

EXTRAPOLACIÓN ESPACIAL DE UN MODELO DE APRENDIZAJE AUTOMÁTICO BASADO EN IMÁGENES SATELITALES PARA LA ESTIMACIÓN DE LA IRRADIANCIA GLOBAL HORIZONTAL

Paula Iturbide¹, Ximena Orsi¹, Valeria Stern¹, Franco Ronchetti^{3,4}, Rodrigo Alonso-Suárez²

¹Grupo de Estudios de la Radiación Solar (GERSolar), Instituto de Ecología y Desarrollo Sustentable (INEDES),
Univ. Nacional de Luján, CP 6700, Buenos Aires, Argentina.

²Laboratorio de Energía Solar, Dpto. de Física del CENUR Litoral Norte, Udelar, Uruguay.

³Instituto de Investigación en Informática LIDI, Universidad Nacional de La Plata, Buenos Aires, Argentina.

⁴Comisión de Investigaciones Científicas de la Pcia. de Buenos Aires (CICPBA), Buenos Aires, Argentina. e-mail: paula.itur@gmail.com

Recibido 04/08/2025; Aceptado 05/10/2025

RESUMEN.- La disponibilidad de estimaciones precisas de irradiancia solar en zonas sin mediciones directas resulta decisiva para el diseño y planificación de sistemas de energía solar. En este trabajo se analiza la capacidad de extrapolación espacial de un modelo empírico basado en redes neuronales artificiales (RNA) e imágenes satelitales, entrenado exclusivamente con datos de la estación de Luján, Argentina. Se evalúa su desempeño al aplicarlo en las estaciones de Paraná, Concepción del Uruguay y General Villegas, comparando las estimaciones con mediciones en tierra y con modelos físicos de referencia (CAM5 y NREL). Los resultados muestran que el modelo mantiene un buen desempeño incluso en estaciones alejadas, con una ligera disminución en la precisión que se mantiene dentro de parámetros aceptables. En todos los casos, el modelo RNA supera en hasta un 16 % en términos de error cuadrático medio porcentual (RMSE_n) a las estimaciones de CAM5 y NREL. Al analizar los errores por condición de cielo, el modelo RNA obtiene los mejores resultados en cielo nublado y parcialmente nublado. En días despejados presenta un rendimiento inferior al de los modelos físicos, lo que es esperable porque no incorpora información de aerosoles o vapor de agua, ni en forma directa como entrada ni a través de un modelo de cielo claro. Estos hallazgos permiten tener mayor confianza en un enfoque basado únicamente en imágenes satelitales y su potencial para ser aplicado en regiones con escasa infraestructura de medición.

Palabras clave: Radiación solar, aprendizaje automático, Imágenes satelitales. GOES16, GHI.

SPATIAL EXTRAPOLATION OF A SATELLITE-BASED MACHINE LEARNING MODEL FOR GLOBAL HORIZONTAL IRRADIANCE ESTIMATION

ABSTRACT.- The availability of accurate solar irradiance estimates in areas without ground measurements is crucial for the design and planning of solar energy systems. This study analyzes the spatial extrapolation capability of an empirical model based on machine learning (ANN) and satellite imagery, trained exclusively with data from the Luján station in Argentina. Its performance is evaluated by applying it to the stations of Paraná, Concepción del Uruguay, and General Villegas, comparing the estimates with ground-based measurements and with two physical reference models (CAM5 and NREL). The results show that the model maintains very good performance even at distant stations, with only a slight decrease in accuracy that remains within excellent parameters. In all cases, the model outperforms CAM5 and NREL estimates by up to 16% in terms of normalized root mean square error (RMSE_n). When analyzing errors by sky condition, the ANN model performs best under cloudy and partly cloudy conditions. On clear-sky days, it performs worse than physical models, which is expected given that it does not incorporate solar geometry variables or a clear-sky model as inputs. These findings highlight the robustness of the approach based solely on satellite imagery and its potential for application in regions with limited measurement infrastructure.

Keywords: Solar radiation, Machine Learning, Satellite images, GOES16, GHI.



