Anexo 1. Para la evaluación de desempeño se utilizaron datos donde la medida de referencia y la predicción estén ambas disponibles. En esta tesis no se aplicaron técnicas de post-proceso de los pronósticos, por lo que existe margen para disminuir la incertidumbre las predicciones. La Sección 4.1 presenta los resultados anuales de la evaluación de tres años completos de pronóstico. Algunos de los resultados reportados también se encuentran publicados en Teixeira-Branco et al. (2022) y Teixeira-Branco et al. (2021). La Sección 4.2 brinda la información sobre el desempeño de los modelos en diferentes estaciones del año, utilizando datos del mismo período de tres años de pronóstico.

4.1. Periodo anual

En la Tabla 4.1 se presenta el valor promedio de GHI que corresponde a la media de las medidas tomadas en distintos sitios para cada hora del día. Este promedio se representa visualmente en la línea continua de la Figura 4.1, mientras que la banda transparente refleja la variabilidad de esta media entre los sitios, expresada a través de la desviación estándar. La Figura 4.1 & Tabla 4.1 muestran que los valores

promedios son muy similares en ambos periodos, presentando mayor variabilidad intra-sitios durante las horas centrales del día. La dispersión máxima encontrada es de 23.5 Wh/m² en los años 2017–2019 y un 29.1 Wh/m² en el período entre 2018–2020.

Hora Local	GHI promedio (en Wh/m ²)	
	2017-2019	2018-2020
7	156.3	158.4
8	238.9	241.8
9	386.6	392.2
10	512.4	520.3
11	598.2	608.0
12	634.5	644.0
13	619.1	627.7
14	555.3	563.3
15	452.7	459.9
16	315.3	319.6
17	186.4	189.0
18	114.2	116.4




Figura 4.1 & Tabla 4.1: GHI promedio en cada hora del día.

La Figura 4.2 presenta los gráficos de dispersión de los modelos de pronóstico evaluados, en azul, junto a la persistencia a escala horaria, en verde, para la estación de Salto. En la diagonal principal, en rojo, está representado el pronóstico perfecto ($x = y$). Las gráficas de dispersión de la técnica de persistencia por separado se encuentran en el Anexo 1.




Figura 4.2: Dispersión horaria de los modelos NWP y de la persistencia (estación LE).

La evaluación de desempeño horario del pronóstico del día siguiente de los mo-

delos globales y de la persistencia para cada hora de predicción, están resumidos en la Figura 4.3 a partir de los indicadores MBD, MAD y el RMSD (en términos absolutos y relativos). En la Figura 4.3 se trazan las métricas de desempeño contra el horizonte de pronóstico en horas (eje x inferior) u hora local (eje x superior). La línea continua representa el desempeño promedio entre los sitios evaluados y el área en transparencia representa la desviación estándar de los mismos. El desempeño en cada sitio, en términos relativos, se han normalizado respecto a la media de la medida de GHI en la hora correspondiente. El desempeño de los modelos globales se mostraron superiores a la persistencia en términos de MAD y RMSD, como se esperaba. Las horas centrales del día reportan los mejores indicadores de los modelos. Por otro lado, el sesgo sistemático de la persistencia se mantiene estable hacia a subestimación, pero muy cercano a cero, y presenta un ligero aumento a lo largo del día.

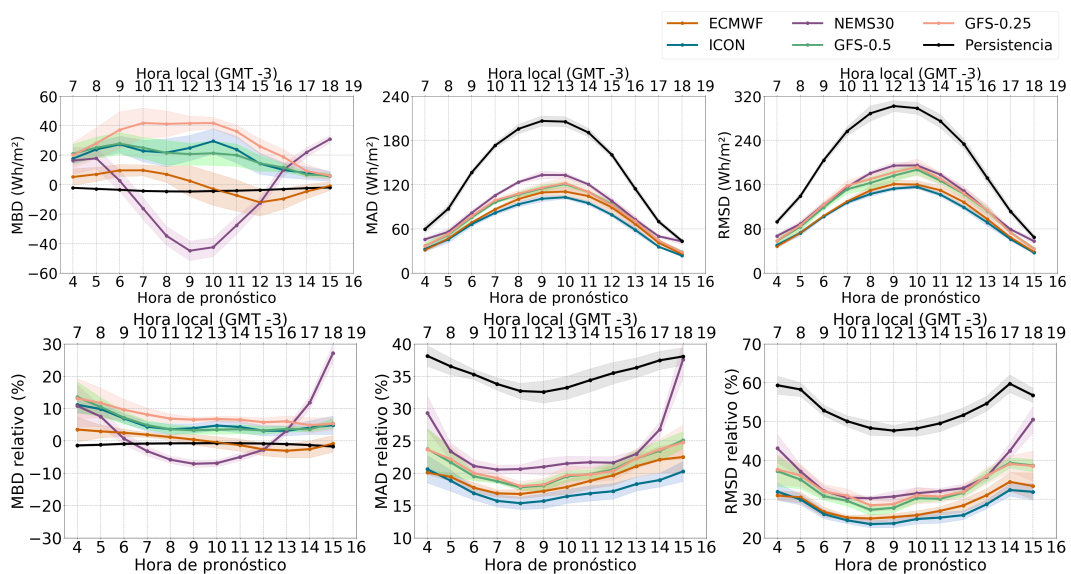


Figura 4.3: Métricas de desempeño intra-diaro del pronóstico del día siguiente (de izquierda a derecha MBD, MAD, RMSD). Panel superior: valores absolutos. Panel inferior: valores relativos.

La Tabla 4.2 presenta en términos relativos los indicadores de desempeño promedio entre los sitios en las horas del día. Para conocer los valores absolutos, se pueden consultar los detalles en el Anexo 1. El modelo NEMS30 presenta un sesgo negativo durante las horas centrales del día (desde las 10 hasta las 15 hrs), lo que se traduce en una subestimación de la irradiación solar. Entre todos los modelos evaluados, este presenta el mayor desvío intra-diaro, con valores de rMBD que oscilan entre -7.1% y $+27.1\%$. Este patrón se corrobora con en el diagrama de dispersión

del modelo, en la Figura 4.2, donde se observa una mayor cantidad de puntos por debajo de la línea diagonal que representa el pronóstico ideal en comparación con los otros modelos. Los modelos GFS-0.5 y GFS-0.25 presentan un sesgo positivo en todas las horas del día, lo que significa que tienden a sobreestimar la irradiación solar constantemente. Este comportamiento se confirma en la gráfica de dispersión de ambos modelos, donde la mayoría de los puntos están por encima de la línea de referencia. Igualmente, el GFS-0.5 presenta menor sesgo (rMBD oscila entre +3.2 % y +13.5 %) en comparación con el GFS-0.25 (rMBD varía entre +4.9 y +13.1 %). El modelo ICON también presenta un sesgo positivo en todas las horas del día, bastante similar al GFS-0.5, con un rMBD variando entre +3.1 y +11.2 %. El modelo ECMWF se diferencia de los demás en su patrón, ya que tiende a sobreestimar la irradiación solar en las primeras horas del día y subestimarlo después del mediodía solar, aunque en ambos casos levemente, y exhibe el menor desvío intra-diario entre los modelos evaluados, con un rMBD que oscila entre -3.0 % y +3.5 %. Por último, la técnica de persistencia muestra subestimación de la irradiación solar en todas las horas del día, un comportamiento que ya se ha encontrado en trabajos previos para la región (Aicardi et al., 2022; Giacosa & Alonso-Suárez, 2018; Teixeira-Branco et al., 2022; Teixeira-Branco et al., 2021).

Tabla 4.2: Desempeño intra-diario del primer día de pronóstico, en términos relativos.

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
MBD (%)												
ECMWF	+3.5	+2.9	+2.5	+1.9	+1.2	+0.4	-0.5	-1.3	-2.6	-3.0	-2.6	-0.9
ICON	+11.2	+9.8	+7.0	+4.4	+3.6	+3.9	+4.7	+4.3	+3.1	+3.1	+4.1	+4.9
GFS-0.5	+13.5	+10.5	+7.2	+4.9	+3.6	+3.3	+3.4	+3.6	+3.2	+3.7	+3.6	+5.4
GFS-0.25	+13.1	+11.8	+9.6	+8.2	+6.9	+6.6	+6.8	+6.5	+5.8	+6.0	+4.9	+5.3
NEMS30	+10.8	+7.5	+0.7	-3.2	-5.8	-7.1	-6.9	-5.0	-2.8	+3.1	+11.8	+27.1
Persistencia	-1.4	-1.2	-0.9	-0.8	-0.8	-0.7	-0.7	-0.7	-0.8	-1.0	-1.3	-1.7
MAD (%)												
ECMWF	20.1	19.4	17.8	16.9	16.8	17.2	17.9	18.8	19.7	21.1	22.1	22.5
ICON	20.6	18.9	16.9	15.7	15.4	15.7	16.4	16.9	17.2	18.3	18.9	20.3
GFS-0.5	23.7	21.7	19.5	18.8	17.8	18.1	19.5	19.8	20.6	22.3	23.5	25.1
GFS-0.25	23.7	22.2	20.0	19.3	18.0	18.3	19.7	19.8	20.3	22.3	23.7	24.8
NEMS30	29.3	23.4	21.1	20.6	20.6	21.0	21.5	21.7	21.6	23.0	26.8	37.5
Persistencia	38.1	36.5	35.3	33.8	32.7	32.6	33.2	34.4	35.5	36.3	37.5	38.1
RMSD (%)												
ECMWF	30.9	30.4	26.7	25.2	25.0	25.4	25.9	27.0	28.4	31.0	34.4	33.4
ICON	31.9	29.9	26.1	24.5	23.6	23.7	24.9	25.2	25.9	28.7	32.4	31.9
GFS-0.5	37.2	35.0	30.7	29.5	27.2	27.8	30.2	30.1	31.6	36.0	39.3	38.7
GFS-0.25	37.6	36.1	32.0	30.9	28.4	28.7	31.0	30.7	31.8	36.0	39.1	38.5
NEMS30	43.1	37.1	32.1	30.4	30.2	30.7	31.5	32.1	32.8	35.7	42.4	50.5
Persistencia	59.3	58.2	52.8	50.1	48.3	47.6	48.2	49.5	51.6	54.6	59.7	56.7

Analizando los resultados en términos de rMAD, se observa desempeño favorable a los modelos de predicción con respecto a la persistencia. Al final del día esta

técnica se acerca al desempeño del modelo NEMS30, como se puede observar en la Figura 4.3. El modelo ICON presenta mejor desempeño según la métrica rMAD, con valores que oscilan entre 15.4 % y 20.6 %, seguido del ECMWF, que presenta rMAD entre 16.8 % y 22.5 %. Los modelos GFS-0.5 y GFS-0.25 presentan rMAD bastante similares, con valores entre 17.8–25.1 % y 18–24.8 %, respectivamente.

En términos de rRMSD, se observa que los modelos numéricos superan a la técnica de persistencia, como muestra en la Figura 4.3. El desempeño intra-diario de la persistencia varía entre un rRMSD de 47.6 % y 59.7 %. El modelo NEMS30 muestra mayor incertidumbre entre los modelos evaluados con un rRMSD intra-diario que oscila entre 30.2–50.5 %. Las diferentes resoluciones del GFS presentan desempeños bastante similares, e incluso con una resolución más baja (GFS-0.5) presenta mejor desempeño en algunas horas del día. Esto puede ocurrir porque la relación entre la resolución espacial y la calidad del pronóstico no es tan directa, ya que aumentar la densidad de la grilla no implica una mejor resolución de la nubosidad. El rRMSD intra-diario del modelo GFS-0.5 varía entre 27.2–39.3 %, mientras el GFS-0.25 reporta valores entre 28.4 % y 39.1 %. Los modelos ICON y ECMWF presentan los mejor desempeño en términos de rRMSD, con valores que fluctúan entre 25.0–34.4 % y 23.6–32.4 %, respectivamente.

En la Tabla 4.3 y en la Figura 4.4 se presentan los valores promedio entre los sitios de la habilidad de pronóstico (FS). Los valores positivos en la Tabla 4.3 indican que los modelos superan a la técnica de persistencia.

Tabla 4.3: FS intra-diario del primer día de pronóstico (en %).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF	47.8	47.8	49.4	49.6	48.3	46.8	46.3	45.5	45.0	43.2	42.3	41.2
ICON	44.0	45.9	48.0	48.9	49.7	48.6	46.7	46.8	47.2	44.9	43.1	39.6
GFS-0.5	37.4	39.9	41.8	41.0	43.6	41.7	37.3	39.2	38.7	34.1	34.0	31.8
GFS-0.25	36.7	38.0	39.5	38.4	41.2	39.8	35.8	38.0	38.3	34.0	34.6	32.1
NEMS30	27.4	36.2	39.2	39.3	37.4	35.6	34.6	35.2	36.4	34.5	29.0	11.0

La mayor ganancia de los NWP con respecto a la persistencia se observa en torno al mediodía solar, lo que se traduce en una mayor coherencia entre las predicciones de los diferentes modelos, con un desvío de 4.7 % entre las predicciones. La habilidad de pronóstico de irradiación solar varía a lo largo del día. El NEMS30 se destaca como el que presenta la menor habilidad de pronóstico en la mayoría de las horas, con valores que oscilan entre 11.0 y 39.3 %, conforme la Tabla 4.3. Por otro lado, los modelos ECMWF y ICON presentan un rendimiento superior, con valores de FS que varían entre 41.2 % y 49.6 % para ECMWF y entre 39.6 % y 49.7 % para

el ICON. En el caso de los modelos GFS-0.5 y GFS-0.25, muestran una capacidad intermedia de pronóstico, con valores que varían entre 31.8 % y 43.6 % y entre 32.1 % y 41.2 %, respectivamente.

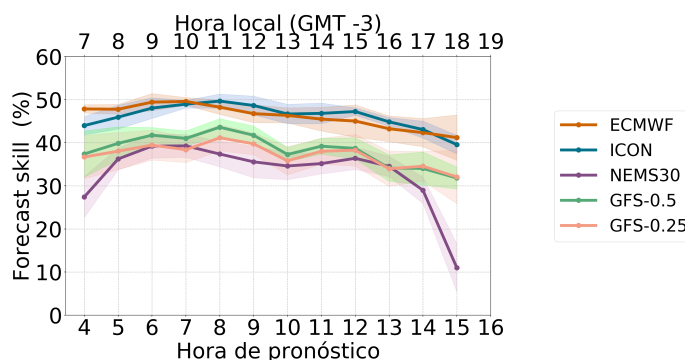


Figura 4.4: FS intra-diario de los modelos NWP.

4.2. Periodo estacional

En esta sección, se analiza la variabilidad de la incertidumbre de los modelos de pronóstico en las diferentes estaciones del año y se comparan con los resultados anuales presentados en la sección anterior. Los datos estacionales provienen de los tres años completos de pronóstico, donde se seleccionaron tres meses representativos para cada estación del año. La primavera corresponde a los meses desde septiembre hasta noviembre (SON), el verano está representado por los meses desde diciembre hasta febrero (DEF), el otoño se abarcan los meses desde marzo hasta mayo (MAM) y el invierno son los meses desde junio hasta julio (JJA).

La Figura 4.5 y la Tabla 4.4 presentan el rMBD promedio entre los sitios de los modelos evaluados en diferentes periodos estacionales, además de incluir los resultados del periodo anual. Los indicadores relativos por sitio han sido normalizados respecto a la media de la medida de GHI en cada hora de las diferentes estaciones del año. Los resultados en términos absolutos se encuentran documentados en el Anexo 2. La Figura 4.5 destaca una coherencia en los resultados de cada modelo en los periodos evaluados, indicando que los sesgos sistemáticos de los modelos presentan poca variabilidad entre los periodos estacionales y anual. Esta consistencia no se aplica en todas regiones del mundo, ya que estudios como el de Jiménez et al. (2022) en la región de Estados Unidos han demostrado una variabilidad estacional significativa, especialmente durante la primavera y el verano.

Tabla 4.4: Evaluación estacional del rMBD intra-diario (en %).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
Primavera	+2.1	+0.9	+1.1	+1.1	+0.6	+0.3	-0.6	-1.6	-3.1	-3.6	-3.4	≈0.0
Verano	+4.4	+3.9	+2.9	+2.3	+1.3	+1.2	+0.1	-0.4	-1.5	-1.6	-1.5	-1.3
Otoño	+4.3	+3.8	+2.7	+1.4	+1.1	-0.7	-1.2	-2.0	-4.4	-5.2	-4.1	-0.1
Invierno	-	+6.0	+4.6	+3.4	+2.0	+0.5	-0.2	-1.5	-1.8	-2.4	-3.1	-
ICON												
Primavera	+13.1	+10.2	+7.1	+5.1	+4.2	+5.0	+5.6	+4.4	+3.0	+2.8	+3.8	+5.0
Verano	+9.3	+7.8	+5.9	+4.9	+5.0	+6.0	+6.6	+5.9	+4.5	+4.5	+5.4	+5.2
Otoño	+12.2	+11.7	+7.0	+3.3	+2.5	+2.4	+4.4	+5.2	+3.5	+3.0	+3.1	+1.7
Invierno	-	+15.0	+9.7	+3.8	+1.3	+0.3	+0.4	-0.3	-0.2	-0.1	-2.8	-
GFS-0.5												
Primavera	+13.9	+9.2	+5.5	+3.2	+2.5	+3.1	+3.6	+3.6	+3.5	+4.2	+4.6	+6.2
Verano	+13.4	+11.3	+8.2	+6.5	+5.4	+5.6	+4.9	+4.5	+3.6	+3.7	+5.3	+5.4
Otoño	+12.1	+11.5	+8.2	+5.2	+4.2	+3.1	+4.3	+5.4	+4.2	+4.4	+1.6	+3.2
Invierno	-	+10.3	+7.2	+4.2	+1.0	-0.6	-0.6	-0.4	+0.3	+1.3	-11.1	-
GFS-0.25												
Primavera	+13.6	+10.4	+7.8	+6.7	+5.8	+6.3	+6.6	+6.4	+6.1	+6.6	+4.8	+3.8
Verano	+12.6	+11.5	+9.6	+9.1	+8.1	+8.4	+7.8	+7.5	+6.6	+6.8	+7.1	+6.0
Otoño	+12.9	+13.6	+11.0	+8.6	+7.7	+6.7	+8.0	+8.5	+6.8	+6.7	+2.2	+2.9
Invierno	-	+10.3	+7.1	+4.2	+1.0	-0.6	-0.6	-0.3	+0.3	+1.3	-11.1	-
NEMS30												
Primavera	+10.4	+3.3	-2.2	-5.2	-6.9	-7.0	-7.1	-5.5	-3.6	+2.5	+14.2	+36.8
Verano	+8.1	+4.3	-2.4	-5.5	-8.1	-9.3	-9.8	-8.0	-6.0	-1.6	+5.3	+22.0
Otoño	+23.1	+14.0	+4.0	-1.8	-4.7	-6.8	-5.8	-3.2	-1.5	+6.0	+18.4	+40.0
Invierno	-	+29.1	+11.9	+4.4	-0.6	-3.1	-2.3	-0.3	+4.4	+15.4	+38.1	-

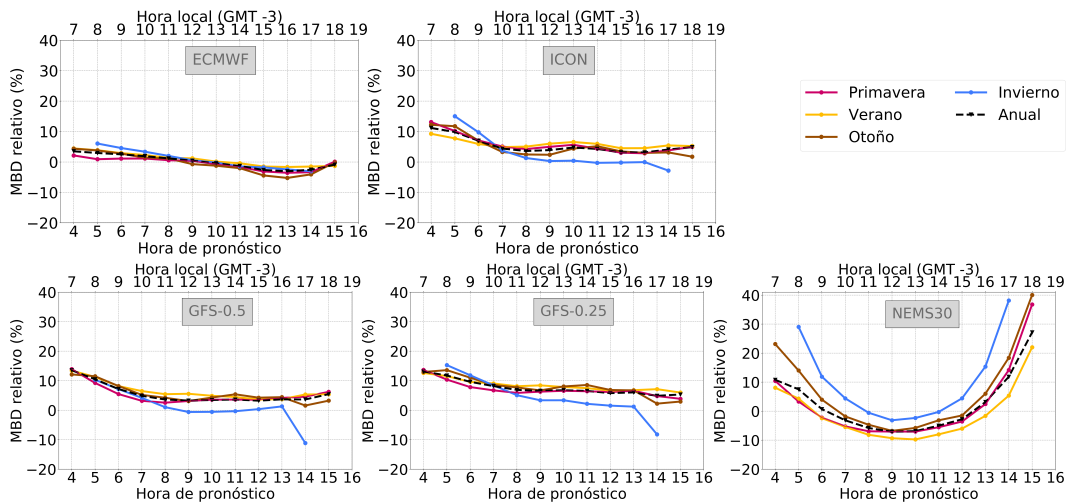


Figura 4.5: rMBD anual y estacional intra-diario.

En cuanto a la comparación de los valores de rMBD estacionales (Tabla 4.4) con los anuales presentados anteriormente (Tabla 4.2), el ECMWF presenta menor el desvío máximo entre los periodos, cerca de 1.6 %, seguido por el ICON con 2.8 %. En cambio, el GFS-0.5 tiene un desvío máximo entre los periodos de 6.8 %, mientras que el GFS-0.25 muestra una tendencia bastante similar con un desvío máximo de 7.9 %. Por último, el NEMS30 muestra la mayor discrepancia entre

los períodos evaluados, con un desvío máximo de 16.1 %, visible en la gráfica del modelo en la Figura 4.5. Estos resultados sugieren que para el modelo NEMS30 podrían ser efectivas la implementación de estrategias de post-procesamiento para mejorar el desempeño según la época del año.

La Figura 4.6 y Tabla 4.5 presentan el rRMSD promedio entre los sitios de los modelos evaluados en diferentes periodos estacionales junto a los resultados periodo anual. Los resultados en términos absolutos se encuentran documentados en el Anexo 2. Al comparar los resultados estacionales de la Tabla 4.5 con los resultados anuales de la Tabla 4.2, se observa que durante el verano y la primavera, todos los modelos exhiben una mejora en el desempeño en comparación con la evaluación anual. Tomando como referencia el modelo ECMWF en verano, se nota un aumento de desempeño intra-diario, que oscilan entre 0.8 % y 4.8 % en diferentes horas del día. En cambio, durante el otoño e invierno, se encuentra un peor desempeño de los modelos en comparación con la evaluación anual. Tomando como ejemplo el ECMWF en otoño, se registra un incremento en la incertidumbre que va desde 0.2 % hasta 3.0 %.

Tabla 4.5: Evaluación estacional y anual del rRMSD intra-diario (en %).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
Primavera	29.9	26.8	25.1	23.4	23.6	23.9	24.2	25.4	26.3	28.3	29.6	31.6
Verano	28.0	25.6	23.3	22.7	23.4	24.2	25.1	25.4	26.7	27.9	29.9	30.9
Otoño	34.0	31.8	27.5	26.9	25.3	25.7	26.5	28.2	28.6	31.6	34.9	33.9
Invierno	–	38.2	31.1	28.3	26.8	26.5	25.2	27.1	28.9	31.6	36.3	–
ICON												
Primavera	34.1	28.1	25.1	23.7	22.9	23.4	24.5	24.3	24.7	26.7	29.4	33.6
Verano	26.3	22.7	21.5	21.1	21.1	21.5	22.3	22.8	23.4	25.4	27.8	29.1
Otoño	36.0	33.0	27.2	25.2	23.7	23.8	25.7	26.3	26.3	29.1	30.8	30.9
Invierno	–	43.4	33.9	29.2	26.9	26.2	26.7	27.3	28.3	30.5	31.4	–
GFS-0.5												
Primavera	36.7	30.0	28.1	27.9	25.5	26.1	28.4	27.6	28.9	31.6	33.4	36.9
Verano	33.0	29.8	26.8	26.3	25.1	26.8	29.5	29.1	30.1	33.1	34.1	35.7
Otoño	39.8	37.4	32.8	30.9	28.3	27.9	30.9	31.3	32.4	36.7	39.9	38.4
Invierno	–	43.7	35.9	33.4	29.9	28.4	28.6	28.9	30.1	33.6	40.8	–
GFS-0.25												
Primavera	37.3	31.0	29.1	29.0	26.6	27.2	29.5	28.8	29.5	32.2	32.7	35.2
Verano	33.4	30.7	27.8	27.2	26.1	27.4	29.6	29.0	30.1	32.9	34.1	36.0
Otoño	40.0	38.4	34.4	32.8	29.6	29.1	32.0	32.3	32.7	37.0	39.5	35.9
Invierno	–	46.4	38.0	35.8	31.2	29.4	29.7	29.8	30.3	33.8	43.6	–
NEMS30												
Primavera	42.5	31.8	29.7	29.3	28.7	28.8	30.3	30.3	30.3	32.5	38.4	52.8
Verano	37.5	31.0	27.9	27.0	28.5	29.3	30.4	30.7	31.5	31.9	35.3	44.5
Otoño	51.3	40.7	33.7	31.4	30.8	31.9	32.1	33.0	32.7	36.4	45.0	61.8
Invierno	–	54.9	38.0	33.4	30.6	30.4	29.4	30.5	31.6	38.7	58.8	–

En la Figura 4.6, se destaca la consistencia entre los modelos, evidenciando una baja dispersión en los periodos evaluados. Una característica común entre los mode-

los es la poca disparidad estacional y anual alrededor del mediodía solar, explicada por la menor incertidumbre de los modelos en la predicción de la irradiación solar en esos momentos del día.