Esta obra está bajo Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional.
<https://creativecommons.org/licenses/by-nc-sa/4.0/>

1. INTRODUCCIÓN

La estimación precisa de la irradiancia solar a partir de imágenes satelitales ha cobrado creciente relevancia en los últimos años, dada su utilidad para planificar y dimensionar sistemas de energía solar en regiones con escasa infraestructura de medición terrestre. Los modelos físicos de transferencia radiativa, como Heliosat-4 (Qu et al., 2017), y los modelos semiempíricos ajustados localmente, como CIM-ESRA o CIM-McClear (Laguarda et al., 2018; Lefèvre et al., 2013), han sido ampliamente utilizados para estimar la irradiancia global horizontal (GHI) en ausencia de mediciones en la Pampa Húmeda Argentina. No obstante, estos enfoques requieren información atmosférica adicional (como aerosoles, vapor de agua o turbidez de Linke), que no siempre está disponible o no siempre tiene la misma calidad que en otras regiones más extensamente estudiadas. Por otro lado, uno de los mayores cuestionamientos a los enfoques basados únicamente en machine learning es su capacidad o no de extrapolar espacialmente sus estimaciones manteniendo similares niveles de desempeño, dado que los parámetros de ajuste podrían tener una mayor dependencia local que los de los modelos semi-empíricos. El presente trabajo busca hacer un primer diagnóstico de extrapolabilidad de herramientas de estimación satelital de irradiancia solar basadas en machine learning, dentro de la zona climáticamente afín de la Pampa Húmeda y con distintas estaciones en un radio de 450 km.

Los modelos de aprendizaje automático (machine learning, ML) son una alternativa prometedora para la estimación satelital de irradiancia solar por su capacidad de generalizar patrones a partir de grandes volúmenes de datos. En trabajos previos (Iturbide et al., 2023a), se desarrolló un modelo de redes neuronales basado exclusivamente en información satelital, entrenado con datos de la estación de medición terrestre de Luján (Buenos Aires, Argentina). A diferencia de otras aproximaciones, el modelo no requiere ninguna variable meteorológica y/o atmosférica como entrada: solo utiliza imágenes del canal visible del satélite geoestacionario GOES-16. Este enfoque demostró que es posible estimar la GHI a escala temporal 10-minutal con altos niveles de precisión con modelos de machine learning usando únicamente variables que representan la nubosidad diurna extraídas de las imágenes satelitales.

Las variables de entrada (el índice de nubosidad, el factor de reflectancia (FR) y la reflectancia planetaria (RP)) fueron calculadas a múltiples escalas espaciales, lo que permitió capturar estructuras nubosas en distintas resoluciones. La estrategia de reducción de dimensionalidad mediante análisis de componentes principales (PCA) confirmó que esta representación satelital condensada mantenía el poder predictivo del modelo sin pérdida de precisión. Entre los algoritmos evaluados, las redes neuronales artificiales (RN) mostraron el mejor desempeño, superando a métodos como random forest (RF), gradient boosting (GB) y la regresión lineal, con un RMSEn promedio del 15,6 % y coeficientes de determinación superiores a 0,94 (Iturbide et al., 2023b).

En este trabajo se busca analizar la capacidad de extrapolación espacial del modelo, es decir, su desempeño al ser aplicado en sitios distintos del lugar donde fue entrenado. Para ello, se reentrenó el modelo exclusivamente con datos de la estación de Luján y se aplicó a tres estaciones ubicadas en diferentes regiones del centro-este argentino: General Villegas, Concepción del Uruguay y Paraná. La evaluación se basa en la comparación con mediciones en tierra y con estimaciones generadas por modelos físicos de referencia, entre ellos el modelo CAMS (Heliosat-4) y un modelo adicional del National Renewable Energy Laboratory (NREL). Este análisis permite identificar los límites y oportunidades de

aplicar modelos de machine learning basados netamente en imágenes satelitales para estimar irradiancia solar en regiones sin mediciones disponibles, un desafío necesario para la expansión de las energías renovables en América Latina.