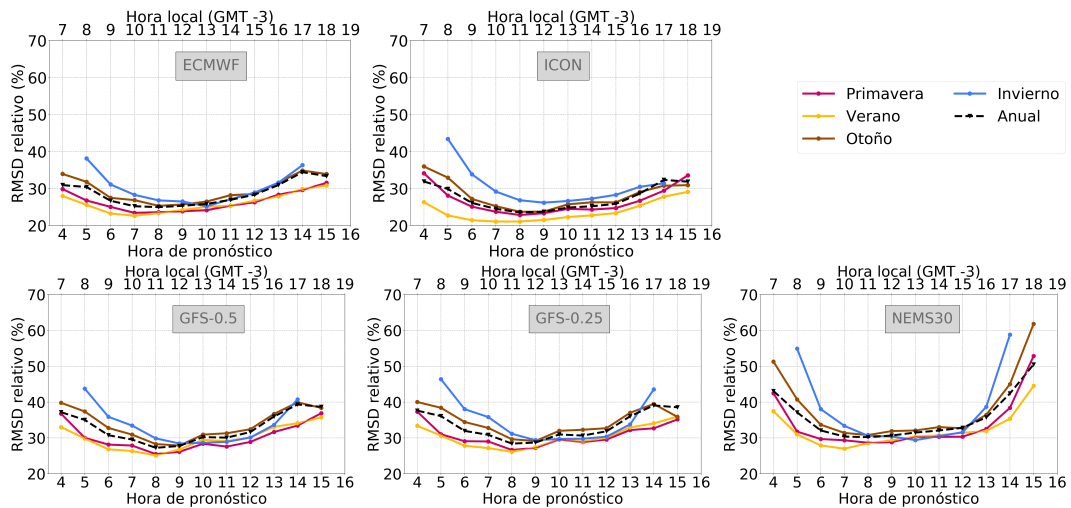


Figura 4.6: rRMSD anual y estacional intra-diarario.

La Figura 4.7 y la Tabla 4.6 muestran la habilidad de pronóstico intra-diarario para cada modelo en cada período evaluado. En la Figura 4.7 se observa que los resultados de la evaluación anual se sitúan en un nivel intermedio entre las estaciones de primavera e invierno, con un rendimiento superior al análisis anual. Las estaciones de otoño y verano presentan un rendimiento inferior a la evaluación anual. Esto ocurre debido a la ganancia respecto a la técnica de la persistencia, que también tiene un comportamiento estacional. Cabe destacar que el modelo NEMS30 muestra valores de FS negativos en primavera y otoño. Esto ocurre debido a que el rRMSD del modelo supera el indicador de la persistencia en estos periodos.

En resumen, el FS intra-diarario anual y estacional muestra que el modelo ECMWF es el más preciso en la región, seguido por el modelo ICON. Los modelos GFS-0.5 y GFS-0.25 presentan resultados similares entre si, pero con desempeño inferior en comparación con los modelos anteriores. Por otro lado, el modelo NEMS30 presenta menor habilidad de pronóstico intra-diarario debido a su bajo desempeño en las horas iniciales y finales del día. En cuanto a la variabilidad de desempeño estacional y anual de los modelos, se observa que la ganancia máxima de la habilidad de pronóstico del periodo estacional, en comparación con el anual, varía entre 4.8 % y 10.3 %. Estas mejoras en el indicador se registra en primavera a las 16 hs con el modelo ICON y en invierno a las 13 hs horas con el modelo NEMS30.

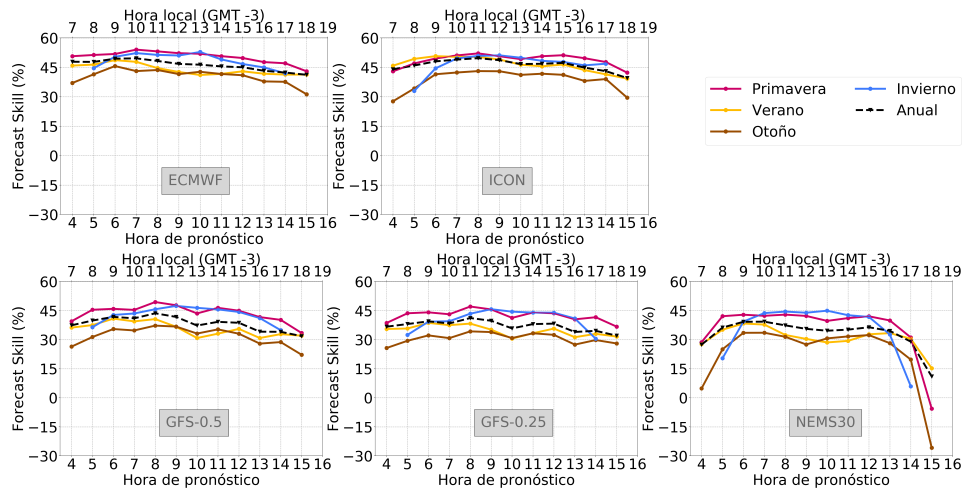


Figura 4.7: FS anual y estacional intra-díario.

Tabla 4.6: Evaluación estacional y anual del FS (en %).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
Primavera	50.7	51.3	51.8	54.0	53.1	52.2	51.9	50.7	49.8	47.7	47.1	43.0
Verano	45.9	46.4	48.7	47.8	44.6	42.6	41.1	41.7	43.0	41.7	41.3	41.3
Otoño	37.0	41.4	45.6	43.1	43.6	41.6	42.7	41.6	41.0	37.8	37.6	31.3
Invierno	-	44.6	50.4	52.3	51.3	51.0	52.8	49.0	46.7	44.9	42.0	-
ICON												
Primavera	43.0	47.0	49.5	51.1	52.1	50.7	49.2	50.7	51.2	49.7	47.7	42.33
Verano	45.8	49.3	50.7	50.3	50.3	49.0	46.4	45.5	46.4	43.6	41.4	39.3
Otoño	27.7	34.2	41.5	42.4	43.1	43.0	41.2	41.7	41.2	38.1	39.0	29.5
Invierno	-	33.0	44.5	49.5	50.8	51.1	49.9	48.3	47.8	46.0	46.8	-
GFS-0.5												
Primavera	39.5	45.4	45.9	45.4	49.4	47.8	43.5	46.4	44.9	41.6	40.2	33.4
Verano	36.2	37.5	40.8	39.4	40.6	36.6	30.8	33.1	35.6	30.8	32.9	32.0
Otoño	26.4	31.4	35.5	34.8	37.2	36.7	33.1	35.3	33.1	28.0	28.7	22.2
Invierno	-	36.4	42.7	43.5	45.7	47.4	46.4	45.6	44.3	41.1	34.9	-
GFS-0.25												
Primavera	38.6	43.6	44.1	43.1	47.1	45.6	41.3	44.0	43.6	40.5	41.6	36.7
Verano	35.5	35.8	38.7	37.5	38.3	35.2	30.6	33.3	35.7	31.3	33.0	31.6
Otoño	25.7	29.4	32.2	30.8	34.3	33.9	30.8	33.3	32.5	27.4	29.8	28.0
Invierno	-	32.5	39.3	39.5	43.4	45.7	44.4	44.0	43.9	40.9	30.5	-
NEMS30												
Primavera	28.7	42.1	42.9	42.3	42.9	42.2	39.7	41.1	42.0	39.9	31.1	-5.6
Verano	27.7	35.1	38.3	37.8	32.4	30.4	28.6	29.4	32.8	33.4	30.5	15.2
Otoño	4.8	25.0	33.5	33.6	31.5	27.5	30.6	31.7	32.3	28.2	19.7	-25.8
Invierno	-	20.4	39.3	43.7	44.5	43.9	45.0	42.6	41.7	32.6	5.9	-

Capítulo 5

Evaluación del pronóstico diario

En este capítulo se brinda una descripción detallada del desempeño anual y estacional a escala diaria para el primer día de pronóstico ofrecido por diferentes modelos globales. Los resultados diarios corresponden a la evaluación de los totales diarios integrados en las primeras 24h de pronóstico por sitio e incluyendo el promedio entre ellos y su desviación estándar (variabilidad territorial). En este capítulo los valores diarios estarán representados en MJ/m^2 para facilitar la interpretación y comparación de los resultados. El desempeño anual y estacional se discuten por separado en la Sección 5.1 y en la Sección 5.2, respectivamente. Algunos de los resultados anuales han sido publicados en Teixeira-Branco et al. (2022) y Teixeira-Branco et al. (2021). En la Sección 5.3 se aborda el impacto de la nubosidad en el desempeño de los pronósticos a partir de indicadores que evalúan la incertidumbre de los pronósticos en diferentes condiciones de cielo. Esta última sección también incluye un análisis de la calidad del pronóstico a partir de la matriz de confusión.

5.1. Periodo anual

En la Figura 5.1 se presenta la dispersión entre la GHI medida y pronosticada por los modelos NWP y por la persistencia, para cada modelo en la estación de Salto. Analizando las gráficas de dispersión de los modelos, se observa que los pronósticos del ECMWF presentan mayor concentración de puntos abajo de la diagonal principal (línea de pronóstico perfecto), principalmente en los días donde la GHI supera los 20 MJ/m^2 , indicando la subestimación al pronosticar los días con mayor irradiación solar. En la gráfica del modelo NEMS30 también se observa un comportamiento hacia la subestimación, sin embargo la dispersión de los puntos

es mayor. En el caso de los modelos ICON y GFS en diferentes resoluciones, se observa en las gráficas de dispersión de los puntos alejados hacia arriba de la diagonal, ambos indicando la sobrestimación de la irradiación solar. Esta discusión se extiende en la siguiente sección de este capítulo.




Figura 5.1: Dispersión diaria de los modelos de pronóstico para la estación LE.

La Figura 5.2 muestra los indicadores de desempeño (rMBD, rMAD y rRMSD) de los diferentes modelos de pronóstico evaluados y de la técnica de persistencia para cada sitio individualmente. En todos los sitios evaluados se observa que la técnica de persistencia presenta una incertidumbre superior a la de los modelos de pronóstico, conforme muestran las gráficas de rMAD y rRMSD.

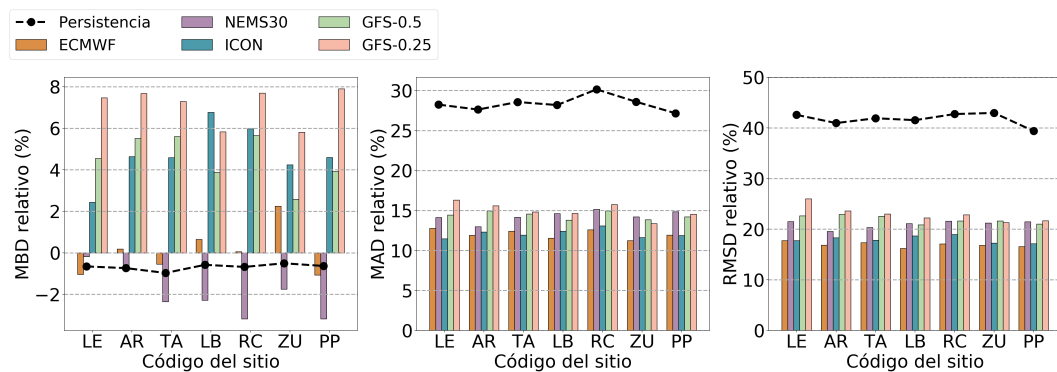


Figura 5.2: Desempeño diario del pronóstico del día siguiente por sitio.

En la Figura 5.2 se puede observar que los desvíos y los desempeños de cada modelos presentan tendencias similares entre los diferentes sitios analizados. El rMBD presenta variaciones significativas dependiendo del sitio, un patrón que se

aprecia en todos los modelos, pero resulta particularmente llamativo en el caso del modelo ICON. Se destaca que, en general, los modelos muestran sesgos positivos, con excepción del NEMS30, que tiene sesgo negativo, y del ECMWF, que varía según el sitio.

La Tabla 5.1 presenta las métricas desempeño y su desvío estándar promedio entre los sitios. La información similar por sitio se encuentra en el Anexo 3, para consulta con mayor detalle. Al analizar el desvío estándar de las métricas calculadas, se aprecia que en términos absolutos, los valores oscilan entre 0.1–0.3 MJ/m². Los indicadores de la evaluación diaria son mejores comparado con los resultados de la evaluación intra-diaria, como se esperaba. No solo el MBD, el MAD y el RMSD son significativamente más bajos, sino que también el FS es más alto. Tomando como ejemplo el modelo ECMWF, el rRMSD promedio horario intra-día oscilaba entre 25.0–34.0 %, mientras que el promedio diario es de un 17.0 %.

Tabla 5.1: Desempeño diario del primer día de pronóstico.

	media (MJ/m ²)	MBD (MJ/m ²)	MAD (MJ/m ²)	RMSD (MJ/m ²)	rMBD (%)	rMAD (%)	rRMSD (%)	FS (%)
media								
ECMWF	16.8	≈0.0	2.0	2.9	+0.1	12.1	17.0	59.4
ICON	17.1	+0.8	2.1	3.1	+4.7	12.1	18.0	55.3
GFS-0.5	16.8	+0.8	2.4	3.7	+4.5	14.4	21.9	47.5
GFS-0.25	16.8	+1.2	2.5	3.9	+7.1	15.0	23.0	45.0
NEMS30	16.8	-0.3	2.4	3.5	-2.0	14.3	21.0	49.7
stdev								
ECMWF	0.4	+0.2	0.1	0.1	+1.2	0.6	0.5	1.2
ICON	0.6	+0.2	0.1	0.1	+1.4	0.6	0.7	1.6
GFS-0.5	0.4	+0.2	0.1	0.2	+1.2	0.5	0.8	2.2
GFS-0.25	0.4	+0.2	0.2	0.3	+0.9	1.0	1.6	3.6
NEMS30	0.4	+0.2	0.1	0.1	+1.1	0.7	0.8	2.2

Los resultados del MBD, en la Tabla 5.1, son coherentes con el comportamiento observado en la gráfica de dispersión de cada modelo (Figura 5.2). El modelo ECMWF tiene el sesgo más bajo entre los modelos evaluados, prácticamente nulo, con un rMBD promedio cercano al +0.1 %. Por otro lado, el NEMS30 muestra un sesgo negativo con un rMBD promedio de aproximadamente -2.0 %, mientras que los modelos ICON y GFS-0.5 presentan sesgos positivos más pronunciados, ambos alrededor del +4.6 %. En términos absolutos, esto equivale a un MBD de 0.8 MJ/m² para ambos modelos. Por último, el GFS-0.25 presenta el mayor desvío diario promedio entre los sitios de los modelos evaluados, con un rMBD de 7.1 %.

Al analizar los indicadores MAD y RMSD, en Tabla 5.1, se encuentra que el modelo GFS-0.25 presenta mayor incertidumbre diaria promedio entre los sitios en

comparación con los otros modelos evaluados, con rRMSD y rMAD alcanzando el 23.0 % y el 15.0 %, respectivamente. Esta mayor incertidumbre está relacionada con el sesgo anteriormente identificado en este modelo, lo que resulta en una mayor variabilidad en sus pronósticos. Por otro lado, los modelos ECMWF y ICON presentan la menor incertidumbre diaria promedio entre los sitios, con un rRMSD de 17.0 % y de 18.0 %, respectivamente. El modelo GFS-0.5 presenta un rRMSD promedio entre los sitios de alrededor del 22.0 %, lo que indica su competitividad en la región en comparación con el pronóstico del NEMS30, que presenta un rRMSD de aproximadamente 21.0 %. Esto sugiere que el modelo GFS-0.5 es una opción viable para predecir el desempeño en la región evaluada.

En la literatura existe una mayor cantidad de artículos que reportan el desempeño del pronóstico solar a escala diaria que en escala intra-día, por lo que existen más trabajos con los cuáles comparar. En general, los indicadores diarios presentados en la Tabla 5.1 están dentro del amplio rango de rRMSD reportado en otras partes del mundo, donde valores oscilan entre 18.0 % y 67.0 % (Tabla 2.2). En un análisis regional, los modelos globales aquí evaluados presentaron desempeño superior al modelo de mesoescala GFS+WRF evaluado en Uruguay por Porrini (2017) y por también por Teixeira-Branco et al. (2018), que reportaron un rRMSD entre 27–39 % y 30–36 %, respectivamente.

De la habilidad de pronóstico, en la Tabla 5.1, se destaca una importante mejora en comparación con la evaluación intra-diaria. Por ejemplo, el modelo ECMWF, muestra una ganancia de aproximadamente el 24.0 % en su desempeño en la escala diaria en comparación con la intra-diaria. Esto se debe al bajo desempeño de la persistencia en la escala diaria. El modelo GFS-0.25 presenta habilidad de pronóstico diario más baja entre los modelos evaluados, con FS de 45.0 %. En cambio, el modelo ECMWF presenta la habilidad de pronóstico diaria superior, con un FS de 59.4 %. El modelo ICON también presenta un buen desempeño, con un FS de 55.3 %. En cuanto los modelos NEMS30 y GFS-0.5 muestran valores muy similares en su desempeño, con una diferencia de aproximadamente un 2.0 % en favor del modelo NEMS30.

5.2. Periodo estacional

En esta sección se brindan los indicadores de desempeño estacional del pronóstico integrado diario de la GHI junto a los resultados anuales presentados en la sección anterior. Los meses que representan cada estación del año son los mismos

definidos en la evaluación intra-diaria.

La Figura 5.3 muestra el RMSD relativo estacional y anual en cada sitio para los modelos globales (representados en forma de barras), y para la persistencia (indicada en forma de línea). De la comparación de desempeño entre persistencia y modelos globales de pronóstico, se observa que estos últimos presentan un mejor rendimiento en cualquier periodo del año, tal como se esperaba. La persistencia muestra una importante variabilidad estacional en la región, siendo más pronunciada que la observada en las predicciones de los modelos NWP, particularmente durante los meses de invierno y verano. Esto se muestra al comparar el máximo desvío estándar estacional entre los modelos; por ejemplo, en la estación LB, el modelo NEMS30 muestra un desvío estándar cercano al 3.4 %, mientras que la persistencia registra un desvío estándar considerablemente mayor, del orden del 8.7 % en la estación de PP. El diagnóstico de este comportamiento de la persistencia es novedoso en la región, dado que el comportamiento estacional no ha sido considerado en el estudio previo realizado por Giacosa y Alonso-Suárez (2018).

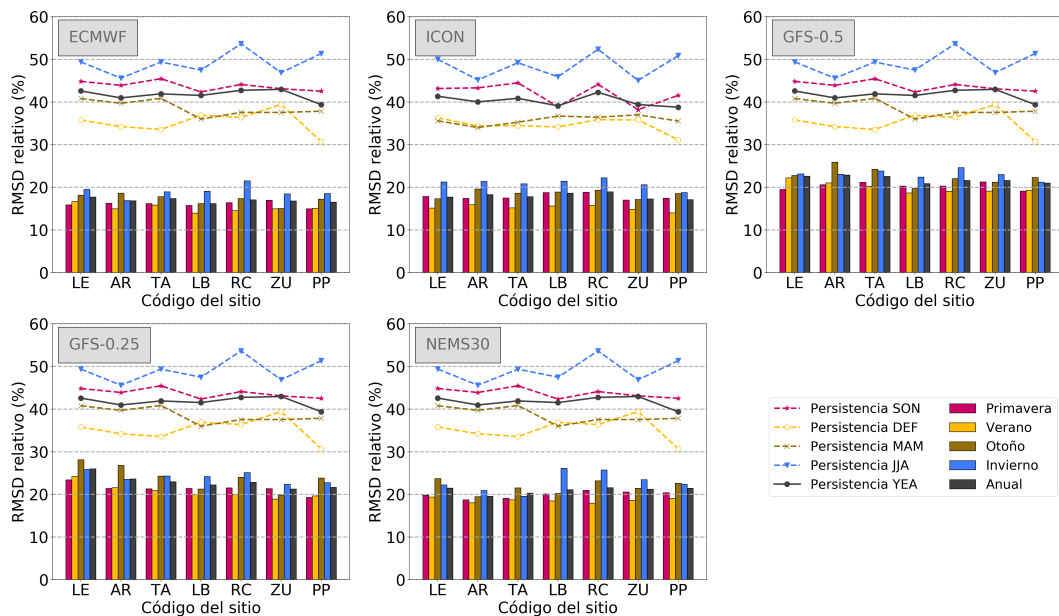


Figura 5.3: rRMSD diario en cada sitio en diferente épocas del año.

Analizando los valores individuales por sitio de rRMSD para cada modelo en los periodos evaluados, se observa que el desempeño entre los sitios son similares entre si, en cualquier época del año. Esta característica se confirma con los bajos valores de desvío estándar de cada periodo, los cuales se presentan en la Tabla 5.2. Esta tabla también proporciona los valores promedio entre los sitios de rRMSD para los diferentes modelos. El máximo desvío estándar (inter-sitios) encontrado

fue de 2.9 %, que en términos absolutos es aproximadamente 0.5 MJ/m², reportado por el GFS-0.25, en los meses de otoño. Al igual que en análisis anteriores, estos resultados confirman que el desempeño de los modelos numéricos no dependen geográficamente de los sitios, en nuestra región, en términos de MAD y RMSD.

Tabla 5.2: rRMSD diario promedio entre los sitios de la evaluación estacional (en %).

	ECMWF	ICON	GFS-0.5	GFS-0.25	NEMS30	Persistencia
media						
Primavera	16.1	17.8	20.3	21.4	20.0	43.7
Verano	15.2	15.2	20.0	20.8	18.6	35.3
Otoño	17.2	18.5	22.6	24.0	21.7	38.6
Invierno	19.0	20.9	23.0	24.0	22.9	49.1
stdev						
Primavera	0.6	0.7	0.8	1.2	0.8	1.1
Verano	0.9	1.3	1.3	1.7	0.5	2.8
Otoño	1.2	2.0	2.0	2.9	1.5	1.8
Invierno	1.4	1.1	1.1	1.2	2.4	2.7

En la Figura 5.4 se muestran las graficas rMBD y rRMSD promedio entre los sitios en los periodos evaluados, para cada pronóstico por separado. De los resultados del rRMSD (Figura 5.4b), se observa que durante el verano se presentan los valores más bajos para todos los pronósticos. Sin embargo, la mejora en el desempeño estacional son relativamente modestas en comparación con los resultados anuales, ya que varía entre 1.7 % y 2.8 %. Considerando el período de verano como ejemplo, se observa un aumento en la incertidumbre anual de aproximadamente un 1.7 % para el ECMWF, un 2.8 % para el modelo ICON, un 1.9 % para el GFS-0.5, un 2.1 % para el GFS-0.25 y un 2.4 % para el modelo NEMS30.

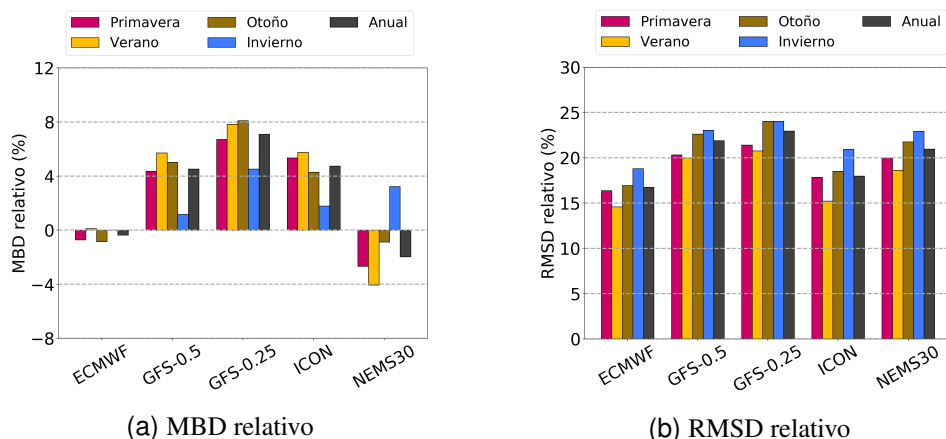


Figura 5.4: Desempeño diario estacional de los modelos de pronóstico

El rMBD, en la Figura 5.4a, muestra la variación estacional en el rMBD. Se observa que los modelos que tienden a subestimar la GHI, como el ECMWF y el

NEMS30, presentan el MBD máximo en otoño y mínimo en invierno, con diferencia entre estos periodos de 0.8 % y 3.1 %, respectivamente. Por otro lado, los modelos con sesgos de sobrestimación, como ICON, GFS-0.5 y GFS-0.25, presentan mayores rMBD en verano y menores en invierno, con diferencias entre estos periodos de 4.5 % (GFS-0.5), 3.3 % (GFS-0.25) y 3.9 % (ICON). La siguiente sección continúa la discusión sobre la dependencia estacional de las predicciones, discriminando según las condiciones de cielo.

5.3. Desempeño según condición de cielo

En esta sección se discute el impacto de la nubosidad en el desempeño de los modelos de pronóstico. Para esto, se presentan tres análisis basados en las diferentes condiciones de cielo. En el primer análisis (Subsección 5.3.1) se evalúa el desempeño anual y estacional de los modelos según tres rangos de índice de cielo claro (K_C), que clasifican las condiciones de cielo en: despejado, parcialmente nublado y nublado. Se emplean indicadores de evaluación como MBD y RMSD. En el segundo análisis (Subsección 5.3.2), se realiza una evaluación complementaria que se centra en la relación entre RMSD y K_C , utilizando una discretización fina de este índice. Esta segunda evaluación toma como referencia el trabajo de Lara-Fanego et al. (2012), que analiza el desempeño en todo el rango de valores de K_C . En el tercer análisis, en la Subsección 5.3.3, se evalúa la calidad de los pronósticos utilizando una matriz de confusión como herramienta.

5.3.1. Discriminación en categorías de cielo

En la Tabla 5.3 se presentan los resultados por sitio de la clasificación de los días según las condiciones de cielo utilizando tres categorías, cielo despejado (des, K_C mayor a 0.90), parcialmente nublado (pnu, K_C entre 0.90 y 0.40) y nublado (nub, K_C menor a 0.40), para las medidas en tierra. Los intervalos que determinan cada condición de cielo fueron definidos a partir de inspección visual de los histogramas del índice de cielo claro (K_C), anteriormente definido en el Capítulo 2.

En la Tabla 5.3 al analizar las condiciones de cielo en los diferentes sitios, independiente del periodo se observa una variabilidad mayor en los días clasificados como cielo despejado y parcialmente nublado. En estas condiciones, entre los años de 2017 y 2019, la dispersión de cantidad de días intra-sitios es de aproximadamente 53 en cielo despejado y 58 en cielo parcialmente nublado. En cambio, en condición

de nubosidad, esta variabilidad se reduce a aproximadamente 13 días.

Tabla 5.3: Cantidad de días de la medida en tierra en función de las condiciones del cielo.

	LE	AR	TA	LB	RC	ZU	PP
	días	días	días	días	días	días	días
Período 01/2017–12/2019							
des	503	440	418	417	351	478	377
pnu	387	429	481	497	553	439	527
nub	184	147	190	175	179	170	176
Período 01/2018–12/2020							
des	539	458	452	435	342	528	385
pnu	373	396	459	500	516	415	541
nub	167	141	180	155	159	143	165

En términos promedio entre los sitios, los días se clasifican en su mayoría como parcialmente nublados, mientras que una minoría se clasifica como nublados. Para el período entre los años de 2017 y 2019, los días de cielo despejado promedio entre los sitios representaron un 40 % de los días, en el período entre 2018 y 2020 fue de aproximadamente un 42 %. Los días clasificados como parcialmente nublado representaron un promedio entre los sitios del 44 % en el período de 2017–2019, ligeramente superior al 43 % en el período de 2018–2020. En cuanto a los días nublados, constituyeron alrededor del 16 % en el primer período y el 15 % en el segundo período.

En la Tabla 5.4 se muestra la cantidad de días clasificados según las mismas condiciones de cielo anteriores para los modelos NWP. El número de días asignados a cada categoría en la Tabla 5.4 refleja la variabilidad entre los modelos, indicando divergencias en la capacidad para pronosticar distintas condiciones atmosféricas. Por ejemplo, en condición cielo despejado, en LE la cantidad de días oscila desde 355 días (ECMWF) hasta 618 días (GFS–0.25). La Figura 5.5 presenta la distribución de días en cada sitio y para cada modelo en términos porcentuales para las tres categorías de cielo: despejado, parcialmente nublado y nublado (de izquierda a derecha).

A pesar de que la estadística de datos en cada sitio discriminados por condiciones de cielo puede ser baja¹, los resultados en los distintos sitios son similares. Para simplificar el análisis y reducir las pequeñas variaciones no significativas debidas a la limitación de datos, se presentará un promedio entre los sitios. Además, dado que el promedio de normalización de los indicadores relativos varían considerablemente entre las tres categorías, se priorizarán los indicadores absolutos en esta subsección,

¹A modo de referencia, la muestra de mayor tamaño corresponde a 553 días clasificados como parcialmente nublados en Rocha (Tabla 5.3).

ya que se consideran más representativos en este contexto. Para obtener resultados detallados por sitio, se pueden consultar en el Anexo 3.

Tabla 5.4: Cantidad de días en cada modelo NWP según la condición del cielo.

	LE días	AR días	TA días	LB días	RC días	ZU días	PP días
ECMWF							
des	355	333	323	371	277	438	301
pnu	583	572	624	600	678	536	623
nub	135	109	140	116	126	111	154
Total	1073	1014	1087	1087	1081	1085	1078
ICON							
des	568	533	535	543	407	563	467
pnu	361	327	396	435	474	417	458
nub	144	128	154	106	130	100	160
Total	1073	988	1085	1084	1011	1080	1085
GFS-0.5							
des	580	535	545	537	459	553	445
pnu	345	361	399	412	485	384	494
nub	146	117	142	137	136	147	139
Total	1071	1013	1086	1086	1080	1084	1078
GFS-0.25							
des	618	566	590	577	511	611	544
pnu	334	335	353	371	443	337	405
nub	122	115	146	141	129	139	131
Total	1074	1016	1089	1089	1083	1087	1080
NEMS30							
des	544	474	421	454	360	487	367
pnu	360	378	471	470	520	433	518
nub	170	164	197	165	203	167	195
Total	1074	1016	1089	1089	1083	1087	1080




Figura 5.5: Porcentaje de días en diferentes condiciones de cielo.

La Tabla 5.5 muestra los valores promedio y la desviación estándar de los indicadores MBD y RMSD para cada condición de cielo, considerando los sitios evaluados. Los valores de desviación estándar indican que el desempeño de los modelos es poco variable en los diferentes sitios y aumenta con el incremento de la nubosidad. En condiciones de cielo despejado, se observa una variabilidad máxima de 0.2 MJ/m² en el sesgo y 0.3 MJ/m² en el RMSD. En condiciones de cielo nublado, la

variabilidad intra-sitios aumenta, alcanzando un MBD máximo de 0.8 MJ/m^2 y un RMSD máximo de 0.9 MJ/m^2 .

Tabla 5.5: Desempeño diario del periodo anual en distintas condiciones de cielo, en MJ/m^2 .

	Despejado		Parcialmente nublado		Nublado	
	promedio	stdev	promedio	stdev	promedio	stdev
MBD						
ECMWF	-1.3	0.2	+0.3	0.3	+2.5	0.5
ICON	-0.3	0.2	+1.3	0.3	+2.3	0.4
GFS-0.5	-0.7	0.1	+1.3	0.2	+2.7	0.6
GFS-0.25	-0.2	0.1	+1.8	0.1	+3.0	0.8
NEMS30	-1.3	0.2	-0.2	0.3	+1.8	0.5
RMSD						
ECMWF	2.0	0.2	3.0	0.2	4.0	0.6
ICON	1.4	0.2	3.7	0.2	4.2	0.4
GFS-0.5	1.9	0.3	4.1	0.3	5.4	0.8
GFS-0.25	1.6	0.3	4.4	0.3	5.8	0.9
NEMS30	2.4	0.2	4.1	0.2	4.0	0.4

La evaluación estacional de cada condición de cielo para cada modelo se muestra en la Figura 5.6 y la Tabla 5.6 en términos de MBD absoluto promedio entre los sitios. Se observa que los sesgos aumentan hacia la sobreestimación con el aumento de la nubosidad, independiente del modelo y de la época del año. Esto sugiere que la sobreestimación diaria previamente reportada en la evaluación anual para todas las condiciones de cielo se debe a los días con nubosidad no pronosticada.

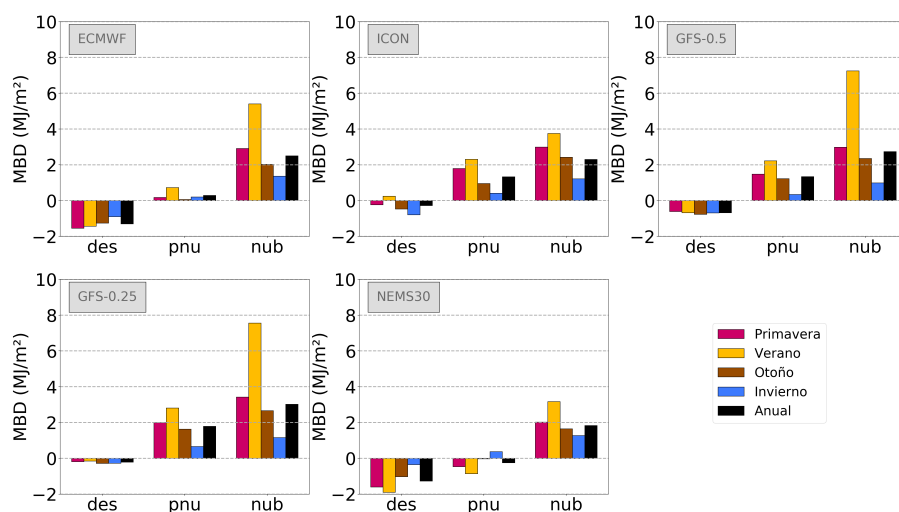


Figura 5.6: MBD según las diferentes condiciones de cielo.

En la Figura 5.6, los días en condiciones de cielo despejado presentan sesgos negativos y tienden a subestimar la irradiación, independiente del modelo. En estas condiciones, el NEMS30 reporta un desvío mayor que los demás modelos, con

MBD que varían en los periodos evaluados entre -0.3 MJ/m^2 y -1.9 MJ/m^2 (Tabla 5.6). Durante el verano y bajo cielos nublados, se registran los mayores desvíos en todos los modelos, oscilando entre $+3.2 \text{ MJ/m}^2$ (NEMS30) y $+7.5 \text{ MJ/m}^2$ (GFS-0.5), los modelos ECMWF y ICON presentan los sesgos intermedios.

Tabla 5.6: MBD estacional en función de las condiciones de cielo, en MJ/m^2

	ECMWF	ICON	GFS-0.5	GFS-0.25	NEMS30
Despejado					
Primavera	-1.5	-0.2	-0.6	-0.2	-1.6
Verano	-1.4	+0.2	-0.7	-0.1	-1.9
Otoño	-1.2	-0.5	-0.8	-0.3	-1.0
Invierno	-0.9	-0.8	-0.7	-0.3	-0.3
Parcialmente nublado					
Primavera	+0.2	+1.8	+1.5	+2.0	-0.5
Verano	+0.7	+2.3	+2.2	+2.8	-0.9
Otoño	≈ 0.0	+0.9	+1.2	+1.6	≈ 0.0
Invierno	+0.2	+0.4	+0.3	+0.6	+0.4
Nublado					
Primavera	+2.9	+3.0	+3.0	+3.4	+2.2
Verano	+5.4	+3.7	+7.2	+7.5	+3.2
Otoño	+2.0	+2.4	+2.3	+2.7	+1.6
Invierno	+1.4	+1.2	+1.0	+1.1	+1.3

La Figura 5.7 y en la Tabla 5.7 presentan los resultados de la evaluación estacional de cada condición de cielo en términos de RMSD promedio entre los sitios para cada modelo.

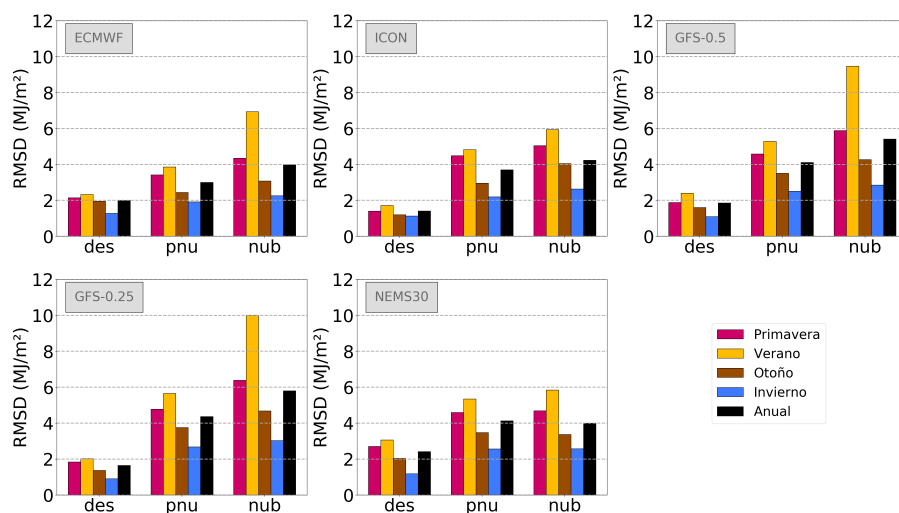


Figura 5.7: RMSD según las diferentes condiciones de cielo.

La Figura 5.7, muestra que el rendimiento de los modelos de pronóstico disminuye a medida que aumenta la nubosidad, independiente del período del año. Por ejemplo, el modelo GFS-0.5 tiene un RMSD de 1.9 MJ/m^2 en días despejados de

primavera, pero este valor aumenta a 2.7 MJ/m² en días parcialmente nublados y alcanza los 4.0 MJ/m² en días nublados. Además, se observa que durante el verano se registran los valores más altos de RMSD, especialmente en días nublados.

Tabla 5.7: RMSD estacional en función de las condiciones de cielo, en MJ/m²

	ECMWF	ICON	GFS-0.5	GFS-0.25	NEMS30
Despejado					
Primavera	2.1	1.4	1.9	1.8	2.7
Verano	2.3	1.7	2.4	2.0	3.0
Otoño	1.9	1.2	1.6	1.4	2.0
Invierno	1.3	1.1	1.1	0.9	1.2
Parcialmente nublado					
Primavera	3.4	4.5	4.6	4.8	4.6
Verano	3.8	4.8	5.3	5.6	5.3
Otoño	2.4	2.9	3.5	3.7	3.5
Invierno	1.9	2.2	2.5	2.7	2.6
Nublado					
Primavera	4.3	5.0	5.9	6.4	4.7
Verano	6.9	5.9	9.5	10.0	5.8
Otoño	3.1	4.0	4.3	4.7	3.4
Invierno	2.2	2.6	2.9	3.0	2.6

5.3.2. Relación entre RMSD y índice de cielo claro

En un estudio previo realizado por Lara-Fanego et al. (2012) se discutió el análisis del rRMSD en diferentes condiciones de cielo basado en el pronóstico de la GHI utilizando el modelo GFS+WRF en cuatro sitios de España. La gráfica obtenida en dicho estudio, presentada en la Figura 5.8, muestra el rRMSD promedio de los cuatro sitios en función del índice de claridad (definido en el Capítulo 2) en diferentes periodos del año. La evaluación también incluye la técnica de persistencia. Los autores encontraron, para el periodo anual, en condiciones de cielo despejado ($K_T \approx 0.8$), un rRMSD menor a 10%, para condiciones parcialmente nubladas ($K_T \approx 0.5$) un rRMSD alrededor de 50% y para condiciones de cielo cubierto ($K_T < 0.3$), un rRMSD superior al 100%. Otro resultado importante destacado por los autores, es una clara dependencia estacional en condiciones de cielo parcialmente nublado y nublado para los sitios estudiados, con rRMSD más altos durante la primavera (rRMSD de $\approx 160\%$) y más bajos durante el otoño (rRMSD de $\approx 94\%$). La Figura 5.9 muestra el mismo análisis propuesto por Lara-Fanego et al. (2012) aplicado a los pronósticos de los modelos evaluados en esta tesis.




Figura 5.8: Desempeño del modelo WRF+GFS. Resultados en términos de rRMSD promedio entre cuatro sitios de España en función del índice de claridad en los diferentes del año. Fuente: Lara-Fanego et al. (2012).

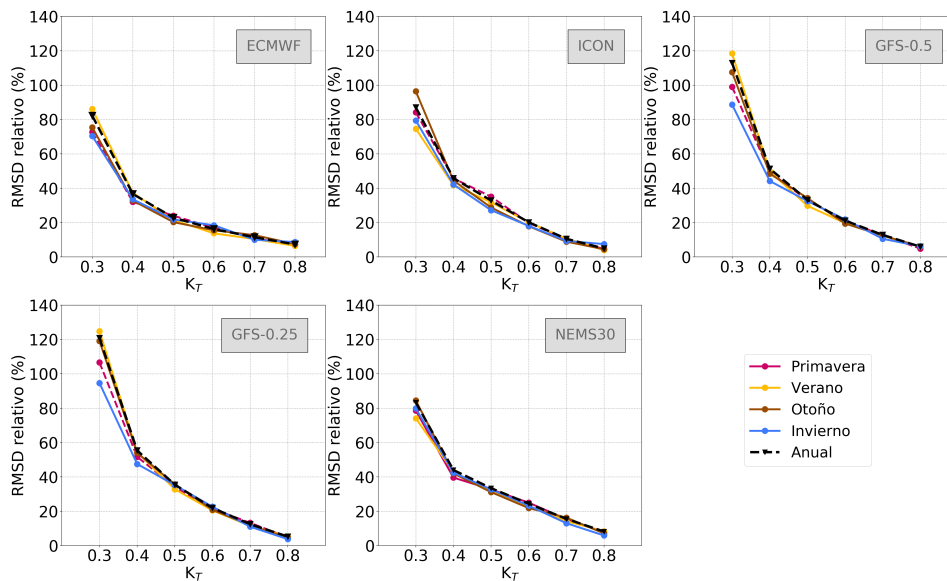


Figura 5.9: rRMSD promedio entre los sitios de cada modelo en función de K_T en los diferentes periodos del año. Metodología propuesta por Lara-Fanego et al. (2012).

Para la construcción de la gráfica se considera la interpretación de los resultados de Lara-Fanego et al. (2012), donde se asume, en el eje x , que el intervalo de K_T excluye el valor de referencia marcado en la gráfica, es decir, los intervalos son del tipo semiabierto. A modo de ejemplo, el valor de 0.3 corresponde al intervalo de $K_T \geq 0.2$ y $K_T < 0.3$. Las principales características encontradas en los resultados

fueron las siguientes:

- Desempeño superior a la evaluación realizada por Lara-Fanego et al. (2012).
- Consistencia en el desempeño durante los diferentes periodos evaluados.

La similitud de los valores de rRMSD encontrados en cada modelo indican una consistencia en el desempeño del pronóstico, lo que sugiere que no existe una dependencia estacional en la región. Tomando como ejemplo el GFS-0.25, la variabilidad inter-estacional de desempeño encontrada en los periodos evaluados en condición de nubosidad ($K_T < 0.3$) es de un 30.0 %, y este valor es aún menor en condiciones de cielo despejado ($K_T \approx 0.8$), cerca de 1.0 %. Esta característica contrasta con los resultados encontrados por Lara-Fanego et al. (2012).

La representación propuesta por Lara-Fanego et al. (2012), presenta algunas limitaciones como, por ejemplo, la definición de los intervalos de K_T . Por esta razón, en la Figura 5.10 se propone una alternativa, que se considera más apropiada, donde se evalúa el RMSD relativo en función de K_C , con diferente criterio para la construcción de los intervalos. El valor representado en el eje x , corresponde al centro de una muestra que varía ± 0.05 . Por ejemplo, en $K_C = 0.3$ están representados los valores en el intervalo entre $K_C > 0.25$ y $K_C \leq 0.35$.

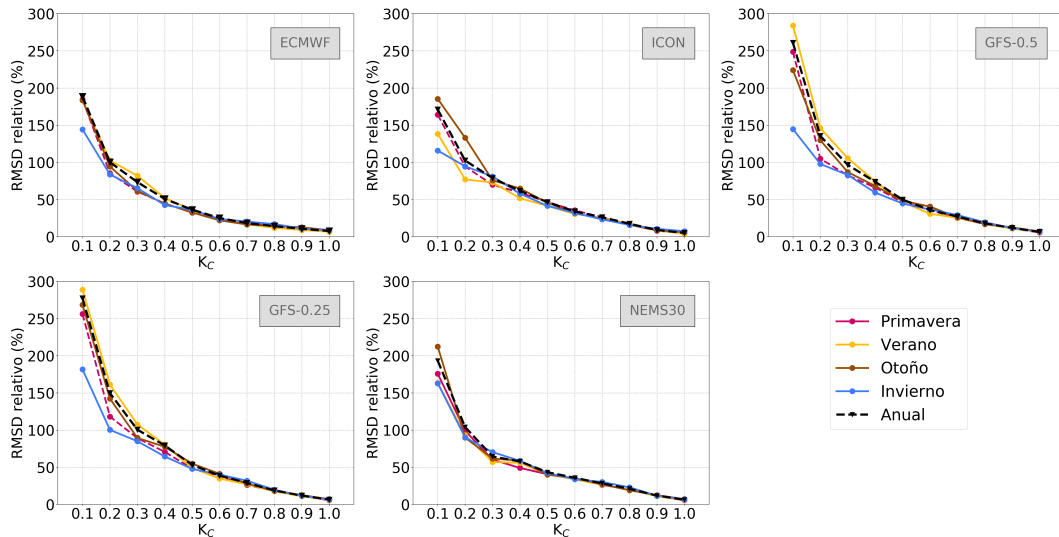


Figura 5.10: Análisis anual y estacional del rRMSD promedio entre los sitios de cada modelo en función del índice de cielo claro.

Al analizar cada modelo de la Figura 5.10 por separado, se observa un desempeño similar en las diferentes épocas del año en la mayoría de las condiciones de

cielo, con una diferencia en $K_C < 0.2$. El modelo GFS-0.5 destaca con una variación de hasta 139 % en rRMSD entre verano e invierno en $K_C = 0.1$, mientras que en $K_C = 0.4$ esta variación máxima es de 15 %, y en $K_C = 0.9$ disminuye a 1 %. En general, se confirma que en la región estudiada, la estacionalidad tiene un impacto bajo en el desempeño del pronóstico de GHI con modelos globales, siendo la nubosidad un factor más influyente. Esta variación estacional en el desempeño se explica principalmente por las diferencias en la distribución de la cantidad de días con cielo despejado, parcialmente nublado y nublado, lo que motiva a enfocar los análisis subsiguientes en una evaluación anual en lugar de considerar estaciones individuales.

Para evaluar mejor los méritos de cada modelo, en la Figura 5.11 se presentan los resultados de la evaluación anual de RMSD en función K_C en términos absolutos (Figura 5.11a) y relativos (Figura 5.11b). Ambas gráficas se complementan entre sí para explicar el comportamiento de los resultados. Por ejemplo, considerando la condición de cielo de $K_C = 0.1$, que muestra la mayor incertidumbre, se observa que el RMSD en términos absolutos varía entre 3.0 MJ/m² (ICON) y 5.0 MJ/m² (GFS-0.25), valores que superan el promedio de GHI en estas condiciones, que suelen alrededor de 2.0 MJ/m², lo que implica RMSD relativos mayores al 150 %.

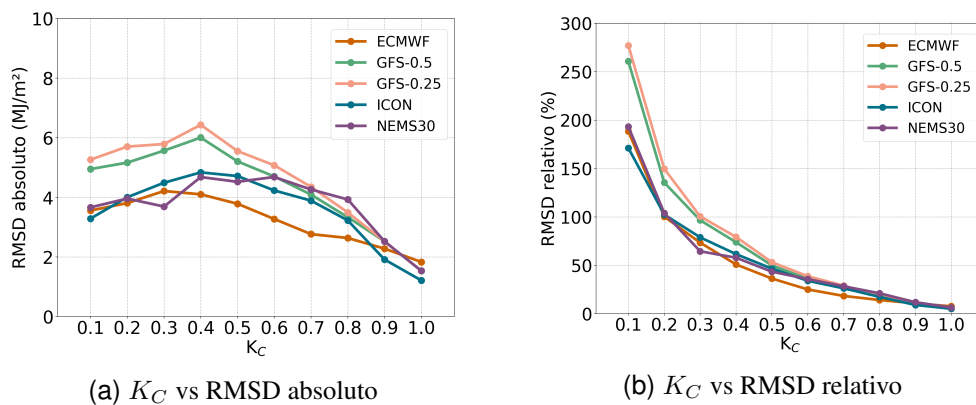


Figura 5.11: Análisis anual del rRMSD promedio entre los sitios en función de K_C .