2. METODOLOGÍA

Con el objetivo de evaluar la capacidad de generalización espacial del modelo propuesto, se entrena una red neuronal artificial utilizando exclusivamente información satelital como entrada con datos de tierra de la estación de Luján. Luego, dicho modelo se aplica, sin recalcular parámetros de la red neuronal, en tres estaciones geográficamente distantes: Paraná, Concepción del Uruguay y General Villegas. El desempeño del modelo se evalúa contra los datos de medición en tierra y se compara con el de estimaciones provenientes de dos modelos físicos satelitales de referencia: CAMS Radiation Service y el modelo PSM de NREL, ambos ampliamente utilizados a escala global para estimar irradiancia solar.

2.1 Configuración del modelo y variables satelitales

El modelo consiste en una red neuronal de tipo feed-forward, con 100 neuronas ocultas y función de activación ReLU (Figura 1), entrenada para minimizar el error cuadrático medio. Esta configuración, junto con los hiperparámetros utilizados, fue definida en un estudio previo (Iturbide et al., 2023a) en base al desempeño observado en la estación de Luján.

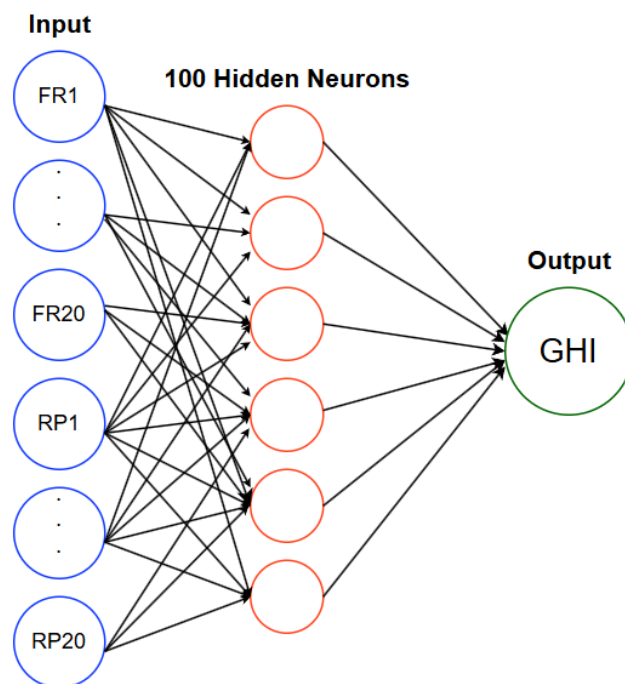


Fig. 1: Diagrama red neuronal feedforward con 100 neuronas ocultas y función de activación Relu-Adam.

Las variables de entrada son exclusivamente satelitales y no se incorporan ni variables meteorológicas locales ni atmosféricas. En particular, se utilizan:

- Factor de reflectancia (FR1 a FR20)
- Reflectancia planetaria (R1 a R20)

Estas variables fueron derivadas de imágenes del canal visible del satélite GOES-16 (banda C02, 0,64 μm), procesadas por el Laboratorio de Energía Solar (LES) de Uruguay. Cada numeración de

FR y R representa promedios espaciales a distintas resoluciones, permitiendo capturar la nubosidad en diferentes niveles de agregación. Estas resoluciones varían desde aproximadamente 1 km × 1 km para los recortes más locales (FR1 y R1), hasta 90 km × 90 km para los recortes regionales más amplios (FR20 y R20). Se debe notar que como $FR = R \cos(\theta z)$, siendo $\cos(\theta z)$ el coseno del ángulo cenital solar local, la red neuronal tiene forma de inferir información relativa a la posición del Sol en cada instante.

2.2 Datos de Tierra

Se emplearon series de irradiancia global horizontal (GHI) provenientes de las estaciones de Luján, Paraná, Concepción del Uruguay y General Villegas, pertenecientes a la red solarimétrica operada por el grupo GERSolar-INTA. Las mediciones, obtenidas con piranómetros de Clase A según ISO 9060:2018, fueron registradas a resolución minutal durante el período 2019–2021 y luego integradas a una escala 10-minutal, en consonancia con la cadencia de imágenes GOES-16.