En condiciones de alta nubosidad ($K_C = 0.1$), los modelos ICON, ECMWF y NEMS30 presentan desempeño similar, con RMSD de 3.3 MJ/m², 3.6 MJ/m² y 3.7 MJ/m², respectivamente. Mientras que los modelos GFS-0.5 y GFS-0.25, presentan mayor incertidumbre, con RMSD de 4.9 MJ/m² y de 5.2 MJ/m², respectivamente. En la Figura 5.11a, se observa que el bajo desempeño de los modelos GFS ocurren principalmente en condiciones de cielo con K_C menor de 0.5, lo que demuestra la debilidad de estos modelos en pronosticar días nublados. Por otro lado, en con-

diciones de cielo despejado ($K_C > 0.9$), se observa que los modelos NEMS30 y ECMWF presentan RMSD igual o superior que demás modelos evaluados.

5.3.3. Desempeño según la matriz de confusión

La matriz de confusión brinda una visualización con la que los modelos predicen la presencia y/o ausencia de determinados eventos. En esta tesis, esta técnica se aplica a la detección de coberturas de nubes que son la principal causa de incertidumbre en los pronósticos de la GHI. Su aplicación, comienza con clasificación de tres eventos (categorías) posibles:

- Cielo despejado, $K_C > 0.9$.
- Cielo parcialmente nublado, $K_C \geq 0.4$ y $K_C \leq 0.9$.
- Cielo nublado, $K_C < 0.4$.

A partir de la clasificación de las distintas condiciones de nubosidad se generan para cada sitio y para cada modelo una matriz de confusión de 3×3 . Debido a la baja dependencia geográfica en el desempeño de los modelos, comprobada en las secciones anteriores, esta sección presenta la matriz de confusión normalizada promediada entre todos los sitios para cada modelo. Para un análisis detallado de la matriz de confusión por sitio y por modelo, se puede consultar el Anexo 4, y para las matrices de confusión normalizadas de cada modelo en cada sitio, consulte el Anexo 5.

La Figura 5.12 presenta la matriz de confusión normalizada promediada entre los sitios para cada modelo. La diagonal principal de cada gráfica representa la tasa de predicciones pronosticadas correctamente por el modelo. Al analizar los tonos en la diagonal, se observa que el modelo ECMWF presenta diferencias notables comparado a los demás modelos. La primer característica observada es que, en condiciones de cielo despejado, el modelo ECMWF presenta la tasa de aciertos más baja entre los modelos evaluados, aproximadamente 67.2 %, mientras que el modelo ICON reporta tasa más alta, con cerca de 20.0 % más de aciertos que el modelo ECMWF. En estas condiciones, cerca de 32.8 % de los días despejados son erróneamente clasificados como parcialmente nublado por el modelo ECMWF, mientras que en el caso del modelo ICON, esta tasa es considerablemente menor, 12.8 %. Estos resultados corroboran con lo previamente por la métrica MBD en diferentes condiciones de cielo, que indicaba la tendencia del ECMWF en subestimar la

irradiación solar en días de cielo despejado. La matriz de confusión complementa esta información mostrando que el modelo identifica varios de estos días como parcialmente nublado.

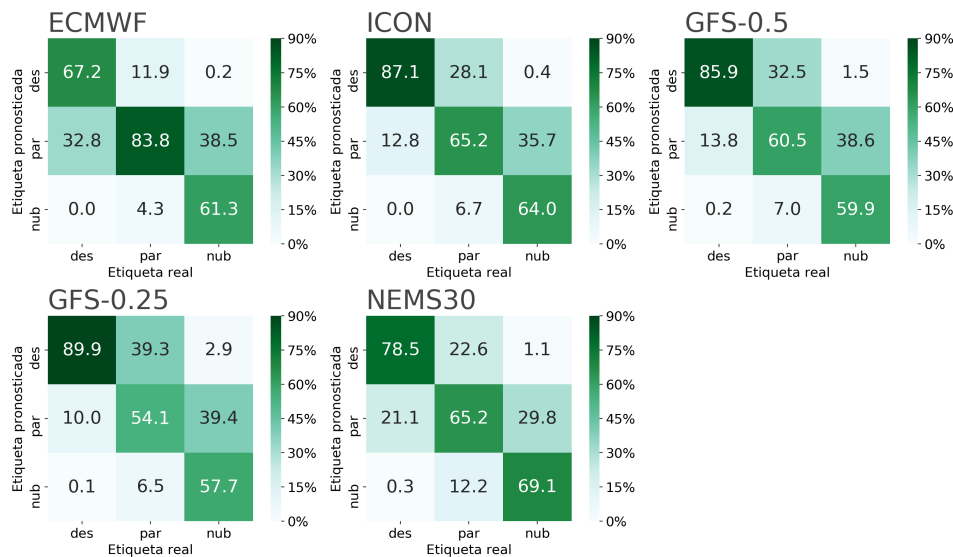


Figura 5.12: Matriz de confusión promediada entre los sitios de cada modelo.

La segunda característica atípica que se encuentra al observar en la gráfica del ECMWF, en la predicción de condiciones de cielo parcialmente nublado, cerca de 83.8 %, en contraste con el ICON que reporta una tasa de 65.2 % (Figura 5.12). La diferencia que se observa entre el ECMWF y los otros modelos se relaciona con la clasificación errónea de días parcialmente nublados como días de cielo despejado. En el caso del modelo ICON, esto representa un 28.1 % de los días, en cuanto que el ECMWF comete un error considerablemente menor, del 11.9 %.

En la categoría de cielo nublado, las tasas de acierto de los modelos NWP son más similares, oscilan entre 57.7 % (GFS-0.25) y 69.1 % (ICON), conforme muestra la Figura 5.12. La tasa de error más expresiva de esta clase se debe a los días clasificados erróneamente como parcialmente nublado, lo que indica la debilidad de los modelos en pronosticar condiciones de mucha nubosidad. Por otro lado, la Figura 5.12 muestra que es poco probable que los modelos confundan un día despejado con uno nublado, o viceversa. En otras palabras, los modelos tienen problemas en distinguir variaciones de nubosidad entre clases cercanas, pero sí lo logran distinguir las clases opuestas (despejado y nublado).

En la Tabla 5.8 se presentan el valor promedio de los indicadores obtenidos a partir de la matriz de confusión de cada sitio y de cada modelo. Los resultados

individuales por sitios se encuentran en el Anexo 4 para más detalle.

Tabla 5.8: Indicadores promedio de la precisión global de los modelos (en %).

	ECMWF	ICON	GFS-0.5	GFS-0.25	NEMS30
A_{CC}	74.0	74.0	71.0	69.0	71.0
BA	71.0	72.0	69.0	67.0	71.0
BAW	76.0	74.0	71.0	70.0	71.0

La representatividad de las métricas de la Tabla 5.8 depende de la distribución y del equilibrio de las clases evaluadas. La precisión (A_{CC}) es un indicador útil cuando la cantidad de datos en cada clase están balanceados. Caso contrario, las métricas más relevantes son la precisión balanceada (BA) o la precisión balanceada ponderada (BAW), esta última considerada más representativa en esta tesis. Esto porque la BAW permite asignar pesos relacionados con la cantidad de muestras, lo que ofrece una evaluación más justa, ante el desbalance en días clasificados como cielo despejado, parcialmente nublado y nublado.

La precisión balanceada ponderada muestra que el modelo ECMWF presenta capacidad superior para predecir las diferentes categorías de condiciones de cielo, con BAW igual a 76.0 %. En seguida, están los modelos ICON (74.0 %), NEMS30 (71.0 %), GFS-0.5 (71.0 %) y GFS-0.25 (69.0 %). Esta precisión global de los modelos coincide con la habilidad de pronóstico diaria encontrada anteriormente. La diferencia entre los resultados se debe a que el FS mide el desempeño con respecto al modelo de referencia (persistencia), mientras que BAW cuantifica la precisión general del modelo de distinguir clases de pronóstico en función de la nubosidad diaria promedio. Estas observaciones sugieren que estos indicadores son herramientas útiles y confiables para la evaluación del rendimiento de los sistemas de pronóstico.

Capítulo 6

Conclusiones

En esta tesis se documenta el diagnóstico de desempeño de las predicciones de GHI proporcionadas por diferentes modelos numéricos de la atmósfera, del tipo global, en la región sureste de Sudamérica. El presente trabajo posibilitó conocer, analizar y comparar el desempeño de varios modelos globales en Uruguay, siendo ésta la primera vez que se realizó un estudio comparativo. Los resultados obtenidos contribuyen al desarrollo de técnicas más precisas de predicción solar en nuestra región y brindan una base de comparación para el desempeño esperable. La evaluación incluyó varias métricas de uso extendido en el área (MBD, MAD, RMSD y FS), agregó un análisis de calidad de la predicción en categorías conceptuales (A_{CC} , BA, BAW), y presentó la información con diagramas visuales útiles, como la discriminación de desempeño en función de K_C .

La evaluación del pronóstico del día siguiente de la GHI se realizó en siete sitios de Uruguay mediante el análisis de cinco modelos globales: ECMWF, ICON, GFS-0.5, GFS-0.25 y NEMS30. Se han utilizado una estadística de tres años de medidas registradas en tierra. Para evaluar el desempeño en este periodo se realizaron dos análisis: en la primera, se ha empleado el periodo completo (anual); y la segunda, se ha enfocado en las diferentes estaciones del año (invierno, primavera, verano y otoño) que se produjeron durante ese mismo periodo. Se reportó el desempeño de los modelos a nivel intra-diario y diario, donde también se incluyó una evaluación por discriminación de condición de cielo. Los resultados se presentaron por sitio y también para el promedio entre los sitios.

En el análisis intra-diario se encontró que las predicciones claramente superaron el desempeño de la persistencia, que se consideró la referencia de desempeño. En el análisis del periodo anual, se observó que para los modelos evaluados,

el mejor desempeño se produjo en las horas centrales del día. De los diferentes modelos evaluados, el NEMS30 presentó el mayor desvío intra-diario, con valores de rMBD que oscilaron entre -7.1% y $+27.1\%$ y un rRMSD que varió entre 30.2% y 50.5% . Por otro lado, el modelo ECMWF presentó el menor desvío, con un indicador rMBD que osciló entre -3.0% y $+3.5\%$, y un rRMSD osciló entre 23.6% – 32.4% . En términos de rRMSD, los valores del ICON fueron muy similares, estando entre 25.0% – 34.4% . Para el modelo GFS–0.5 se encontró que el rRMSD varió entre 27.2% y 39.3% , mientras que para el GFS–0.25, los valores oscilaron entre 28.4% y 39.1% . En el análisis estacional, se obtuvieron resultados similares en las diversas estaciones, los cuales también fueron semejantes a los encontrados en la evaluación anual.

En cuanto a la evaluación a escala diaria, se encontraron indicadores de desempeño superiores en comparación con la escala intra-diaria. No solo se registraron valores más bajos de MBD, MAD y RMSD, sino que también hubo un aumento significativo en el FS por un empeoramiento de la referencia de persistencia. La variación de las métricas evaluadas entre los sitios presentaron valores bajos, tanto en la evaluación del periodo anual (un máximo de 0.4 MJ/m^2), como en la evaluación estacional (un máximo de 0.5 MJ/m^2). Esto demostró que el rendimiento de los modelos en la región no depende de una característica geográfica en particular. En lo que se refiere a desempeño, la técnica de persistencia fue inferior a todos los modelos evaluados, y a diferencia de los modelos evaluados, presentó una fuerte dependencia estacional en la región, con extremos de desempeño en los meses de invierno y verano. Los modelos ICON y ECMWF proporcionaron predicciones con menor incertidumbre, el rRMSD de la evaluación anual fue de 18.0% y de 16.7% , respectivamente. En cambio, el modelo GFS-0.25 presentó el mayor desvío y incertidumbre de los modelos evaluados, con rRMSD de 23.0% . Los modelos NEMS30 y GFS–0.5 fueron intermedios a esta escala temporal, y reportaron un rRMSD de 21.0% y 21.9% , respectivamente.

En el primer análisis complementario de la evaluación del pronóstico diario, se evaluó el desempeño de los modelos según las condiciones de cielo, utilizando la discriminación en categorías de cielo. En la evaluación anual y estacional en diferentes condiciones de cielo, se observó muy poca variabilidad entre los sitios. La desviación estándar de MBD osciló entre $0.1\text{--}0.8 \text{ MJ/m}^2$ y del RMSD varió entre $0.1\text{--}0.9 \text{ MJ/m}^2$. Esto demuestra la baja dependencia geográfica de los modelos globales evaluados en la región. El rendimiento de los pronósticos disminuyó con el aumento de la nubosidad para todos los períodos evaluados. Los modelos evaluados

subestiman la irradiación solar en condiciones de cielo despejado, independiente del período del año. En la evaluación estacional se encontró que en condiciones de cielo despejado, el modelo NEMS30 presentó el mayor desvío (MBD entre -0.3 MJ/m^2 y -1.9 MJ/m^2), mientras que el GFS-0.25 presentó el menor desvío (MBD entre -0.1 MJ/m^2 y -0.3 MJ/m^2) entre los modelos evaluados. En condiciones de cielo nublado, este comportamiento cambió, y los modelos sobreestimaron la irradiación solar. El NEMS30 presentó el menor desvío (MBD entre $+1.3 \text{ MJ/m}^2$ y $+3.2 \text{ MJ/m}^2$), y el GFS-0.25 presentó el desvío mayor (MBD entre $+1.1 \text{ MJ/m}^2$ y $+7.5 \text{ MJ/m}^2$). Además, se encontró que el periodo de verano presentó el mayor desvío en condiciones de nubosidad en todos los modelos evaluados.

En el segundo análisis complementario de la evaluación del pronóstico diario, se relacionó el RMSD y el índice de cielo claro. La propuesta basada en Lara-Fanego et al. (2012) mostró que el desempeño de cada modelo fue bastante similar en las diferentes épocas del año. Los resultados del análisis también indicaron que la variabilidad estacional, encontrada en el primer análisis con K_C , no está relacionada con la capacidad de los modelos, sino está principalmente relacionada con la distribución de muestras claras, parcialmente nubladas, y nubladas en cada periodo. En condiciones de alta nubosidad los pronósticos de los modelos ECMWF, ICON y NEMS presenta menor incertidumbre, con RMSD de 3.3 MJ/m^2 , 3.6 MJ/m^2 y 3.7 MJ/m^2 , respectivamente. Los modelos GFS-0.5 y GFS-0.25 presentan mayor incertidumbre en sus pronósticos a partir de un K_C menor que 0.5.

En el tercer y ultimo análisis complementario de la evaluación del pronóstico diario, se utilizó la matriz de confusión de los modelos. Este análisis mostró que la baja precisión del modelo ECMWF en predecir condiciones de cielo despejado se debe a su tendencia a pronosticar erróneamente varios de estos días como parcialmente nublados. El indicador general basado en la capacidad de los modelos para clasificar las distintas condiciones de cielo indicó que el modelo ECMWF con la mayor precisión (BAW de 76.0 %). En segundo lugar se encuentra el ICON (BAW de 74.0 %), seguido del NEMS30 (BAW de 71.0 %), GFS-0.5 (BAW de 71.0 %) y GFS-0.25 (BAW de 70.0 %).

Después de analizar los resultados presentados, se concluye que el desempeño de los modelos evaluados no presentan dependencia geográfica o estacional. La baja variabilidad de desempeño en las diferentes épocas del año son novedosas en la región y se trata de una información relevante que permite afirmar que los modelos evaluados no requerirían correcciones mayores según la época del año. En lo que se refiere al diagnostico del desempeño de los modelos de pronóstico, se identifica-

ron fortalezas y debilidades en todos ellos. El modelo ECMWF presentó el mejor desempeño observado hasta la fecha para un NWP en la región, resultado que es consistente con estudios previamente informados en otras partes del mundo. Sin embargo, este modelo presenta una tendencia en subestimar la irradiación disponible en condiciones de cielo despejado, además de que su acceso que es restricto. El modelo ICON presentó desempeño muy cercano al ECMWF, lo que representa una buena alternativa considerando que sus pronósticos son de dominio publico. El modelo GFS-0.5 presentó resultados competitivos, aunque por debajo del europeo y del ICON, y sus pronósticos también son de dominio publico. El análisis de la matriz confusión permitió identificar que los modelos son capaces de distinguir condiciones de nubosidad muy disímiles, pero tienen dificultades cuando las condiciones de nubosidad varían poco, por ejemplo, entre despejado y parcialmente nublado, y entre parcialmente nublado y nublado. Los pronósticos del modelo NEMS30 se presentaron peor desempeño intra-diario, sin embargo en la evaluación diaria se mostraron competitivos principalmente en días nublados, lo cual puede estar relacionado con alguna técnica de postproceso desconocida que es aplicada por la empresa propietaria.

Para trabajos futuros, se pretende establecer estrategias que permitan reducir la incertidumbre de los modelos globales para predecir la energía solar mediante el uso de técnicas de postproceso. El paso siguiente, está relacionado con el desarrollo del pronóstico probabilístico utilizando ensembles para predecir hasta cinco días para adelante. Hasta la fecha no se ha desarrollado pronósticos probabilísticos en Uruguay y la región para estos horizontes de predicción de la energía solar. Se pretende evaluar el desempeño de diversos modelos globales que cuentan con ensembles sin postproceso y avanzar en el uso de técnicas de postproceso probabilístico lineal y no lineal.

Lista de figuras

2.1	Relación entre horizonte temporal de pronóstico y resolución espacial	7
2.2	Tipos de las grillas de los modelos NWP	10
2.3	Ejemplo de una matriz confusión	17
3.1	Datos horarios de la estación LE (01/2017–12/2020).	24
3.2	Serie temporal diurna de GHI pronosticada	26
3.3	Estacionalidad mensual de GHI medida y pronosticada.	32
4.1	GHI promedio en cada hora del día.	34
4.2	Dispersión horaria de los modelos de pronóstico	34
4.3	Desempeño intra-diario del pronóstico del día siguiente	35
4.4	Habilidad de pronóstico de intra-diario	38
4.5	Desvío medio intra-diario estacional y anual	39
4.6	Desvío cuadrático medio intra-diario estacional y anual	41
4.7	Habilidad de pronóstico intra-diario estacional y anual	42
5.1	Dispersión diaria de los modelos de pronóstico	44
5.2	Desempeño del pronóstico diario por sitio	44
5.3	RMSD diario en cada sitio en diferente épocas del año (en %)	47
5.4	Desempeño diario estacional de los modelos de pronóstico	48
5.5	Porcentaje de días en diferentes condiciones de cielo	51
5.6	MBD de diferentes condiciones de cielo	52
5.7	RMSD de diferentes condiciones de cielo	53
5.8	Metodología base para relacionar rRMSD en función del K_T	55
5.9	RMSD relativo de los modelos evaluados en función del K_T	55
5.10	RMSD relativo de los modelos evaluados en función del K_C	56
5.11	RMSD relativo anual de los modelos evaluados en función del K_C	57
5.12	Matriz de confusión de los modelos globales	59

1.1	Dispersión intra-diaria de la persistencia	72
2.1	MBD intra-diario: evaluación estacional	81
2.2	RMSD intra-diario: evaluación estacional	82
4.1	Matriz confusión por sitio: ECMWF	88
4.2	Matriz confusión por sitio: ICON	88
4.3	Matriz confusión por sitio: GFS-0.5	89
4.4	Matriz confusión por sitio: GFS-0.25	89
4.5	Matriz confusión por sitio: NEMS30	89
5.1	Matriz confusión normalizada por sitio: ECMWF	91
5.2	Matriz confusión normalizada por sitio: ICON	91
5.3	Matriz confusión normalizada por sitio: GFS-0.5	92
5.4	Matriz confusión normalizada por sitio: GFS-0.25	92
5.5	Matriz confusión normalizada por sitio: NEMS30	92

Lista de tablas

2.1	Modelos globales operativos en el mundo	13
2.2	Review desempeño de los modelos NWP	19
3.1	Ubicación de las estaciones de medida utilizadas	23
3.2	Configuración de los modelos utilizados	25
3.3	Promedio horario de la GHI medida y pronosticada (2017–2019) . .	30
3.4	Promedio horario de la GHI medida y pronosticada (2018–2020) . .	30
3.5	Cantidad de días evaluados	31
3.6	Estacionalidad de la GHI en Uruguay	31
4.1	Una tabla junto a una figura	34
4.2	Desempeño intra-diario del primer día de pronóstico	36
4.3	Habilidad de pronóstico intra-diario	37
4.4	MBD intra-diario (%): evaluación estacional	39
4.5	RMSD intra-diario (%): evaluación estacional	40
4.6	Habilidad de pronóstico intra-diario: evaluación estacional	42
5.1	Desempeño diario del primer día de pronóstico	45
5.2	RMSD diario (%): evaluación estacional	48
5.3	Cantidad de días según la condición del cielo: referencia	50
5.4	Cantidad de días según la condición del cielo: modelos evaluados . .	51
5.5	Desempeño diario discriminado por condiciones de cielo	52
5.6	MBD de diferente condiciones de cielo: evaluación estacional . . .	53
5.7	RMSD de diferente condiciones de cielo: evaluación estacional . . .	54
5.8	Indicadores de precisión según la matriz de confusión	60
1.1	MBD por sitio para cada modelo	73
1.2	MBD relativo por sitio para cada modelo	74
1.3	MAD por sitio para cada modelo	75

1.4	MAD relativo por sitio para cada modelo	76
1.5	RMSD por sitio para cada modelo	77
1.6	RMSD relativo por sitio para cada modelo	78
1.7	FS por sitio para cada modelo	79
2.1	MBD intra-diario: evaluación estacional	81
2.2	RMSD intra-diario: evaluación estacional	82
3.1	Desempeño diario por sitio	84
3.2	Desempeño por sitio según condición de cielo: ECMWF	85
3.3	Desempeño por sitio según condición de cielo: ICON	85
3.4	Desempeño por sitio según condición de cielo: GFS-0.5	86
3.5	Desempeño por sitio según condición de cielo: GFS-0.25	86
3.6	Desempeño por sitio según condición de cielo: NEMS30	87
4.1	Precisión por sitio según la matriz confusión	90

Referencias bibliográficas

- Abal, G., Alonso-Suárez, R., & Laguarda, A. (2020). *Notas del curso fundamentos del recurso solar*. (inf. téc.). Laboratorio de Energía Solar, Universidad de la República.
- Aicardi, D., Musé, P., & Alonso-Suárez, R. (2022). A comparison of satellite cloud motion vectors techniques to forecast intra-day hourly solar global horizontal irradiation. *Solar Energy*, 233, 46-60.
- Alonso-Suárez, R., Abal, G., Siri, R., & Muse, P. (2014). Satellite-derived solar irradiation map for Uruguay. *Energy Procedia*, 57, 1237-1246.
- Alonso-Suárez, R., David, M., Texeira-Branco, V., & Lauret, P. (2020). Intra-day solar probabilistic forecasts including local short-term variability and satellite information. *Renewable Energy*, 158, 554-573.
- Alonso-Suárez, R., Marchesoni, F., Dovat, L., & Laguarda, A. (2021). Satellite-Based Operational Solar Irradiance Forecast for Uruguay's Solar Power Plants. *2021 IEEE URUCON*.
- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar Energy*, 136, 78-111.
- Bird, L., Milligan, M., & Lew, D. (2013). *Integrating variable renewable energy: Challenges and solutions* (inf. téc.). National Renewable Energy Lab.(NREL).
- Buizza, R. (2021). Chapter 3 - Probabilistic view of numerical weather prediction and ensemble prediction. En *Uncertainties in Numerical Weather Prediction* (pp. 81-117). Elsevier.
- Buizza, R., Houtekamer, P. L., Pellerin, G., Toth, Z., Zhu, Y., & Wei, M. (2005). A Comparison of the ECMWF, MSC, and NCEP Global Ensemble Prediction Systems. *Monthly Weather Review*, 133, 1076-1097.

- Caldas, M., & Alonso-Suárez, R. (2019). Very short-term solar irradiance forecast using all-sky imaging and real-time irradiance measurements. *Renewable Energy*, *143*, 1643-1658.
- Charney, J. G., Fjörtoft, R., & Neumann, J. V. (1950). Numerical integration of the barotropic vorticity equation. *Tellus*, *2*, 237-254.
- Chu, Y., Pedro, H. T., & Coimbra, C. F. (2013). Hybrid intra-hour DNI forecasts with sky image processing enhanced by stochastic learning. *Solar Energy*, *98*, 592-603.
- Clough, S., Shephard, M., Mlawer, E., Delamere, J., Iacono, M., Cady-Pereira, K., Boukabara, S., & Brown, P. (2005). Atmospheric radiative transfer modeling: a summary of the AER codes. *Journal of Quantitative Spectroscopy and Radiative Transfer*, *91*, 233-244.
- Coimbra, C. F. M., Kleissl, J., & Marquez, R. (2013). Chapter 8 – Overview of Solar-Forecasting Methods and a Metric for Accuracy Evaluation. *Solar Energy Forecasting and Resource Assessment*, 171-194.
- Coimbra, C. F., & Pedro, H. T. (2013). Chapter 15 - Stochastic-Learning Methods. En J. Kleissl (Ed.), *Solar Energy Forecasting and Resource Assessment* (pp. 383-406). Academic Press.
- Collard, A., Hilton, F., Forsythe, M., & Candy, B. (2011). From Observations to Forecasts – Part 8: The use of satellite observations in numerical weather prediction. *Weather*, *66*.
- Congalton, R. (1991). A review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, *37*, 35-46.
- Daley, R. (1991). *Atmospheric data analysis*. Cambridge University Press.
- Das, U. K., Tey, K. S., Seyedmahmoudian, M., Mekhilef, S., Idris, M. Y. I., Van Deventer, W., Horan, B., & Stojcevski, A. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable and Sustainable Energy Reviews*, *81*, 912-928.
- David, M., & Lauret, P. (2018). Solar radiation probabilistic forecasting. En R. Perez (Ed.), *Wind Field and Solar Radiation Characterization and Forecasting* (pp. 201-227). Atmospheric Sciences Research Center.
- Diagne, M., David, M., Boland, J., Schmutz, N., & Lauret, P. (2014). Postprocessing of solar irradiance forecasts from WRF model at reunion island. *Energy Procedia*, *57*, 1364-1373.

- Diagne, M., David, M., Lauret, P., Boland, J., & Schmutz, N. (2013). Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27, 65-76.
- Dudhia, J. (2014). A history of mesoscale model development. *Asia-Pacific Journal of Atmospheric Sciences*, 50, 121-131.
- Duffie, J. A., & Beckman, W. A. (2013). Solar Radiation. En *Solar Engineering of Thermal Processes* (Second Edition, pp. 3-42). John Wiley; Sons, Ltd.
- Erdener, B. C., Feng, C., Doubleday, K., Florita, A., & Hodge, B.-M. (2022). A review of behind-the-meter solar forecasting. *Renewable and Sustainable Energy Reviews*, 160, 112224.
- Fabel, Y., Nouri, B., Wilbert, S., Blum, N., Triebel, R., Hasenbalg, M., Kuhn, P., Zarzalejo, L. F., & Pitz-Paal, R. (2022). Applying self-supervised learning for semantic cloud segmentation of all-sky images. *Atmospheric Measurement Techniques*, 3, 797-809.
- Feng, C., Zhang, J., Zhang, W., & Hodge, B.-M. (2022). Convolutional neural networks for intra-hour solar forecasting based on sky image sequences. *Applied Energy*, 310, 118438.
- Ghimire, S., Deo, R. C., Raj, N., & Mi, J. (2019). Deep solar radiation forecasting with convolutional neural network and long short-term memory network algorithms. *Applied Energy*, 253, 113541.
- Giacosa, G. (2020). *Pronóstico de la energía solar a partir de imágenes satelitales* (Tesis de maestría). Facultad de Ingeniería, Universidad de la República (Uruguay).
- Giacosa, G., & Alonso-Suárez, R. (2018). Desempeño de la persistencia para la predicción del recurso solar en Uruguay. *Revista Brasileira de Energía Solar*, 9, 107-116.
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for Multi-Class Classification: an Overview. <https://arxiv.org/abs/2008.05756>
- Gupta, A., Tatbul, N., Marcus, R., Zhou, S., Lee, I., & Gottschlich, J. (2020). Class-Weighted Evaluation Metrics for Imbalanced Data Classification. <https://arxiv.org/abs/2010.05995>
- Heydarian, C., Doyle, T., & Samavi, R. (2022). MLCM: Multi-Label Confusion Matrix. *IEEE Acces*, 10, 19083-19095.
- Hogan, R. J., & Bozzo, A. (2018). A flexible radiation scheme for the ECMWF model. *Journal of Advances in Modeling Earth Systems*, 10, 1990-2008.

- Hólm, E., Forbes, R., Lang, S., Magnusson, L., & Malardel, S. (2016). *New model cycle brings higher resolution* (inf. téc.). ECMWF.
- Iacono, M. J., Delamere, J. S., Mlawer, E. J., Shephard, M. W., Clough, S. A., & Collins, W. (2008). Radiative forcing by long-lived greenhouse gases: Calculations with the aer radiative transfer model. *Journal de Geophysical Research*, 113.
- Iacono, M. J., Mlawer, E. J., Clough, S. A., & Morcrette, J. (2000). Impact of an improved longwave radiation model, RRTM, on the energy budget and thermodynamic properties of the NCAR community climate model, CCM3. *Journal de Geophysical Research*, 105, 14873-14890.
- IEA. (2022). *Solar PV* (inf. téc.). International Energy Agency.
- Inman, R. H., Pedro, H. T., & Coimbra, C. F. (2013). Solar forecasting methods for renewable energy integration. *Progress in Energy and Combustion Science*, 39(6), 535-576.
- Iqbal, M. (1983). Chapter 4 - Extraterrestrial solar irradiation. En *An Introduction to Solar Radiation* (pp. 59-84). Academic Press.
- IRENA. (2019). *Future of Solar Photovoltaic: Deployment, investment, technology, grid integration and socio-economic aspects (A Global Energy Transformation: paper)* (inf. téc.). International Renewable Energy Agency, Abu Dhabi.
- Jiménez, P. A., Dudhia, J., Thompson, G., Lee, J. A., & Brummet, T. (2022). Improving the cloud initialization in WRF-Solar with enhanced short-range forecasting functionality: The MAD-WRF model. *Solar Energy*, 239, 221-233.
- Kalnay, E. (2002). *Atmospheric Modeling, Data Assimilation and Predictability*. Cambridge University Press.
- Katiraei, F., & Agüero, J. (2011). Solar pv integration challenges. *IEEE Power Energy Magazine*, 9(5), 62-71.
- Kühnert, J., Lorenz, E., & Heinemann, D. (2013). Chapter 11 - Satellite-Based Irradiance and Power Forecasting for the German Energy Market. En J. Kleissl (Ed.), *Solar Energy Forecasting and Resource Assessment* (pp. 267-297). Academic Press.
- Kurihara, Y. (1965). Numerical integration of the primitive equations on a spherical grid. *Monthly Weather Review*, 93, 399-415.
- Laguarda, A., Giacosa, G., Alonso-Suárez, R., & Abal, G. (2020). Performance of the site-adapted CAMS database and locally adjusted cloud index models for estimating global solar horizontal irradiation over the Pampa Húmeda. *Solar Energy*, 199, 295-307.

- Lara-Fanego, V., Ruiz-Arias, J., Pozo-Vázquez, D., Santos-Alamillos, F., & Tovar-Pescador, J. (2012). Evaluation of the WRF model solar irradiance forecasts in Andalusia (southern Spain). *Solar Energy*, *86*, 2200-2217.
- Lauret, P., Alonso-Suárez, R., Le Gal La Salle, J., & David, M. (2022). Solar Forecasts Based on the Clear Sky Index or the Clearness Index: Which Is Better? *Solar*, *2*, 432-444.
- Lauret, P., Lorenz, E., & David, M. (2016). Solar Forecasting in a Challenging Insular Context. *Atmosphere*, *7*.
- Lefèvre, M., Oumbe, A., Blanc, P., Espinar, B., Gschwind, B., Qu, Z., Wald, L., Schroedter-Homscheidt, M., Hoyer-Klick, C., Arola, A., Benedetti, A., Kaiser, J. W., & Morcrette, J. J. (2013). McClear: a new model estimating downwelling solar radiation at ground level in clear-sky conditions. *Atmospheric Measurement Techniques*, *6*, 2403-2418.
- Li, B., & Zhang, J. (2020). A review on the integration of probabilistic solar forecasting in power systems. *Solar Energy*, *210*, 68-86.
- 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.
- Logothetis, S.-A., Salamalikis, V., Nouri, B., Remund, J., Zarzalejo, L. F., Xie, Y., Wilbert, S., Ntavelis, E., Nou, J., Hendrikx, N., Visser, L., Sengupta, M., Pó, M., Chauvin, R., Grieu, S., Blum, N., Sark, W. v., & Kazantzidis, A. (2022). Solar Irradiance Ramp Forecasting Based on All-Sky Imagers. *Energies*, *15*.
- Lorenz, E., Hammer, A., & Heinemann, D. (2004). Short term forecasting of solar radiation based on satellite data. *ISES Europe Solar Congress*.
- Lorenz, E., Kühnert, J., Heinemann, D., Nielsen, K. P., Remund, J., & Müller, S. C. (2016). Comparison of global horizontal irradiance forecasts based on numerical weather prediction models with different spatio-temporal resolutions. *Progress in Photovoltaics: Research and Applications*, *24*, 1626-1640.
- Lorenz, E., Hurka, J., Heinemann, D., & Beyer, H. G. (2009). Irradiance Forecasting for the Power Prediction of Grid-Connected Photovoltaic Systems. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *2*, 2-10.
- Lusi, A., Orte, F., Alonso-Suárez, R., Délía, R., & Wolfram, E. (2023). Evaluación de los modelos de radiación solar global Heliosat-4 y McClear en dos sitios de Argentina. *Anales AFA*, *34*, 76-81.

- Lynch, P. (2008). The origins of computer weather prediction and climate modeling. *Journal of Computational Physics*, 227, 3431-3444.
- Macrae, N. (2019). *John von Neumann: The scientific genius who pioneered the modern computer, game theory, nuclear deterrence, and much more*. Plunkett Lake Press.
- Marchesoni-Acland, F., & Alonso-Suárez, R. (2020). Intra-day solar irradiation forecast using RLS filters and satellite images. *Renewable Energy*, 161, 1140-1154.
- Marchesoni-Acland, F., Herrera, A., Mozo, F., Camiruaga, I., Castro, A., & Alonso-Suárez, R. (2023). Deep learning methods for intra-day cloudiness prediction using geostationary satellite images in a solar forecasting framework. *Solar Energy*, 262, 111820.
- Marquez, R., & Coimbra, C. F. (2013). Intra-hour DNI forecasting based on cloud tracking image analysis. *Solar Energy*, 91, 327-336.
- Meteoblue. (2011). *Weather model theory*. <https://content.meteoblue.com/en/research-education/educational-resources/weather-model-theory>
- Mills, A., Ahlstrom, M., Brower, M., Ellis, A., George, R., Hoff, T., Kroposki, B., Lenox, C., Miller, N., Stein, J., & Wan, Y.-h. (2009). *Understanding variability and uncertainty of photovoltaics for integration with the electric power system* (inf. téc.). Ernest Orlando Lawrence Berkeley National Laboratory.
- Milton, S. F., & Wilson, C. A. (1996). The Impact of Parameterized Subgrid-Scale Orographic Forcing on Systematic Errors in a Global NWP Model. *Monthly Weather Review*, 124, 2023-2045.
- Mlawer, E. J., Taubman, S., Brown, P. D., Iacono, M. J., & Clough, S. A. (1997). Radiative transfer for inhomogeneous atmospheres: Rrtm, a validated correlated-k model for the longwave. *Journal de Geophysical Research*, 102, 16663-16682.
- Peel, M. C., Finlayson, B. L., & McMahon, T. A. (2007). Updated world map of the Köppen-Geiger climate classification. *Hydrology and Earth System Sciences*, 11, 1633-1644.
- Pelland, S., Galanis, G., & Kallos, G. (2013). Solar and photovoltaic forecasting through post-processing of the Global Environmental Multiscale numerical weather prediction model. *Progress in Photovoltaics: Research and Applications*, 21, 284-296.

- Pereira, R. B., Plastino, A., Zadrozny, B., & Merschmann, L. H. (2018). Correlation analysis of performance measures for multi-label classification. *Information Processing & Management*, 54, 359-369.
- Perez, R., Kivalov, S., Schlemmer, J., Hemker, K., Renne, D., & Hoff, T. (2010). Validation of short and medium term operational solar radiation forecasts in the US. *Solar Energy*, 84, 2161-2172.
- Perez, R., Lorenz, E., Pelland, S., Beauharnois, M., Van Knowe, G., Hemker, K., Heinemann, D., Remund, J., Müller, S. C., Traunmüller, W., Steinmayer, G., Pozo, D., Ruiz-Arias, J. A., Lara-Fanego, V., Ramirez-Santigosa, L., Gaston-Romero, M., & Pomares, L. M. (2013). Comparison of numerical weather prediction solar irradiance forecasts in the US, Canada and Europe. *Solar Energy*, 94, 305-326.
- Porrini, C. (2017). *Evaluación del modelo regional WRF para pronósticos de radiación solar en superficie dentro del territorio uruguayo*. (Tesis de grado). Facultad de Ciencias. Universidad de la República (Uruguay).
- Porrini, C., Gutiérrez, A., Cazes Boezio, G., Hermida, G., Oroño, D., & Puppo, M. (2015). Development of a Model Output Statistic and implementation of an operational solar photovoltaic energy forecast model based in WRF. *IEEE PES Innovative Smart Grid Technologies Latin America (ISGT LATAM)*, 248-253.
- Qin, J., Jiang, H., Lu, N., Yao, L., & Zhou, C. (2022). Enhancing solar PV output forecast by integrating ground and satellite observations with deep learning. *Renewable and Sustainable Energy Reviews*, 167, 112680.
- Reikard, G. (2009). Predicting solar radiation at high resolutions: a comparison of time series forecasts. *Solar Energy*, 83, 342-349.
- Remund, J., Perez, R., & Lorenz, E. (2008). Comparison of solar radiation forecasts for the USA. *European PV Conference*.
- Richardson, L. F. (1922). *Weather prediction by numerical process*. Cambridge University Press.
- Rieger, D., Köhler, M., Hogan, R. J., Schäfer, S. A. K., Seifert, A., de Lozar, A., & Zängl, G. (2019). *ecRad in ICON - Details on the Implementation and First Results* (inf. téc.). ICON - Deutscher Wetterdienst.
- Shuman, F. G., & Hovermale, J. B. (1968). An Operational Six-Layer Primitive Equation Model. *Journal of Applied Meteorology and Climatology*, 7, 525-547.

- Sianturi, Y., Sopaheluwakan, A., & Sartika, K. A. (2021). Evaluation of ECMWF model to predict daily and monthly solar radiation over Indonesia region. *IOP Conference Series: Earth and Environmental Science*, 893, 012074.
- Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D., Barker, D., Duda, M., Huang, X., Wang, W., & Powers, J. (2008). *A description of the advanced research WRF* (inf. téc.). NCAR.
- Spencer, J. (1971). Fourier Series Representation of the Position of the Sun. *Search* 2, 172.
- Stensrud, D. J. (2007). *Parameterization Schemes: Keys to Understanding Numerical Weather Prediction Models*. Cambridge University Press.
- Teixeira-Branco, V., Alonso-Suárez, R., & Cazes, G. (2022). Pronóstico del día siguiente de la radiación solar en la región de la Pampa Húmeda: Análisis de desempeño del modelo GFS. *Anais do IX Congresso Brasileiro de Energia Solar*.
- Teixeira-Branco, V., Alonso-Suárez, R., & David, M. (2021). Performance assessment of the ECMWF solar irradiation forecast in the Pampa Húmeda region of South America. *Proceedings of the ISES Solar World Congress*.
- Teixeira-Branco, V., Alonso-Suárez, R., de Almeida, E., Porrini, C., Gutiérrez, A., & Cazes, G. (2018). Evaluación del pronóstico de irradiación solar diaria en Uruguay utilizando el modelo WRF. *Anais do VII Congresso Brasileiro de Energia Solar*.
- 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.
- Verzijlbergh, R. A., Heijnen, P. W., R., S., Los, A., & Jonker, H. J. (2015). Improved model output statistics of numerical weather prediction based irradiance forecasts for solar power applications. *Solar Energy*, 118, 634-645.
- Victoria, M., Haegel, N., Peters, I. M., Sinton, R., Jager-Waldau, A., del Cañizo, C., Breyer, C., Stocks, M., Blakers, A., Kaizuka, I., Komoto, K., & Smets, A. (2021). Solar photovoltaics is ready to power a sustainable future. *Joule*, 5(5), 1041-1056.
- Visser, L., Lorenz, E., Heinemann, D., & van Sark, W. G. (2022). 1.11 - Solar Power Forecasts. En *Comprehensive Renewable Energy* (Second Edition, pp. 213-233). Elsevier.

- Wang, N. (2021). Chapter 2 - Numerical uncertainties in discretization of the shallow-water equations for weather prediction models. En *Uncertainties in Numerical Weather Prediction* (pp. 47-80). Elsevier.
- WMO. (2020). *GDPFS and NWP Annual Progress Reports* (inf. téc.). World Meteorological Organization.
- Yang, D. (2020). Choice of clear-sky model in solar forecasting. *Journal of Renewable and Sustainable Energy*, 12, 026101.
- Yang, D., Alessandrini, S., Antonanzas, J., Antonanzas-Torres, F., Badescu, V., Beyer, H. G., Blaga, R., Boland, J., Bright, J. M., Coimbra, C. F., David, M., Frimane, Â., Gueymard, C. A., Hong, T., Kay, M. J., Killinger, S., Kleissl, J., Lauret, P., Lorenz, E., ... Zhang, J. (2020). Verification of deterministic solar forecasts. *Solar Energy*, 210, 20-37.
- Yang, D., Kleissl, J., Gueymard, C. A., Pedro, H. T., & Coimbra, C. F. (2018). History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Solar Energy*, 168, 60-101.
- Yang, D., Wang, W., Gueymard, C. A., Hong, T., Kleissl, J., Huang, J., Perez, M. J., Perez, R., Bright, J. M., Xia, X., van der Meer, D., & Peters, I. M. (2022). A review of solar forecasting, its dependence on atmospheric sciences and implications for grid integration: Towards carbon neutrality. *Renewable and Sustainable Energy Reviews*, 161, 112348.

APÉNDICES

Apéndice 1

Conceptos básicos de radiación solar

Este apéndice describe algunos conceptos básicos relacionados con la radiación solar cuyo conocimiento es necesario para la tesis y están referenciados en el texto.

Ubicar la posición del Sol es necesario en diferentes cálculos relacionados al recurso solar. El ángulo cenital, que se define en la Ecuación 1.1, es el ángulo que permite identificar la posición del Sol en un determinado lugar y momento. El ángulo cenital es el ángulo formado por la dirección de la línea Tierra-Sol y la normal del observador,

$$\cos \theta_z = \sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega, \quad (1.1)$$

donde, ϕ es la latitud del observador, δ es la declinación solar y ω es el ángulo horario. La declinación solar se define como el ángulo formado entre el plano orbital de la Tierra y el plano ecuatorial. Según Spencer (1971), se calcula como:

$$\begin{aligned} \delta = & 0.006918 - 0.399912 \cos(\Gamma) + 0.070257 \sin(\Gamma) - 0.006758 \cos(2\Gamma) \\ & + 0.000907 \sin(2\Gamma) - 0.002697 \cos(3\Gamma) + 0.00148 \sin(3\Gamma), \end{aligned} \quad (1.2)$$

donde $\Gamma = 2\pi(n-1)/365$, en que la n corresponde al día juliano. El ángulo horario es el ángulo de rotación de la Tierra con respecto a su eje. Este ángulo describe el desplazamiento angular del Sol de Este a Oeste y se calcula a partir de la Ecuación 1.3,

$$\omega = \frac{\pi}{12}(t_s - 1) \quad (1.3)$$

siendo t_s la hora solar, calculada como:

$$t_s = t_{UTC} + \frac{\psi - \psi_{UTC}}{15} + \frac{E}{60} \quad (1.4)$$

donde t_{UTC} es la hora local civil, ψ es la longitud local, ψ_{UTC} es la longitud de huso, que para la región de estudio es UTC-3, que corresponde a -45° . La E corresponde a ecuación del tiempo en minutos, calculada según Spencer (1971), conforme la Ecuación (1.5).

$$E = 229.18[0.0000075 + 0.001868 \cos(\Gamma) - 0.032077 \sin(\Gamma) - 0.014615 \cos(2\Gamma) - 0.04089 \sin(2\Gamma)] \quad (1.5)$$

El ángulo complementario del ángulo cenital, se conoce como altura solar (α). La altura solar es el formado por la línea Tierra-Sol y el horizonte del observador. El azimuth solar describe la orientación de la línea Tierra-Sol sobre el plano horizontal del observador. Por convención se considera negativo la mañana y positivo a la tarde, siendo igual 0° al mediodía solar, cuando el Sol se encuentra en su punto más alto. Iqbal (1983) calcula la altura solar como:

$$\gamma_S = \text{signo}(\omega) \left| \arccos \left(\frac{\sin \delta \cos \phi - \cos \delta \sin \phi \cos \omega}{\cos \alpha_S} \right) \right|. \quad (1.6)$$

Para definir otras variables a nivel de superficie terrestre es necesario primero definir irradiación que incide en un plano horizontal en el tope de la atmósfera, definida por Iqbal (1983) como:

$$G_{oh} = G_{sc} F_n \cos \bar{\theta}_z, \quad (1.7)$$

siendo $I_{sc} = 1367 \text{ Wh/m}^2$, F_n el factor orbital, y el $\cos \bar{\theta}_z$ corresponde al coseno del ángulo cenital evaluado en el medio del intervalo horario. El factor orbital se define como muestra la Ec. 1.8,

$$F_n = 1.000110 + 0.034221 \cos(\Gamma) + 0.001280 \sin(\Gamma) \\ + 0.000719 \cos(2\Gamma) + 0.000077 \sin(2\Gamma) \quad (1.8)$$

El cociente entre la irradiación global y la irradiación en el tope de la atmósfera en un plano horizontal es lo que se conoce como índice de claridad,

$$k_T = \frac{G_h}{G_{oh}} \quad (1.9)$$

Otra variable adimensionada de interés en esta tesis es el índice de cielo claro. El índice de cielo claro es resultado del cociente entre la irradiación global y la irradiación en caso de no haber nubes, ($G_{h,cks}$). Esta última variable en general se obtiene de modelos de estimación.

$$k_c = \frac{G_h}{G_{h,cks}} \quad (1.10)$$

A escala diaria, el índice de claridad (K_T) y índice de cielo despejado (K_C) se calculan de la misma manera, pero se utilizan los acumulados diarios de las respectivas variables de entrada.

ANEXOS

Anexo 1

Desempeño anual intra-diario por sitio

La Figura 1.1 muestra la gráfica de dispersión de la técnica de persistencia.




Figura 1.1: Dispersión intra-diaria de la persistencia.

Tabla 1.1: MBD por sitio para cada modelo, en términos absolutos (Wh/m²).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
LE	+4.5	+5.9	+8.5	+9.6	+8.5	-5.6	-9.8	-18.8	-23.4	-16.2	-7.9	-1.7
AR	+13.9	+14.3	+6.8	+10.2	+11.9	+7.1	-2.9	-6.7	-18.9	-12.8	-7.5	-3.9
TA	+8.5	+12.2	+18.6	+13.0	+2.2	-8.0	-15.7	-12.2	-15.9	-16.9	-9.1	-4.2
LB	-1.5	+2.8	+7.7	+11.5	+8.2	+3.4	+1.7	-0.4	-5.8	-3.4	-0.2	+2.1
RC	+0.3	+1.5	+6.2	+6.4	+7.0	+3.8	+1.3	-4.5	-8.0	-7.6	-2.5	+0.9
ZU	+1.2	+4.1	+10.1	+13.9	+13.7	+22.5	+17.1	+10.7	+3.8	+2.2	+3.5	+3.1
PP	+9.5	+8.3	+9.6	+3.2	-2.3	-5.8	-12.3	-19.5	-16.0	-12.4	-8.6	-2.7
ICON												
LE	+14.3	+17.9	+20.0	+16.1	+11.8	+12.4	+16.0	+9.0	+0.5	+0.7	+2.8	+2.8
AR	+22.9	+28.0	+27.6	+20.8	+22.1	+20.9	+26.4	+21.0	+11.3	+8.5	+6.7	+5.1
TA	+19.2	+26.7	+29.8	+22.5	+17.0	+20.9	+24.1	+19.6	+14.3	+11.8	+11.4	+8.5
LB	+16.1	+26.3	+32.2	+35.7	+38.1	+38.4	+41.3	+37.3	+22.7	+15.5	+13.0	+9.0
RC	+17.6	+25.8	+33.3	+29.7	+30.8	+33.4	+38.3	+31.8	+19.5	+7.7	+3.4	+0.6
ZU	+12.2	+15.5	+19.2	+15.9	+15.3	+24.6	+30.5	+24.7	+18.3	+15.4	+12.0	+9.9
PP	+21.1	+26.9	+28.9	+19.0	+16.8	+23.4	+29.9	+23.3	+12.9	+10.0	+5.2	+4.2
GFS-0.5												
LE	+17.4	+20.6	+24.6	+24.4	+24.1	+22.9	+27.7	+23.7	+17.0	+14.3	+7.3	+9.1
AR	+30.2	+36.2	+31.8	+30.5	+29.8	+27.8	+25.4	+24.3	+17.1	+14.9	+5.8	+4.5
TA	+20.9	+30.0	+39.3	+37.2	+29.1	+25.7	+24.8	+23.4	+17.9	+11.2	+5.1	+3.9
LB	+12.1	+17.5	+19.2	+19.0	+16.5	+15.7	+20.7	+21.2	+14.1	+12.2	+9.3	+8.2
RC	+20.1	+24.2	+28.6	+26.7	+29.2	+28.7	+30.4	+28.5	+20.1	+12.4	+8.3	+6.0
ZU	+16.9	+17.1	+18.8	+16.9	+9.7	+13.5	+8.6	+8.1	+4.6	+6.4	+5.9	+6.1
PP	+28.6	+30.0	+32.4	+20.2	+12.9	+10.6	+11.5	+10.8	+10.8	+9.5	+5.8	+5.8
GFS-0.25												
LE	+27.3	+39.3	+53.9	+57.3	+54.2	+46.3	+41.6	+29.1	+15.4	+8.9	+0.1	+1.9
AR	+28.9	+38.5	+39.7	+45.3	+47.0	+46.2	+43.3	+38.6	+27.3	+21.3	+8.7	+5.4
TA	+21.3	+32.7	+46.2	+48.9	+42.3	+39.4	+37.7	+33.3	+24.9	+15.7	+7.5	+5.5
LB	+8.3	+16.1	+23.1	+30.7	+31.4	+33.7	+40.1	+36.4	+25.0	+19.5	+11.6	+7.9
RC	+17.4	+23.0	+31.8	+37.7	+44.1	+46.5	+49.9	+42.9	+29.8	+18.8	+10.6	+5.7
ZU	+9.9	+13.2	+20.6	+28.5	+28.6	+39.2	+39.3	+36.2	+28.3	+24.4	+14.7	+9.8
PP	+26.9	+33.5	+44.8	+44.4	+40.6	+40.0	+40.6	+36.2	+30.7	+23.2	+10.7	+6.6
NEMS30												
LE	+20.4	+23.5	+12.3	-2.6	-21.6	-37.1	-32.8	-19.3	-10.5	+13.2	+26.4	+36.2
AR	+31.1	+27.6	+2.9	-15.9	-32.2	-43.9	-41.9	-21.4	-6.2	+17.5	+25.7	+31.2
TA	+17.4	+16.2	+6.9	-13.3	-36.4	-47.0	-49.0	-34.0	-17.3	+6.3	+18.6	+29.9
LB	+13.5	+15.0	-0.2	-18.0	-35.7	-46.7	-44.8	-30.3	-12.5	+9.4	+20.9	+30.3
RC	+1.0	+5.5	-10.3	-25.9	-39.6	-47.9	-39.7	-25.4	-9.8	+10.1	+23.5	+29.9
ZU	+18.6	+20.4	+6.5	-14.9	-36.2	-35.9	-38.4	-27.9	-15.8	+4.3	+18.0	+28.2
PP	+12.2	+16.4	+0.1	-22.8	-41.3	-55.3	-51.0	-35.1	-16.0	+8.5	+20.7	+30.5
media												
ECMWF	+5.2	+7.0	+9.6	+9.7	+7.0	+2.5	-2.9	-7.3	-12.0	-9.6	-4.6	-0.9
ICON	+17.6	+23.9	+27.3	+22.8	+21.7	+24.9	+29.5	+23.8	+14.2	+9.9	+7.8	+5.7
GFSS-0.5	+20.9	+25.1	+27.8	+25.0	+21.6	+20.7	+21.3	+20.0	+14.5	+11.5	+6.8	+6.2
GFS-0.25	+20.0	+28.0	+37.1	+41.8	+41.2	+41.6	+41.8	+36.1	+25.9	+18.8	+9.1	+6.1
NEMS30	+16.3	+17.8	+2.6	-16.2	-34.7	-44.9	-42.5	-27.6	-12.6	+9.9	+22.0	+30.9
stdev												
ECMWF	+5.6	+4.8	+4.2	+3.8	+5.5	+10.6	+11.1	+10.7	+9.2	+7.0	+4.9	+3.0
ICON	+3.8	+5.0	+5.6	+7.4	+9.5	+8.6	+8.6	+9.1	+7.2	+5.1	+4.3	+3.5
GFS-0.5	+6.5	+7.2	+7.5	+7.2	+8.5	+7.4	+8.3	+7.6	+5.3	+2.9	+1.5	+1.9
GFS-0.25	+8.4	+10.6	+12.4	+10.2	+8.8	+4.9	+4.0	+4.3	+5.1	+5.2	+4.6	+2.4
NEMS30	+9.1	+7.1	+7.2	+7.5	+6.5	+6.7	+6.3	+6.0	+4.0	+4.4	+3.3	+2.5

Tabla 1.2: rMBD por sitio para cada modelo, en términos relativos (%).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
LE	+3.2	+2.6	+2.3	+1.9	+1.4	-0.9	-1.5	-3.2	-4.9	-4.8	-4.2	-1.4
AR	+9.6	+6.0	+1.7	+1.9	+1.9	+1.1	-0.5	-1.2	-4.0	-3.9	-4.2	-3.5
TA	+5.7	+5.1	+4.9	+2.6	+0.4	-1.3	-2.5	-2.2	-3.5	-5.3	-5.0	-3.8
LB	-0.9	+1.2	+2.0	+2.3	+1.4	+0.5	+0.3	-0.1	-1.3	-1.1	-0.1	+1.7
RC	+0.2	+0.6	+1.6	+1.3	+1.2	+0.6	+0.2	-0.9	-1.9	-2.7	-1.4	+0.8
ZU	+0.7	+1.8	+2.7	+2.8	+2.3	+3.6	+2.7	+1.9	+0.8	+0.7	+1.8	+2.5
PP	+6.0	+3.3	+2.4	+0.6	-0.4	-0.9	-2.0	-3.6	-3.7	-4.2	-4.8	-2.5
ICON												
LE	+9.7	+7.7	+5.1	+3.1	+1.9	+1.9	+2.5	+1.5	+0.1	+0.2	+1.5	+2.3
AR	+14.9	+11.3	+6.8	+3.8	+3.5	+3.1	+4.0	+3.6	+2.4	+2.6	+3.7	+4.6
TA	+12.5	+10.9	+7.6	+4.3	+2.7	+3.2	+3.8	+3.4	+3.1	+3.7	+6.3	+7.8
LB	+9.5	+10.9	+8.3	+7.0	+6.4	+6.1	+6.7	+6.7	+4.9	+4.8	+6.5	+7.3
RC	+11.1	+10.8	+8.8	+6.0	+5.4	+5.6	+6.7	+6.2	+4.8	+2.7	+1.9	+0.6
ZU	+7.4	+6.5	+4.9	+3.1	+2.5	+3.8	+4.7	+4.2	+3.8	+4.6	+5.9	+7.7
PP	+13.1	+10.7	+7.3	+3.6	+2.8	+3.7	+4.9	+4.3	+2.9	+3.4	+2.8	+3.9
GFS-0.5												
LE	+12.2	+9.1	+6.5	+4.8	+4.0	+3.5	+4.3	+4.1	+3.5	+4.2	+3.9	+7.7
AR	+21.0	+15.1	+7.9	+5.7	+4.8	+4.2	+3.9	+4.2	+3.6	+4.5	+3.3	+4.0
TA	+14.0	+12.7	+10.3	+7.3	+4.8	+4.0	+3.9	+4.2	+3.9	+3.6	+2.8	+3.5
LB	+7.2	+7.3	+5.0	+3.8	+2.8	+2.5	+3.4	+3.9	+3.2	+3.9	+4.7	+6.9
RC	+11.7	+9.6	+7.3	+5.3	+5.1	+4.7	+5.2	+5.5	+4.8	+4.3	+4.5	+5.6
ZU	+10.6	+7.4	+5.0	+3.3	+1.6	+2.1	+1.4	+1.4	+1.0	+1.9	+3.0	+4.8
PP	+18.1	+12.0	+8.3	+3.9	+2.2	+1.7	+1.9	+2.0	+2.5	+3.2	+3.2	+5.5
GFS-0.25												
LE	+19.2	+17.4	+14.3	+11.3	+9.0	+7.1	+6.5	+5.0	+3.2	+2.6	+0.1	+1.7
AR	+20.1	+16.1	+9.8	+8.5	+7.6	+7.0	+6.7	+6.7	+5.8	+6.4	+4.9	+4.9
TA	+14.2	+13.8	+12.1	+9.6	+7.0	+6.1	+6.0	+5.9	+5.5	+5.0	+4.1	+4.9
LB	+4.9	+6.7	+6.0	+6.1	+5.3	+5.4	+6.6	+6.7	+5.6	+6.2	+6.0	+6.5
RC	+10.1	+9.1	+8.1	+7.4	+7.6	+7.7	+8.6	+8.3	+7.2	+6.6	+5.8	+5.3
ZU	+6.2	+5.7	+5.5	+5.6	+4.8	+6.2	+6.3	+6.4	+6.1	+7.4	+7.5	+7.7
PP	+17.0	+13.5	+11.4	+8.6	+6.8	+6.4	+6.7	+6.7	+7.1	+7.9	+5.9	+6.2
NEMS30												
LE	+14.3	+10.4	+3.3	-0.5	-3.6	-5.7	-5.1	-3.3	-2.2	+3.9	+14.1	+30.9
AR	+21.7	+11.5	+0.7	-3.0	-5.2	-6.7	-6.5	-3.7	-1.3	+5.3	+14.5	+28.3
TA	+11.6	+6.8	+1.8	-2.6	-6.1	-7.3	-7.8	-6.1	-3.8	+2.0	+10.2	+27.0
LB	+8.0	+6.3	≈0.0	-3.6	-6.1	-7.5	-7.4	-5.6	-2.8	+3.0	+10.7	+25.2
RC	+0.6	+2.2	-2.6	-5.1	-6.8	-7.9	-6.8	-4.9	-2.4	+3.5	+12.8	+27.7
ZU	+11.7	+8.9	+1.7	-3.0	-6.1	-5.7	-6.1	-4.9	-3.4	+1.3	+9.1	+22.1
PP	+7.7	+6.6	≈0.0	-4.4	-6.9	-8.8	-8.4	-6.5	-3.7	+2.9	+11.4	+28.7
media												
ECMWF	+3.5	+2.9	+2.5	+1.9	+1.2	+0.4	-0.5	-1.3	-2.6	-3.0	-2.6	-0.9
ICON	+11.2	+9.8	+7.0	+4.4	+3.6	+3.9	+4.7	+4.3	+3.1	+3.1	+4.1	+4.9
GFS-0.5	+13.5	+10.5	+7.2	+4.9	+3.6	+3.3	+3.4	+3.6	+3.2	+3.7	+3.6	+5.4
GFS-0.25	+13.1	+11.8	+9.6	+8.2	+6.9	+6.6	+6.8	+6.5	+5.8	+6.0	+4.9	+5.3
NEMS30	+10.8	+7.5	+0.7	-3.2	-5.8	-7.1	-6.9	-5.0	-2.8	+3.1	+11.8	+27.1
stdev												
ECMWF	+3.8	+2.0	+1.1	+0.7	+0.9	+1.7	+1.8	+1.9	+2.0	+2.2	+2.7	+2.6
ICON	+2.5	+1.9	+1.5	+1.5	+1.7	+1.5	+1.5	+1.8	+1.6	+1.5	+2.1	+2.8
GFS-0.5	+4.7	+2.9	+1.9	+1.4	+1.4	+1.2	+1.4	+1.4	+1.2	+0.9	+0.8	+1.5
GFS-0.25	+6.1	+4.6	+3.3	+2.0	+1.4	+0.8	+0.8	+1.0	+1.3	+1.8	+2.4	+1.9
NEMS30	+6.5	+3.1	+1.9	+1.5	+1.1	+1.1	+1.1	+1.2	+0.9	+1.3	+2.0	+2.8

Tabla 1.3: MAD por sitio para cada modelo, en términos absolutos (Wh/m²).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
LE	28.5	44.0	69.9	86.9	97.5	111.0	117.1	115.1	98.6	76.2	44.3	29.8
AR	29.1	46.2	64.9	85.6	103.3	113.7	117.3	110.7	93.4	70.6	40.6	27.6
TA	30.1	48.7	69.4	88.0	108.5	111.8	110.3	106.6	95.6	71.8	42.4	25.5
LB	33.5	44.1	69.2	86.3	96.7	103.0	103.3	97.4	81.8	62.8	40.9	24.5
RC	34.8	48.8	69.0	87.6	101.1	112.5	114.4	105.0	85.1	60.7	41.9	22.5
ZU	31.4	44.4	68.8	87.1	97.5	102.1	101.1	94.3	78.6	59.2	35.3	24.5
PP	32.5	48.8	69.0	83.8	98.0	111.2	110.1	101.9	89.9	64.0	42.2	24.8
ICON												
LE	27.8	38.9	61.3	78.2	89.2	96.2	100.5	98.3	83.7	64.4	37.0	26.3
AR	32.4	45.3	63.5	78.3	94.9	101.5	103.1	93.8	78.0	62.8	33.8	22.6
TA	34.1	49.6	67.1	83.2	93.1	98.8	102.1	90.5	79.7	59.9	35.9	22.5
LB	32.2	43.6	65.6	84.5	93.5	99.8	103.3	97.2	75.4	55.9	36.5	22.4
RC	32.5	47.0	70.1	85.0	99.5	108.7	107.4	97.2	79.9	54.7	35.5	22.5
ZU	30.5	41.9	65.9	81.7	93.0	100.7	101.3	92.2	76.9	55.5	34.5	24.1
PP	39.0	53.2	70.2	81.0	89.8	100.3	102.1	94.8	79.1	56.2	36.9	24.2
GFS-0.5												
LE	31.5	45.1	74.0	95.3	109.2	115.2	121.4	111.9	93.4	71.7	39.9	28.3
AR	41.5	58.6	76.7	98.2	110.1	122.6	126.9	112.8	96.1	76.1	42.4	29.2
TA	35.7	54.5	77.2	98.3	111.1	112.6	118.9	109.9	98.1	73.1	45.1	28.0
LB	33.8	46.3	71.0	95.1	103.7	106.8	116.1	109.3	88.6	67.1	43.5	29.0
RC	39.1	55.4	78.7	95.5	104.6	118.8	122.6	108.7	89.6	65.7	45.0	26.1
ZU	34.0	44.8	72.3	94.8	104.7	113.8	117.6	108.1	90.4	68.0	44.1	30.7
PP	43.3	58.5	78.5	95.6	102.6	113.9	121.1	109.9	93.9	69.5	46.0	29.0
GFS-0.25												
LE	37.0	54.2	82.4	102.5	113.8	120.9	135.5	122.8	103.0	81.1	47.4	32.5
AR	40.0	59.3	78.0	100.3	111.2	124.0	129.1	114.3	96.5	76.5	42.4	30.8
TA	36.3	54.5	77.9	100.3	109.4	113.0	117.9	108.7	97.3	72.9	45.0	26.5
LB	32.6	46.7	73.3	98.4	106.8	110.3	118.1	107.9	85.3	65.0	42.9	26.2
RC	37.7	54.5	78.8	99.2	108.2	121.6	127.2	110.1	88.4	64.8	44.3	25.6
ZU	33.2	44.5	71.4	93.9	102.3	109.3	110.2	100.7	83.4	64.6	41.1	27.5
PP	40.4	57.2	79.3	95.7	101.7	111.2	115.3	104.7	90.3	67.3	45.2	28.3
NEMS30												
LE	40.7	48.2	77.5	103.3	121.8	131.2	134.1	123.0	105.8	79.9	52.9	50.1
AR	49.4	58.3	78.6	101.8	121.1	131.2	129.0	118.7	96.9	72.7	49.8	43.9
TA	45.9	57.9	81.0	107.5	126.6	128.0	133.1	121.6	102.6	74.6	49.6	40.4
LB	43.8	52.8	80.0	104.1	123.4	134.6	136.3	119.7	95.4	72.6	51.0	41.8
RC	48.1	60.1	87.5	107.3	123.8	139.0	131.9	117.7	92.9	65.7	48.4	38.0
ZU	44.8	52.4	79.6	104.2	121.4	126.3	127.9	118.5	94.9	73.2	48.9	46.4
PP	46.8	61.5	87.2	108.6	125.8	141.3	138.4	122.9	96.2	68.7	48.4	39.4
media												
ECMWF	31.4	46.4	68.6	86.5	100.4	109.3	110.5	104.4	89.0	66.4	41.1	25.6
ICON	32.6	45.6	66.2	81.7	93.3	100.9	102.8	94.8	79.0	58.5	35.7	23.5
GFS-0.5	37.0	51.9	75.5	96.1	106.6	114.8	120.7	110.1	92.9	70.2	43.7	28.6
GFS-0.25	36.8	53.0	77.3	98.6	107.6	115.8	121.9	109.9	92.0	70.3	44.0	28.2
NEMS30	45.6	55.9	81.6	105.3	123.4	133.1	133.0	120.3	97.8	72.5	49.9	42.9
stdev												
ECMWF	2.3	2.3	1.7	1.4	4.3	4.7	6.4	7.3	7.4	6.4	2.8	2.4
ICON	3.5	4.8	3.3	2.8	3.4	3.8	2.2	2.9	2.7	3.9	1.2	1.5
GFS-0.5	4.4	6.3	3.1	1.5	3.4	5.0	3.6	1.7	3.5	3.7	2.0	1.4
GFS-0.25	3.0	5.4	3.8	2.9	4.4	6.2	8.9	7.1	7.1	6.6	2.1	2.6
NEMS30	2.9	4.8	4.0	2.5	2.2	5.5	3.7	2.2	4.6	4.5	1.6	4.2

Tabla 1.4: rMAD por sitio para cada modelo, en términos relativos (%).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
LE	20.0	19.5	18.5	17.1	16.2	17.1	18.3	19.8	20.5	22.4	23.6	25.5
AR	20.2	19.3	16.1	16.0	16.6	17.2	18.2	19.1	19.7	21.4	22.8	25.0
TA	20.1	20.6	18.2	17.3	18.0	17.4	17.5	19.0	21.1	22.7	23.4	23.1
LB	19.8	18.4	18.0	17.1	16.4	16.5	17.0	17.9	18.3	20.1	20.9	20.4
RC	20.3	19.4	17.6	17.3	17.5	18.6	19.7	20.4	20.5	21.2	22.8	20.9
ZU	19.8	19.2	18.2	17.3	16.4	16.2	16.2	16.7	16.9	18.0	17.9	19.3
PP	20.6	19.6	17.6	16.2	16.4	17.7	18.2	18.9	20.9	21.8	23.2	23.4
ICON												
LE	18.9	16.7	15.7	14.9	14.4	14.5	15.4	16.6	17.1	18.5	19.3	21.5
AR	21.2	18.4	15.6	14.4	15.0	15.1	15.7	16.0	16.3	18.9	19.0	20.2
TA	22.2	20.3	17.0	15.0	15.1	15.1	16.0	15.9	17.2	18.8	19.8	20.6
LB	18.9	18.1	16.9	16.6	15.7	15.7	16.7	17.5	16.4	17.4	18.2	18.2
RC	20.4	19.7	18.5	17.1	17.4	18.1	18.6	19.0	19.4	19.4	19.5	20.2
ZU	18.5	17.6	16.9	15.7	15.1	15.4	15.8	15.8	16.0	16.4	17.0	18.6
PP	24.3	21.2	17.7	15.5	14.8	15.9	16.7	17.5	18.1	18.9	19.9	22.6
GFS-0.5												
LE	22.1	20.0	19.6	18.7	18.1	17.7	19.0	19.2	19.5	21.1	21.3	24.2
AR	28.9	24.5	19.0	18.3	17.7	18.6	19.7	19.5	20.3	23.0	23.8	26.4
TA	23.8	23.1	20.3	19.3	18.5	17.5	18.9	19.6	21.6	23.2	24.8	25.4
LB	20.0	19.4	18.5	18.9	17.6	17.1	19.1	20.0	19.8	21.4	22.3	24.2
RC	22.8	22.0	20.1	18.8	18.1	19.6	21.1	21.1	21.6	23.0	24.5	24.2
ZU	21.4	19.4	19.1	18.8	17.6	18.1	18.8	19.1	19.4	20.6	22.3	24.1
PP	27.3	23.5	20.1	18.5	17.1	18.1	20.0	20.4	21.8	23.7	25.3	27.4
GFS-0.25												
LE	25.9	24.0	21.8	20.2	18.9	18.6	21.2	21.1	21.4	23.8	25.3	27.8
AR	27.8	24.8	19.3	18.7	17.9	18.8	20.0	19.7	20.3	23.2	23.8	27.9
TA	24.2	23.0	20.5	19.7	18.2	17.6	18.7	19.4	21.5	23.1	24.8	23.9
LB	19.3	19.5	19.1	19.5	18.2	17.6	19.4	19.8	19.0	20.8	22.0	21.8
RC	22.0	21.6	20.2	19.6	18.7	20.1	21.9	21.3	21.3	22.7	24.1	23.8
ZU	20.9	19.3	18.9	18.6	17.2	17.3	17.6	17.8	17.9	19.6	20.8	21.6
PP	25.5	23.0	20.3	18.5	17.0	17.7	19.0	19.4	21.0	22.9	24.8	26.6
NEMS30												
LE	28.6	21.3	20.5	20.3	20.2	20.2	21.0	21.1	22.0	23.5	28.2	42.8
AR	34.3	24.3	19.5	19.0	19.5	19.9	20.0	20.5	20.4	22.0	28.0	39.8
TA	30.6	24.5	21.3	21.1	21.0	19.9	21.2	21.7	22.6	23.6	27.3	36.5
LB	25.9	22.1	20.8	20.7	21.0	21.5	22.4	21.9	21.3	23.2	26.1	34.8
RC	28.0	23.9	22.4	21.2	21.4	23.0	22.7	22.8	22.3	23.0	26.4	35.3
ZU	28.2	22.7	21.0	20.6	20.4	20.0	20.5	21.0	20.3	22.2	24.8	36.4
PP	29.6	24.7	22.3	21.0	21.0	22.5	22.8	22.8	22.3	23.4	26.6	37.1
media												
ECMWF	20.1	19.4	17.8	16.9	16.8	17.2	17.9	18.8	19.7	21.1	22.1	22.5
ICON	20.6	18.9	16.9	15.7	15.4	15.7	16.4	16.9	17.2	18.3	18.9	20.3
GFS-0.5	23.7	21.7	19.5	18.8	17.8	18.1	19.5	19.8	20.6	22.3	23.5	25.1
GFS-0.25	23.7	22.2	20.0	19.3	18.0	18.3	19.7	19.8	20.3	22.3	23.7	24.8
NEMS30	29.3	23.4	21.1	20.6	20.6	21.0	21.5	21.7	21.6	23.0	26.8	37.5
stdev												
ECMWF	0.3	0.6	0.8	0.6	0.7	0.8	1.1	1.2	1.6	1.6	2.0	2.4
ICON	2.1	1.6	1.0	0.9	1.0	1.2	1.1	1.2	1.2	1.1	1.1	1.5
GFS-0.5	3.2	2.1	0.7	0.3	0.4	0.8	0.8	0.7	1.1	1.2	1.5	1.3
GFS-0.25	3.1	2.1	1.0	0.6	0.7	1.0	1.5	1.2	1.4	1.5	1.6	2.7
NEMS30	2.6	1.3	1.0	0.7	0.7	1.3	1.1	0.9	0.9	0.6	1.2	2.8

Tabla 1.5: RMSD por sitio para cada modelo, en términos absolutos (Wh/m²).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
LE	44.5	71.3	107.3	131.2	146.5	161.0	165.3	162.8	138.4	108.2	69.3	43.7
AR	45.2	72.6	100.5	134.8	161.6	174.1	172.5	159.1	134.9	102.5	64.4	41.3
TA	48.0	77.6	106.6	131.9	161.2	164.0	159.5	150.6	138.9	103.8	65.6	38.7
LB	50.5	67.7	102.7	126.9	141.6	149.3	150.2	141.2	118.5	96.3	66.3	37.4
RC	51.7	74.9	100.1	126.7	145.3	159.7	162.1	146.3	119.9	88.3	62.6	31.3
ZU	46.8	68.7	101.8	128.5	146.2	155.7	154.2	143.4	120.3	90.5	58.4	38.4
PP	51.5	75.7	103.1	125.1	144.2	162.4	156.4	144.3	127.2	93.9	62.2	35.6
ICON												
LE	46.1	68.2	100.6	127.7	142.8	151.0	154.6	146.6	125.3	98.6	63.0	42.8
AR	47.9	69.8	98.5	127.6	149.4	157.4	158.8	140.2	117.3	98.2	61.3	36.4
TA	52.3	76.8	103.9	133.0	145.2	152.1	155.7	136.3	123.0	94.7	61.8	35.1
LB	51.4	69.8	102.4	130.2	143.1	150.9	158.9	147.3	116.7	92.2	64.4	36.6
RC	50.1	71.6	106.0	124.9	144.9	156.5	157.9	140.1	114.6	82.5	56.0	33.8
ZU	48.7	69.4	100.1	126.5	140.4	151.4	154.2	140.9	120.0	89.3	61.8	38.2
PP	57.3	80.4	105.2	122.9	135.8	149.6	150.5	141.4	114.2	85.1	59.0	36.3
GFS-0.5												
LE	50.9	78.0	120.6	156.3	173.2	182.5	194.4	172.5	145.4	112.6	69.2	45.0
AR	61.9	92.4	124.8	163.3	176.5	195.3	202.3	172.3	148.6	123.9	72.3	44.7
TA	55.6	85.5	121.6	157.7	172.8	176.6	186.1	168.4	151.1	116.8	73.5	42.3
LB	55.4	75.3	111.5	148.7	155.8	161.2	178.0	164.7	138.0	112.6	76.1	46.6
RC	61.2	87.5	119.2	140.8	151.5	172.4	187.0	160.4	133.9	106.3	72.4	38.6
ZU	54.0	76.2	115.0	149.5	160.0	175.7	185.0	170.6	145.3	112.9	76.4	48.5
PP	66.5	91.0	119.2	143.4	151.4	169.4	176.8	159.5	139.2	107.4	73.2	43.2
GFS-0.25												
LE	57.1	89.8	134.7	171.3	187.4	198.0	215.8	192.5	161.3	129.4	77.7	50.5
AR	60.8	93.9	128.1	168.3	181.6	200.4	207.1	175.8	150.5	125.2	73.0	47.9
TA	57.6	86.5	124.9	162.5	174.9	179.6	188.9	172.7	152.5	116.2	71.7	41.5
LB	54.4	77.2	116.6	157.7	166.6	171.3	182.8	166.0	135.9	109.6	73.0	41.8
RC	60.6	88.3	120.9	147.9	162.4	182.0	195.4	164.3	133.5	103.9	71.0	38.4
ZU	53.8	76.3	115.3	151.0	160.9	171.9	175.6	161.6	136.9	104.7	70.3	43.8
PP	65.1	91.1	124.0	148.2	156.3	172.2	176.0	158.8	138.3	106.5	72.5	43.5
NEMS30												
LE	59.6	81.0	123.2	158.0	184.0	194.1	201.1	185.3	163.1	124.2	83.9	66.2
AR	70.5	91.7	120.5	153.1	181.5	197.1	190.7	181.5	149.2	115.7	79.6	58.2
TA	68.6	89.2	124.0	158.7	185.8	188.2	195.4	179.4	154.7	117.2	80.0	54.8
LB	64.8	81.5	118.4	150.6	177.3	195.7	194.9	174.8	141.9	112.7	80.0	55.9
RC	68.4	95.5	130.1	156.4	174.1	195.4	192.7	172.1	138.1	100.1	76.0	50.8
ZU	68.8	87.2	121.6	153.6	179.0	185.3	187.1	177.1	148.0	115.0	78.4	63.2
PP	68.9	94.9	130.1	158.8	182.9	205.4	201.6	175.3	144.7	103.8	75.0	54.4
media												
ECMWF	48.3	72.6	103.2	129.3	149.5	160.9	160.0	149.7	128.3	97.6	64.1	38.1
ICON	50.5	72.3	102.4	127.5	143.1	152.7	155.8	141.8	118.7	91.5	61.0	37.0
GFS-0.5	57.9	83.7	118.9	151.4	163.0	176.2	187.1	166.9	143.1	113.2	73.3	44.1
GFS-0.25	58.5	86.2	123.5	158.1	170.0	182.2	191.7	170.2	144.1	113.6	72.7	43.9
NEMS30	67.1	88.7	124.0	155.6	180.7	194.4	194.8	177.9	148.5	112.7	79.0	57.6
stdev												
ECMWF	3.0	3.7	2.8	3.5	8.3	7.6	7.4	8.3	9.0	7.4	3.5	4.0
ICON	3.7	4.5	2.8	3.3	4.2	3.0	3.0	3.9	4.2	6.2	2.8	2.9
GFS-0.5	5.4	7.1	4.4	8.1	10.9	10.7	8.9	5.4	6.2	5.9	2.4	3.2
GFS-0.25	4.0	6.8	6.7	9.6	11.6	12.3	15.4	11.5	10.6	10.2	2.4	4.1
NEMS30	3.7	5.9	4.6	3.2	4.1	6.5	5.3	4.5	8.4	8.2	2.9	5.4

Tabla 1.6: rRMSD por sitio para cada modelo, en términos relativos (%).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
LE	31.2	31.6	28.4	25.8	24.3	24.8	25.8	28.0	28.8	31.8	36.9	37.4
AR	31.5	30.3	24.9	25.2	26.0	26.4	26.7	27.5	28.4	31.0	36.2	37.4
TA	32.0	32.8	28.0	25.9	26.8	25.5	25.3	26.9	30.6	32.9	36.1	35.0
LB	29.9	28.3	26.7	25.2	24.1	23.9	24.7	25.9	26.4	30.8	34.0	31.2
RC	30.1	29.8	25.6	25.0	25.1	26.4	27.9	28.4	28.8	30.9	34.1	29.1
ZU	29.4	29.8	26.9	25.4	24.5	24.7	24.7	25.4	25.8	27.5	29.6	30.1
PP	32.5	30.4	26.3	24.2	24.1	25.8	25.8	26.8	29.5	32.0	34.2	33.5
ICON												
LE	31.4	29.3	25.9	24.4	23.0	22.8	23.7	24.7	25.6	28.4	32.9	35.0
AR	31.2	28.3	24.2	23.4	23.6	23.4	24.2	23.9	24.5	29.5	34.5	32.6
TA	34.1	31.5	26.4	25.4	23.6	23.3	24.4	23.9	26.6	29.8	34.1	32.2
LB	30.2	29.0	26.3	25.5	24.1	23.8	25.6	26.5	25.4	28.6	32.0	29.7
RC	31.4	30.0	28.0	25.1	25.3	26.1	27.4	27.4	27.9	29.3	30.7	30.3
ZU	29.5	29.1	25.6	24.3	22.8	23.2	24.0	24.2	25.0	26.4	30.4	29.5
PP	35.7	32.1	26.5	23.5	22.4	23.7	24.7	26.1	26.1	28.7	31.8	33.8
GFS-0.5												
LE	35.7	34.5	32.0	30.8	28.7	28.1	30.4	29.7	30.3	33.1	36.9	38.5
AR	43.1	38.6	30.9	30.5	28.4	29.6	31.3	29.8	31.3	37.5	40.6	40.5
TA	37.1	36.2	32.0	31.0	28.7	27.5	29.6	30.0	33.3	37.0	40.4	38.3
LB	32.8	31.5	29.0	29.5	26.5	25.8	29.3	30.2	30.8	36.0	38.9	38.8
RC	35.7	34.8	30.5	27.8	26.2	28.5	32.2	31.1	32.2	37.2	39.4	35.9
ZU	34.0	33.1	30.4	29.6	26.8	27.9	29.6	30.2	31.2	34.3	38.7	38.1
PP	42.0	36.6	30.4	27.7	25.3	27.0	29.2	29.6	32.3	36.6	40.2	40.7
GFS-0.25												
LE	40.0	39.7	35.7	33.7	31.1	30.5	33.7	33.1	33.6	38.0	41.4	43.1
AR	42.3	39.2	31.7	31.4	29.2	30.4	32.1	30.4	31.7	37.9	41.0	43.4
TA	38.4	36.6	32.8	31.9	29.1	28.0	30.0	30.8	33.6	36.8	39.5	37.5
LB	32.2	32.3	30.4	31.3	28.3	27.4	30.1	30.4	30.3	35.0	37.4	34.8
RC	35.3	35.1	30.9	29.2	28.1	30.1	33.6	31.9	32.1	36.4	38.7	35.7
ZU	33.9	33.1	30.5	29.9	27.0	27.3	28.1	28.6	29.4	31.8	35.7	34.4
PP	41.1	36.6	31.7	28.6	26.1	27.4	29.0	29.5	32.1	36.3	39.9	40.9
NEMS30												
LE	41.8	35.8	32.6	31.1	30.5	29.9	31.4	31.9	34.0	36.5	44.7	56.6
AR	49.1	38.3	29.9	28.6	29.2	29.9	29.5	31.3	31.5	35.0	44.7	52.7
TA	45.7	37.7	32.6	31.2	30.9	29.3	31.1	32.0	34.1	37.1	44.0	49.6
LB	38.4	34.1	30.8	29.9	30.1	31.3	32.1	32.0	31.7	36.0	40.9	46.6
RC	39.9	37.9	33.3	30.8	30.1	32.3	33.2	33.4	33.2	35.0	41.4	47.1
ZU	43.3	37.8	32.1	30.4	30.0	29.4	30.0	31.3	31.7	34.9	39.8	49.6
PP	43.5	38.1	33.2	30.7	30.5	32.7	33.3	32.5	33.6	35.4	41.3	51.2
media												
ECMWF	30.9	30.4	26.7	25.2	25.0	25.4	25.9	27.0	28.4	31.0	34.4	33.4
ICON	31.9	29.9	26.1	24.5	23.6	23.7	24.9	25.2	25.9	28.7	32.4	31.9
GFS-0.5	37.2	35.0	30.7	29.5	27.2	27.8	30.2	30.1	31.6	36.0	39.3	38.7
GFS-0.25	37.6	36.1	32.0	30.9	28.4	28.7	31.0	30.7	31.8	36.0	39.1	38.5
NEMS30	43.1	37.1	32.1	30.4	30.2	30.7	31.5	32.1	32.8	35.7	42.4	50.5
stdev												
ECMWF	1.2	1.4	1.2	0.6	1.1	0.9	1.1	1.1	1.7	1.7	2.4	3.4
ICON	2.2	1.4	1.2	0.9	0.9	1.1	1.3	1.4	1.1	1.1	1.6	2.1
GFS-0.5	3.9	2.4	1.0	1.4	1.4	1.2	1.1	0.5	1.0	1.7	1.3	1.6
GFS-0.25	3.9	2.8	1.9	1.8	1.6	1.5	2.2	1.5	1.6	2.1	2.0	3.9
NEMS30	3.6	1.6	1.3	0.9	0.5	1.4	1.4	0.7	1.2	0.9	2.0	3.4

Tabla 1.7: FS por sitio para cada modelo (en %)

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
LE	47.6	47.0	46.5	48.6	49.5	48.8	47.5	44.5	43.7	41.1	40.4	36.3
AR	47.2	47.4	52.4	50.0	47.2	44.2	43.6	41.7	41.8	41.6	39.9	34.3
TA	48.7	46.0	48.2	49.4	46.8	46.2	45.4	44.5	41.5	40.6	39.6	37.7
LB	46.8	48.8	48.1	50.3	49.4	48.4	48.1	47.9	48.6	45.7	45.9	47.5
RC	47.3	47.9	50.0	48.4	48.1	47.3	46.7	46.7	47.7	46.2	42.7	46.4
ZU	49.6	49.5	51.1	50.9	50.6	48.6	48.2	49.7	50.4	47.2	47.8	45.0
PP	47.6	47.8	49.7	49.6	46.0	43.8	44.9	43.4	41.7	40.4	40.0	41.2
ICON												
LE	44.0	46.9	49.3	49.3	51.8	51.7	49.7	48.9	48.6	44.9	45.2	37.6
AR	45.9	49.0	51.2	49.9	49.2	48.1	47.5	48.1	47.7	43.3	41.2	38.0
TA	41.9	44.2	47.0	48.2	51.5	51.1	48.1	49.4	46.7	44.7	41.4	40.5
LB	44.4	45.4	46.3	47.7	47.5	46.2	42.4	42.9	46.0	45.2	44.7	43.9
RC	45.4	45.7	44.5	48.2	48.0	46.2	46.2	46.4	47.0	46.4	45.5	38.7
ZU	46.0	49.2	50.5	49.9	50.3	49.0	46.4	47.6	47.9	45.4	42.1	39.7
PP	40.3	41.3	47.4	49.4	49.4	48.2	46.4	44.4	46.7	44.0	41.3	38.5
GFS-0.5												
LE	40.0	42.1	39.9	38.7	40.3	41.9	38.2	41.2	40.8	38.7	40.4	34.3
AR	27.8	33.0	41.0	39.4	42.4	37.4	33.9	36.9	35.8	29.4	32.6	29.0
TA	40.6	40.6	40.9	39.5	42.9	42.1	36.3	37.9	36.3	33.1	32.4	31.8
LB	41.6	43.1	43.6	41.7	44.3	44.3	38.5	39.3	40.1	36.5	38.0	34.7
RC	37.6	39.2	40.4	42.6	45.9	43.1	38.5	41.5	41.6	35.2	33.7	33.9
ZU	41.8	44.0	44.7	42.9	46.0	42.0	37.9	40.2	40.0	34.1	31.7	30.4
PP	32.3	37.2	41.8	42.2	43.4	41.4	37.7	37.4	36.2	31.7	29.5	28.6
GFS-0.25												
LE	32.8	33.3	32.8	32.8	35.4	37.0	31.4	34.4	34.3	29.6	33.2	26.4
AR	29.1	31.9	39.4	37.5	40.7	35.7	32.3	35.6	35.0	28.6	31.9	23.9
TA	38.5	39.8	39.3	37.7	42.2	41.1	35.3	36.3	35.8	33.5	34.0	33.2
LB	42.6	41.6	41.0	38.2	40.5	40.8	36.8	38.8	41.0	38.2	40.5	41.3
RC	38.2	38.7	39.6	39.7	42.0	40.0	35.8	40.1	41.7	36.6	34.9	34.3
ZU	42.0	43.9	44.6	42.3	45.7	43.3	41.0	43.3	43.5	38.9	37.1	37.2
PP	33.7	37.1	39.5	40.3	41.5	40.4	38.0	37.7	36.6	32.3	30.1	28.2
NEMS30												
LE	29.8	39.8	38.6	38.0	36.6	38.3	36.1	36.9	33.6	32.4	27.8	3.4
AR	17.6	33.5	43.0	43.2	40.8	36.8	37.7	33.5	35.6	34.1	25.8	7.5
TA	26.7	38.0	39.8	39.1	38.6	38.3	33.1	33.9	34.8	32.9	26.4	11.7
LB	31.7	38.4	40.1	41.0	36.7	32.3	32.7	35.5	38.4	36.5	34.8	21.5
RC	30.2	33.6	34.9	36.3	37.8	35.5	36.6	37.2	39.7	38.9	30.3	13.2
ZU	25.9	35.9	41.6	41.3	39.6	38.9	37.2	37.9	38.9	32.9	29.9	9.4
PP	29.9	34.5	36.6	36.0	31.6	28.9	29.0	31.2	33.7	34.0	27.7	10.0
media												
ECMWF	47.8	47.8	49.4	49.6	48.3	46.8	46.3	45.5	45.0	43.2	42.3	41.2
ICON	44.0	45.9	48.0	48.9	49.7	48.6	46.7	46.8	47.2	44.9	43.1	39.6
GFS-0.5	37.4	39.9	41.8	41.0	43.6	41.7	37.3	39.2	38.7	34.1	34.0	31.8
GFS-0.25	36.7	38.0	39.5	38.4	41.2	39.8	35.8	38.0	38.3	34.0	34.6	32.1
NEMS30	27.4	36.2	39.2	39.3	37.4	35.6	34.6	35.2	36.4	34.5	29.0	11.0
stdev												
ECMWF	1.0	1.1	2.0	0.9	1.7	2.1	1.7	2.8	3.7	3.0	3.3	5.2
ICON	2.1	2.8	2.4	0.9	1.6	2.2	2.3	2.4	0.9	1.0	2.0	2.2
GFS-0.5	5.4	3.8	1.8	1.8	2.0	2.2	1.7	1.8	2.5	3.1	3.8	2.6
GFS-0.25	5.0	4.3	3.5	3.0	3.0	2.6	3.3	3.0	3.7	4.1	3.4	6.2
NEMS30	4.8	2.5	2.8	2.7	3.0	3.7	3.2	2.4	2.6	2.4	3.1	5.6

Anexo 2

Desempeño estacional intra-diario por sitio

Tabla 2.1: MBD intra-diario de la evaluación estacional y anual, en términos absolutos (Wh/m^2).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
Anual	+5.2	+7.0	+9.6	+9.7	+7.0	+2.5	-2.9	-7.3	-12.0	-9.6	-4.6	-0.9
Primavera	+3.5	+2.9	+5.2	+6.8	+4.0	+2.3	-4.5	-10.1	-15.7	-12.7	-6.5	+0.1
Verano	+9.0	+14.5	+16.1	+15.8	+10.6	+9.7	+1.1	-3.2	-9.9	-8.2	-4.8	-1.9
Otoño	+2.4	+6.4	+8.7	+6.3	+6.0	-4.0	-6.8	-10.0	-17.1	-13.2	-5.0	0.0
Invierno	-	+4.3	+8.7	+10.0	+7.6	+2.0	-1.4	-5.9	-5.4	-4.3	-1.7	-
ICON												
Anual	+17.6	+23.9	+27.3	+22.8	+21.7	+24.9	+29.5	+23.8	+14.2	+9.9	+7.8	+5.7
Primavera	+22.1	+33.9	+34.8	+31.5	+29.9	+36.3	+39.6	+27.4	+15.7	+10.1	+7.4	+3.6
Verano	+19.8	+30.8	+33.8	+34.9	+40.7	+50.9	+54.8	+45.7	+29.8	+23.4	+18.5	+8.6
Otoño	+7.9	+20.2	+22.4	+14.5	+12.8	+13.2	+24.2	+25.0	+13.4	+7.6	+3.9	+1.1
Invierno	-	+11.4	+18.7	+11.4	+4.8	+0.9	+1.2	-1.7	-1.1	-0.5	-1.5	-
GFS-0.5												
Anual	+20.9	+25.1	+27.8	+25.0	+21.6	+20.7	+21.3	+20.0	+14.5	+11.5	+6.8	+6.2
Primavera	+23.4	+30.6	+26.6	+19.5	+17.6	+22.2	+24.5	+22.0	+17.7	+14.6	+8.7	+4.5
Verano	+27.6	+42.9	+45.4	+45.1	+42.9	+46.1	+40.0	+33.5	+22.9	+18.2	+17.4	+8.6
Otoño	+7.7	+19.5	+25.8	+22.9	+22.0	+17.5	+23.5	+26.0	+16.5	+11.4	+2.0	+2.0
Invierno	-	+7.6	+13.8	+12.7	+4.1	-2.7	-2.7	-1.6	+0.9	+2.0	-5.9	-
GFS-0.25												
Anual	+20.0	+28.0	+37.1	+41.8	+41.2	+41.6	+41.8	+36.1	+25.9	+18.8	+9.1	+6.1
Primavera	+22.7	+34.3	+38.1	+41.1	+40.5	+44.8	+45.3	+39.3	+30.6	+22.9	+9.0	+2.8
Verano	+25.7	+43.8	+53.2	+63.0	+64.4	+69.9	+64.5	+56.2	+42.6	+33.6	+23.4	+9.5
Otoño	+8.0	+22.9	+34.6	+38.0	+40.6	+38.0	+44.0	+41.3	+26.5	+17.1	+2.7	+1.8
Invierno	-	+11.5	+22.9	+25.6	+19.8	+14.2	+13.6	+7.6	+4.2	+1.8	-4.3	-
NEMS30												
Anual	+10.8	+7.5	+0.7	-3.2	-5.8	-7.1	-6.9	-5.0	-2.8	+3.1	+11.8	+27.1
Primavera	+17.8	+10.8	-11.1	-32.1	-47.9	-50.3	-48.5	-34.0	-17.9	+8.5	+26.8	+32.9
Verano	+15.9	+16.0	-13.7	-38.2	-64.8	-77.6	-80.2	-60.6	-39.3	-8.5	+17.6	+34.6
Otoño	+14.6	+23.3	+12.4	-8.0	-24.7	-38.5	-31.7	-15.2	-5.8	+15.4	+22.7	+23.4
Invierno	-	+20.9	+22.5	+13.2	-2.0	-13.4	-10.1	-1.2	+12.2	+23.9	+20.3	-

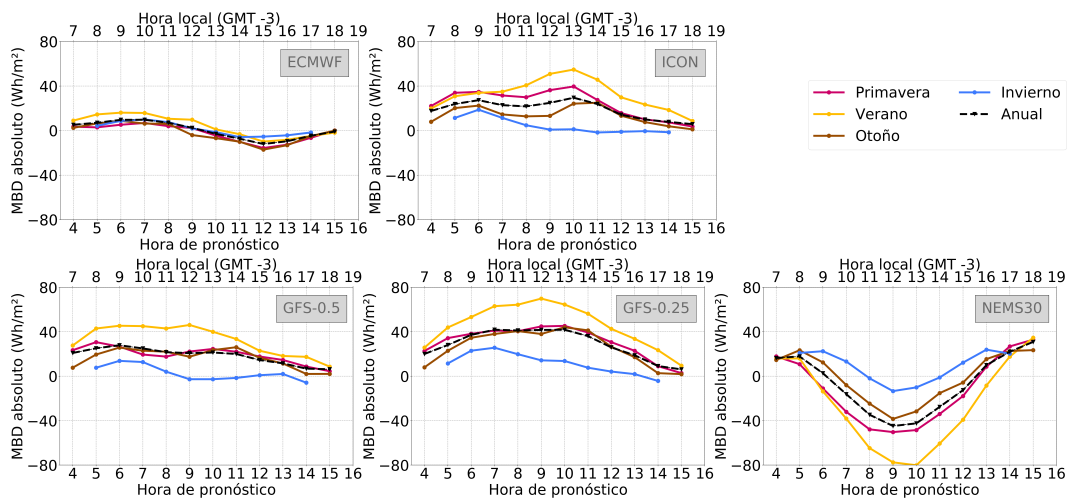


Figura 2.1: MBD intra-diario de la evaluación estacional y anual, en términos absolutos (Wh/m^2).

Tabla 2.2: RMSD intra-diario de la evaluación estacional y anual, en términos absolutos (Wh/m^2).

	Hora local											
	7	8	9	10	11	12	13	14	15	16	17	18
ECMWF												
Anual	48.3	72.6	103.2	129.3	149.5	160.9	160.0	149.7	128.3	97.6	64.1	38.1
Primavera	50.6	88.7	122.1	143.2	163.2	170.9	166.6	156.4	131.7	99.8	56.4	22.9
Verano	58.0	98.1	129.5	158.0	185.7	201.2	206.3	192.2	173.4	139.6	98.6	48.8
Otoño	21.7	53.4	86.3	119.1	133.6	145.8	145.2	136.2	110.3	79.9	42.9	19.8
Invierno	-	28.3	59.2	85.0	103.0	112.7	105.2	98.8	79.4	49.4	19.4	-
ICON												
Anual	50.5	72.3	102.4	127.5	143.1	152.7	155.8	141.8	118.7	91.5	61.0	37.0
Primavera	57.7	93.8	123.8	147.8	161.3	170.5	172.1	152.4	125.8	95.0	56.3	24.0
Verano	56.3	90.2	122.7	150.7	170.9	182.5	186.9	175.9	156.1	130.6	94.5	47.0
Otoño	23.3	56.2	87.4	113.9	128.4	137.9	144.2	129.7	103.5	75.0	38.2	18.6
Invierno	-	32.9	65.1	88.8	103.7	111.6	111.7	100.3	78.0	47.9	17.2	-
GFS-0.5												
Anual	57.9	83.7	118.9	151.4	163.0	176.2	187.1	166.9	143.1	113.2	73.3	44.1
Primavera	62.0	99.6	137.2	170.3	176.2	186.8	195.5	169.6	144.4	111.2	63.5	26.7
Verano	68.5	114.5	149.4	183.6	199.2	222.4	242.5	220.7	196.0	165.7	112.6	6.4
Otoño	25.5	62.8	102.9	137.0	149.2	158.2	169.3	151.0	125.3	92.9	49.1	22.5
Invierno	-	32.7	68.4	100.7	114.9	121.1	119.8	105.8	83.0	52.9	21.8	-
GFS-0.25												
Anual	58.5	86.2	123.5	158.1	170.0	182.2	191.7	170.2	144.1	113.6	72.7	43.9
Primavera	62.8	102.8	141.8	177.2	184.1	194.7	203.6	177.6	147.9	113.4	62.3	25.4
Verano	68.5	114.5	149.4	183.6	199.2	222.4	242.5	220.7	196.0	165.7	112.6	56.4
Otoño	25.5	64.4	108.1	145.3	156.2	165.5	175.2	155.8	126.4	93.8	48.6	21.0
Invierno	-	34.6	72.6	107.9	119.9	125.1	124.3	109.1	83.7	53.3	23.3	-
NEMS30												
Anual	67.1	88.7	124.0	155.6	180.7	194.4	194.8	177.9	148.5	112.7	79.0	57.6
Primavera	74.5	105.4	144.7	179.2	197.9	206.0	208.7	186.4	152.0	114.6	73.3	47.5
Verano	77.5	119.0	155.5	188.1	226.4	244.0	249.9	233.0	204.6	160.1	116.8	70.4
Otoño	32.7	68.2	105.7	139.1	162.4	181.0	175.7	159.3	126.3	92.2	55.4	36.2
Invierno	-	40.3	72.2	100.1	117.1	129.0	122.6	111.2	86.6	60.2	31.3	-




Figura 2.2: RMSD intra-diario de la evaluación estacional y anual, en términos absolutos (Wh/m^2).

Anexo 3

Indicadores de desempeño diario por sitio

Tabla 3.1: Desempeño diario por sitio.

	<i>N</i> (días)	media (MJ/m ²)	MBD (MJ/m ²)	MAD (MJ/m ²)	RMSD (MJ/m ²)	rMBD (%)	rMAD (%)	rRMSD (%)	FS (%)
ECMWF									
LE	1073	17.2	-0.2	2.2	3.1	-1.0	12.8	17.7	58.3
AR	1014	17.5	≈0.0	2.1	2.9	+0.2	11.9	16.9	58.8
TA	1087	16.9	-0.1	2.1	2.9	-0.5	12.4	17.4	58.6
LB	1087	16.6	+0.1	1.9	2.7	+0.6	11.5	16.2	61.0
RC	1081	16.2	≈0.0	2.0	2.8	+0.1	12.6	17.1	60.0
ZU	1085	16.9	+0.4	1.9	2.8	+2.2	11.2	16.8	60.8
PP	1078	16.6	-0.2	2.0	2.7	-1.1	11.9	16.6	58.0
ICON									
LE	1073	17.6	+0.4	2.0	3.1	+2.4	11.5	17.7	57.1
AR	988	17.7	+0.8	2.2	3.2	+4.6	12.3	18.3	54.2
TA	1085	17.2	+0.8	2.0	3.1	+4.6	11.9	17.8	56.4
LB	1084	16.9	+1.1	2.1	3.2	+6.8	12.4	18.7	52.3
RC	1011	15.8	+0.9	2.1	3.0	+6.0	13.1	19.0	55.2
ZU	1080	17.4	+0.7	2.0	3.0	+4.2	11.6	17.3	56.1
PP	1085	16.7	+0.8	2.0	2.9	+4.6	11.9	17.1	55.8
GFS-0.5									
LE	1071	17.2	+0.8	2.5	3.9	+4.5	14.4	22.6	46.8
AR	1013	17.5	+1.0	2.6	4.0	+5.5	14.9	22.9	44.1
TA	1086	16.9	+0.9	2.5	3.8	+5.6	14.6	22.6	46.1
LB	1086	16.6	+0.6	2.3	3.5	+3.9	13.8	20.9	49.8
RC	1080	16.2	+0.9	2.4	3.5	+5.6	14.9	21.6	49.4
ZU	1084	16.9	+0.4	2.3	3.7	+2.6	13.8	21.6	49.6
PP	1078	16.6	+0.7	2.4	3.5	+3.9	14.2	21.0	46.6
GFS-0.25									
LE	1074	17.2	+1.3	2.8	4.5	+7.5	16.3	26.0	39.0
AR	1016	17.5	+1.3	2.7	4.1	+7.7	15.6	23.6	42.3
TA	1089	16.9	+1.2	2.5	3.9	+7.3	14.8	23.0	45.1
LB	1089	16.6	+1.0	2.4	3.7	+5.8	14.6	22.3	46.4
RC	1083	16.2	+1.2	2.5	3.7	+7.7	15.7	22.9	46.5
ZU	1087	16.9	+1.0	2.3	3.6	+5.8	13.4	21.3	50.4
PP	1080	16.6	+1.3	2.4	3.6	+7.9	14.5	21.7	45.0
NEMS30									
LE	1074	17.2	≈0.0	2.4	3.7	-0.2	14.1	21.5	49.5
AR	1016	17.5	-0.2	2.3	3.4	-0.9	13.0	19.6	52.2
TA	1089	16.9	-0.4	2.4	3.4	-2.4	14.2	20.3	51.5
LB	1089	16.6	-0.4	2.4	3.5	-2.3	14.6	21.1	49.2
RC	1083	16.2	-0.5	2.4	3.5	-3.2	15.2	21.6	49.4
ZU	1087	16.9	-0.3	2.4	3.6	-1.7	14.2	21.2	50.6
PP	1080	16.6	-0.5	2.5	3.6	-3.2	14.8	21.5	45.5
media									
ECMWF	-	16.8	≈0.0	2.0	2.9	+0.1	12.1	17.0	59.4
ICON	-	17.1	+0.8	2.1	3.1	+4.7	12.1	18.0	55.3
GFSS-0.5	-	16.8	+0.8	2.4	3.7	+4.5	14.4	21.9	47.5
GFS-0.25	-	16.8	+1.2	2.5	3.9	+7.1	15.0	23.0	45.0
NEMS30	-	16.8	-0.3	2.4	3.5	-2.0	14.3	21.0	49.7
stdev									
ECMWF	-	0.4	+0.2	0.1	0.1	+1.2	0.6	0.5	1.2
ICON	-	0.6	+0.2	0.1	0.1	+1.4	0.6	0.7	1.6
GFS-0.5	-	0.4	+0.2	0.1	0.2	+1.2	0.5	0.8	2.2
GFS-0.25	-	0.4	+0.2	0.2	0.3	+0.9	1.0	1.6	3.6
NEMS30	-	0.4	+0.2	0.1	0.1	+1.1	0.7	0.8	2.2

Tabla 3.2: Desempeño por sitio según condición de cielo: modelo ECMWF.

Cod	Días	MBD (MJ/m ²)	MAD (MJ/m ²)	RMSD (MJ/m ²)	rMBD (%)	rMAD (%)	rRMSD (%)	Promedio (MJ/m ²)
Despajado								
LE	355	-1.6	1.7	2.3	-6.9	7.2	9.8	23.3
AR	333	-1.2	1.3	2.1	-5.2	5.7	9.0	23.1
TA	323	-1.4	1.5	2.0	-6.0	6.2	8.6	23.4
LB	371	-1.2	1.4	1.9	-5.3	5.9	8.2	23.2
RC	277	-1.4	1.5	2.0	-6.0	6.6	9.0	22.6
ZU	438	-1.0	1.1	1.6	-4.3	5.0	6.9	22.7
PP	301	-1.3	1.4	2.1	-5.8	6.3	9.1	22.9
media	-	-1.3	1.4	2.0	-5.7	6.1	8.7	23.0
stdev	-	0.2	0.2	0.2	0.8	0.7	0.9	0.3
Parcialmente nublado								
LE	583	+0.2	2.5	3.3	+1.6	16.1	21.4	15.4
AR	572	+0.3	2.5	3.1	+2.2	15.4	19.6	16.0
TA	624	≈0.0	2.3	3.0	≈0.0	14.4	18.5	16.1
LB	600	+0.5	2.1	2.9	+3.3	13.9	18.8	15.3
RC	678	+0.1	2.1	2.8	+0.9	13.5	17.8	15.8
ZU	536	+0.8	2.1	2.9	+5.0	13.9	18.8	15.4
PP	623	+0.0	2.3	3.0	+0.1	14.0	18.7	16.2
media	-	+0.3	2.3	3.0	+1.9	14.5	19.1	15.7
stdev	-	0.3	0.2	0.2	1.8	0.9	1.1	0.4
Nublado								
LE	135	+2.9	3.1	4.2	+66.5	70.9	96.8	4.3
AR	109	+2.8	3.2	4.3	+60.6	69.1	91.0	4.7
TA	140	+2.5	2.9	4.2	+57.2	66.5	95.0	4.4
LB	116	+2.2	2.6	3.6	+45.7	56.2	77.4	4.7
RC	126	+2.3	2.8	3.7	+49.5	61.0	79.8	4.6
ZU	111	+3.2	3.4	4.8	+70.6	75.1	106.8	4.5
PP	154	+1.7	2.3	3.1	+38.7	52.2	71.2	4.4
media	-	+2.5	2.9	4.0	+55.5	0.7	88.3	4.5
stdev	-	0.5	0.4	0.6	11.5	8.3	12.6	0.2

Tabla 3.3: Desempeño por sitio según condición de cielo: modelo ICON.

Cod	Días	MBD (MJ/m ²)	MAD (MJ/m ²)	RMSD (MJ/m ²)	rMBD (%)	rMAD (%)	rRMSD (%)	Promedio (MJ/m ²)
Despajado								
LE	568	-0.5	1.0	1.5	-2.3	4.1	6.6	23.1
AR	533	+0.0	1.0	1.8	+0.1	4.3	7.6	23.4
TA	535	-0.2	0.8	1.1	-0.7	3.5	4.8	23.3
LB	543	-0.2	0.8	1.3	-0.7	3.6	5.8	22.8
RC	407	-0.4	0.9	1.3	-1.8	4.2	5.9	22.0
ZU	563	-0.5	1.0	1.4	-2.1	4.3	6.3	22.6
PP	467	-0.2	0.9	1.4	-1.1	4.1	6.3	22.9
media	-	-0.3	0.9	1.4	-1.2	4.0	6.2	22.9
stdev	-	0.2	0.1	0.2	0.9	0.3	0.9	0.5
Parcialmente nublado								
LE	361	+0.9	3.0	4.0	+5.8	19.8	26.0	15.4
AR	327	+1.2	3.1	3.9	+7.4	20.0	25.2	15.6
TA	396	+1.2	2.9	3.7	+7.4	18.2	23.1	15.9
LB	435	+1.8	2.9	3.7	+11.8	18.4	23.9	15.5
RC	474	+1.4	2.6	3.4	+9.4	17.0	22.6	15.2
ZU	417	+1.5	2.9	3.8	+10.2	19.2	24.8	15.2
PP	458	+1.3	2.7	3.4	+8.0	16.6	21.4	16.0
media	-	+1.3	2.9	3.7	+8.6	18.5	23.9	15.5
stdev	-	0.3	0.2	0.2	2.0	1.3	1.6	0.3
Nublado								
LE	144	+2.5	3.2	4.4	+56.7	72.6	101.7	4.4
AR	128	+2.4	3.4	4.5	+51.4	71.8	96.6	4.7
TA	154	+2.2	3.0	4.4	+46.1	64.0	93.1	4.7
LB	106	+2.6	3.2	4.5	+56.7	70.1	99.3	4.6
RC	130	+2.3	2.9	4.0	+50.9	64.5	88.9	4.5
ZU	100	+2.8	3.3	4.5	+61.3	71.1	97.4	4.6
PP	160	+1.4	2.2	3.3	+31.5	49.8	74.0	4.5
media	-	+2.3	3.0	4.2	+50.7	66.3	93.0	4.6
stdev	-	0.4	0.4	0.4	9.8	8.0	9.3	0.1

Tabla 3.4: Desempeño por sitio según condición de cielo: modelo GFS-0.5.

Cod	Días	MBD (MJ/m ²)	MAD (MJ/m ²)	RMSD (MJ/m ²)	rMBD (%)	rMAD (%)	rRMSD (%)	Promedio (MJ/m ²)
Despajado								
LE	580	-0.8	1.1	1.7	-3.2	4.6	7.3	23.3
AR	535	-0.4	1.0	2.0	-1.9	4.4	8.7	23.1
TA	545	-0.5	0.9	1.5	-2.3	3.8	6.3	23.4
LB	537	-0.7	1.1	2.0	-3.1	4.6	8.8	23.2
RC	459	-0.7	1.1	1.7	-3.2	4.7	7.7	22.6
ZU	553	-0.8	1.1	2.3	-3.5	5.0	10.0	22.7
PP	445	-0.8	1.1	1.7	-3.4	4.6	7.6	22.9
media	-	-0.7	1.0	1.9	-3.0	4.5	8.0	23.0
stdev	-	0.1	0.1	0.3	0.6	0.4	1.2	0.3
Parcialmente nublado								
LE	345	+1.6	3.5	4.4	+10.1	22.8	29.0	15.4
AR	361	+1.5	3.6	4.5	+9.3	22.4	28.0	16.0
TA	399	+1.5	3.1	4.0	+9.1	19.6	25.1	16.1
LB	412	+1.3	3.0	3.9	+8.6	19.5	25.7	15.3
RC	485	+1.5	2.9	3.8	+9.4	18.6	24.3	15.8
ZU	384	+0.9	3.1	4.0	+5.6	20.2	26.0	15.4
PP	494	+1.2	3.0	4.0	+7.6	18.7	24.9	16.2
media	-	+1.3	3.2	4.1	+8.5	20.3	26.2	15.7
stdev	-	0.3	0.3	0.3	1.5	1.7	1.7	0.4
Nublado								
LE	146	+3.4	4.2	6.3	+77.9	98.1	145.3	4.3
AR	117	+3.7	4.6	6.3	+79.0	98.4	134.8	4.7
TA	142	+2.9	4.1	6.0	+64.6	92.7	136.6	4.4
LB	137	+2.0	3.2	4.6	+42.7	69.0	97.9	4.7
RC	136	+2.4	3.5	4.7	+52.9	75.0	102.8	4.6
ZU	147	+2.8	3.7	5.5	+62.1	83.0	121.2	4.5
PP	139	+2.0	3.2	4.5	+45.8	72.1	102.0	4.4
media	-	+2.7	3.8	5.4	+60.7	84.0	120.1	4.5
stdev	-	0.6	0.5	0.8	14.4	12.5	19.3	0.2

Tabla 3.5: Desempeño por sitio según condición de cielo: modelo GFS-0.25.

Cod	Días	MBD (MJ/m ²)	MAD (MJ/m ²)	RMSD (MJ/m ²)	rMBD (%)	rMAD (%)	rRMSD (%)	Promedio (MJ/m ²)
Despajado								
LE	618	-0.3	1.1	2.0	-1.4	4.6	8.5	23.3
AR	566	+0.0	1.0	2.0	+0.0	4.5	8.6	23.1
TA	590	-0.2	0.8	1.5	-0.9	3.4	6.4	23.4
LB	577	-0.3	0.9	1.7	-1.3	3.9	7.3	23.2
RC	511	-0.4	0.9	1.5	-1.7	4.0	6.7	22.6
ZU	611	-0.2	0.8	1.6	-1.0	3.7	7.0	22.7
PP	544	-0.1	0.8	1.3	-0.3	3.4	5.7	22.9
media	-	-0.2	0.9	1.6	-0.9	3.9	7.2	23.0
stdev	-	0.1	0.7	0.3	0.6	0.5	1.1	0.3
Parcialmente nublado								
LE	334	+1.8	3.9	4.9	+12.0	25.4	32.1	15.4
AR	335	+1.9	3.8	4.7	+11.7	23.5	29.1	16.0
TA	353	+1.9	3.4	4.2	+11.5	20.8	26.2	16.1
LB	371	+1.6	3.3	4.3	+10.6	21.6	28.2	15.3
RC	443	+1.8	3.2	4.1	+11.2	20.1	25.7	15.8
ZU	337	+1.6	3.2	4.1	+10.4	21.1	26.9	15.4
PP	405	+2.0	3.3	4.2	+12.3	20.2	26.1	16.2
media	-	+1.8	3.4	4.4	+11.4	21.8	27.8	15.7
stdev	-	0.1	0.3	0.3	0.7	2.0	2.3	0.4
Nublado								
LE	122	+4.5	5.2	7.4	+103.5	121.5	171.5	4.3
AR	115	+3.8	4.7	6.5	+81.6	101.2	139.2	4.7
TA	146	+2.8	4.1	6.0	+63.6	92.0	136.0	4.4
LB	141	+2.2	3.6	5.1	+46.1	76.5	107.4	4.7
RC	129	+2.8	3.8	5.2	+61.7	83.5	113.2	4.6
ZU	139	+2.8	3.7	5.6	+62.2	83.0	125.2	4.5
PP	131	+2.3	3.4	4.8	+51.8	77.5	108.8	4.4
media	-	+3.0	4.1	5.8	+67.2	90.7	128.7	4.5
stdev	-	0.8	0.1	0.9	19.5	16.1	22.7	0.2

Tabla 3.6: Desempeño por sitio según condición de cielo: modelo NEMS30.

Cod	Días	MBD (MJ/m²)	MAD (MJ/m²)	RMSD (MJ/m²)	rMBD (%)	rMAD (%)	rRMSD (%)	Promedio (MJ/m²)
Despajado								
LE	544	-1.2	1.4	2.5	-5.4	6.2	10.9	23.3
AR	474	-0.9	1.1	2.1	-3.8	4.7	9.1	23.1
TA	421	-1.4	1.5	2.3	-6.0	6.6	9.9	23.4
LB	454	-1.3	1.6	2.5	-5.7	6.9	11.0	23.2
RC	360	-1.3	1.5	2.4	-5.9	6.8	10.6	22.6
ZU	487	-1.2	1.4	2.5	-5.5	6.3	10.9	22.7
PP	367	-1.4	1.6	2.6	-6.3	7.0	11.3	22.9
media	-	-1.3	1.5	2.4	-5.5	6.3	10.5	23.0
stdev	-	0.2	0.2	0.2	0.8	0.8	0.8	0.3
Parcialmente nublado								
LE	360	+0.3	3.4	4.5	+2.2	22.3	29.4	15.4
AR	378	-0.1	3.2	4.1	-0.7	20.2	25.8	16.0
TA	471	-0.4	2.9	3.8	-2.2	18.1	23.7	16.1
LB	470	-0.2	3.1	4.1	-1.2	20.1	27.0	15.3
RC	520	-0.6	3.0	4.0	-4.1	19.0	25.2	15.8
ZU	433	-0.3	3.2	4.2	-1.8	21.1	27.3	15.4
PP	518	-0.5	3.1	4.1	-3.1	19.1	25.7	16.2
media	-	-0.2	3.1	4.1	-1.5	20.0	26.3	15.7
stdev	-	0.3	0.2	0.2	2.0	1.4	1.8	0.4
Nublado								
LE	170	+2.5	3.1	4.4	+58.5	71.1	102.7	4.3
AR	164	+2.0	2.9	4.1	+42.2	61.4	88.3	4.7
TA	197	+1.7	2.9	4.3	+39.0	65.9	98.1	4.4
LB	165	+1.4	2.6	3.5	+29.2	54.4	74.5	4.7
RC	203	+1.5	2.5	3.7	+33.4	55.3	80.0	4.6
ZU	167	+2.4	2.9	4.4	+52.4	65.1	98.0	4.5
PP	190	+1.4	2.4	3.5	+31.2	55.8	80.0	4.4
media	-	+1.8	2.8	4.0	+40.8	61.3	88.8	4.5
stdev	-	0.5	0.2	0.4	11.1	6.4	11.0	0.2

Anexo 4

Matriz confusión por sitio




Figura 4.1: Matriz confusión por sitio: ECMWF.




Figura 4.2: Matriz confusión por sitio: ICON.




Figura 4.3: Matriz confusión por sitio: GFS-0.5.




Figura 4.4: Matriz confusión por sitio: GFS-0.25.

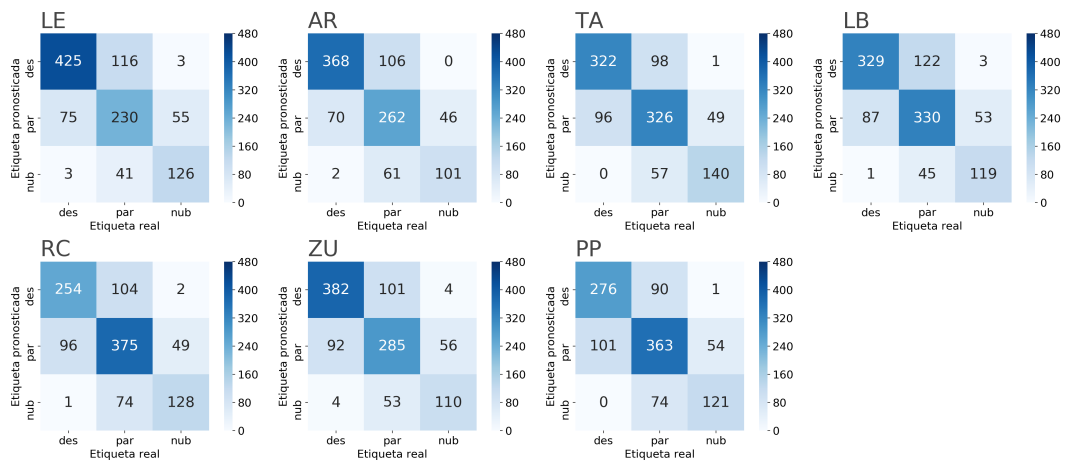


Figura 4.5: Matriz confusión por sitio: NEMS30.

A partir de la matriz confusión de cada sitio se obtiene los indicadores de precisión A_{CC} , BA y BAW para cada modelo evaluado, conforme se muestra en la tabla que sigue a continuación.

Tabla 4.1: Indicadores de precisión por sitio, según la matriz confusión (en %).

	ECMWF	GFS-0.5	GFS-0.25	ICON	NEMS30
LE					
A_{CC}	70	77	73	69	73
BA	69	74	69	64	71
BAW	75	77	72	68	72
AR					
A_{CC}	71	76	71	70	72
BA	68	73	68	67	71
BAW	74	75	71	70	72
TA					
A_{CC}	75	74	71	69	72
BA	72	72	69	68	73
BAW	77	74	71	70	72
LB					
A_{CC}	74	72	71	68	71
BA	70	69	70	68	71
BAW	76	73	72	69	71
RC					
A_{CC}	75	73	69	67	70
BA	71	72	69	67	71
BAW	77	74	71	69	70
ZU					
A_{CC}	76	75	70	71	71
BA	71	69	67	68	70
BAW	77	75	69	70	71
PP					
A_{CC}	76	74	71	70	70
BA	74	75	70	70	70
BAW	77	74	71	72	71
media					
A_{CC}	74	74	71	69	71
BA	71	72	69	67	71
BAW	76	74	71	70	71

Anexo 5

Matriz confusión normalizada por sitio




Figura 5.1: Matriz confusión normaliza por sitio: ECMWF.




Figura 5.2: Matriz confusión normaliza por sitio: ICON.




Figura 5.3: Matriz confusión normaliza por sitio: GFS-0.5.




Figura 5.4: Matriz confusión normaliza por sitio: GFS-0.25.

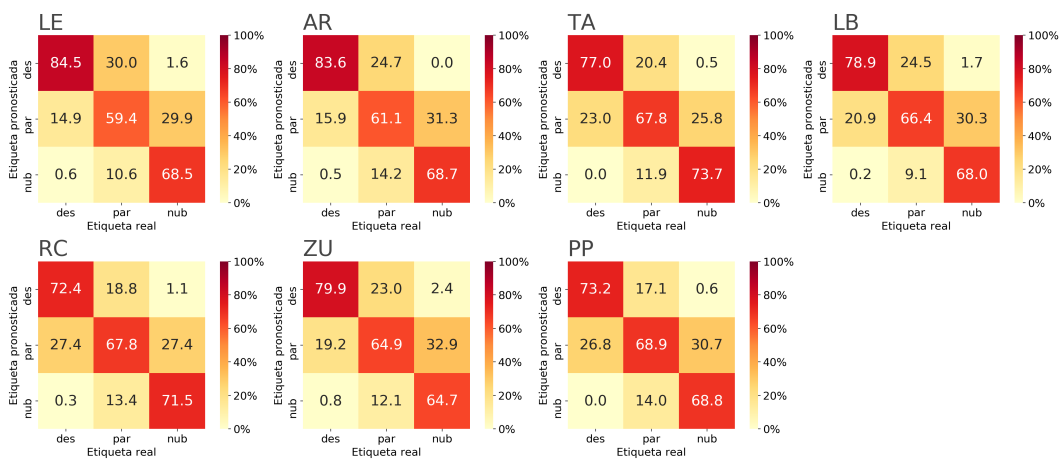


Figura 5.5: Matriz confusión normaliza por sitio: NEMS30.