Para garantizar la calidad de las mediciones, se aplicó un conjunto de filtros automáticos sugeridos en la bibliografía seguido de una revisión visual, en línea con lo propuesto por Long y Shi (2008) y otros trabajos regionales (Alonso Suárez, R et al., 2024):

- Altura solar mínima: se eliminaron observaciones con altura solar menor a 7°.
- Rangos físicos válidos (BSRN): se descartaron valores negativos o superiores al umbral máximo teórico.
- Comparación con modelo de cielo claro (Ineichen y Pérez, 2002): se eliminaron datos fuera del umbral superior esperado.
- Índice de claridad (Perez et al., 1990): se removieron datos con valores inconsistentes en términos de claridad atmosférica. ($k_t \leq 0.89$).

2.3 Datos de Modelos físicos basados en Imágenes Satelitales

Además de las estimaciones generadas por el modelo de red neuronal, se utilizaron dos fuentes externas para comparar el desempeño de la extrapolación:

- CAMS Radiation Service (Copernicus Atmosphere Monitoring Service): El modelo CAMS combina imágenes satelitales con modelos atmosféricos y algoritmos de transferencia radiativa, utilizando el método Heliosat-4 (Qu et al., 2017). Integra observaciones de satélites geoestacionarios (como Meteosat Second Generation, MSG) con datos de reanálisis meteorológico, como concentración de aerosoles, vapor de agua y propiedades físicas de nubes, para estimar la irradiancia global horizontal (GHI), directa (DNI) y difusa (DHI) a diferentes escalas temporales. Su resolución espacial es de aproximadamente 3 a 5 km sobre el área de estudio, y temporalmente se genera con una cadencia de 15 minutos, que es la frecuencia de imágenes MSG. Este modelo es ampliamente usado como benchmark internacional. Los datos de GHI se descargaron con resolución minutal (disponibles a esta escala) y fueron integrados a 10 minutos.
- NREL / NSRDB (Physical Solar Model – PSM): El modelo físico PSM, desarrollado por NREL y utilizado en la National Solar Radiation Database (NSRDB), combina imágenes

satelitales (principalmente del sistema GOES en América) con datos atmosféricos modelados provenientes del North American Mesoscale Model (NAM) y el Climate Forecast System Reanalysis (CFSR). Emplea algoritmos de cielo claro y parámetros atmosféricos como nubosidad, presión, temperatura, contenido de vapor de agua y concentración de aerosoles para estimar GHI, DNI y DHI. Su resolución espacial varía entre 2 y 4 km sobre el área de estudio, con una resolución temporal de 5 a 30 minutos según la región y el período histórico considerado. Se descargaron estimaciones de irradiancia solar a escala 10-minutal desde el portal de la National Solar Radiation Database.

Estas fuentes se utilizaron como referencia para evaluar la calidad de las predicciones generadas por el modelo extrapolado, aplicando las mismas métricas de validación en todas las estaciones.

2.4 Métricas de desempeño

Para evaluar la precisión de las estimaciones de irradiancia solar generadas por los modelos, se utilizaron métricas estadísticas estándar que permiten cuantificar tanto los errores absolutos como normalizados, así como la correlación con los valores medidos en tierra. Las métricas seleccionadas son las siguientes:

- MBE (Mean Bias Error): mide el sesgo medio entre los valores estimados y observados. Indica si el modelo tiende a sobrestimar o subestimar. ec.(1)
- RMSE (Root Mean Square Error): es la raíz cuadrada del error cuadrático medio. Penaliza fuertemente los errores grandes y se interpreta como una medida de dispersión. ec.(2)
- MAE (Mean Absolute Error): expresa el promedio del valor absoluto del error. A diferencia del RMSE, todos los errores tienen la misma ponderación. ec.(3).
- R^2 (Coeficiente de determinación): indica el grado de correlación lineal entre las estimaciones del modelo y los valores observados. ec.(4)

Además, se incluyen las versiones normalizadas de las primeras tres métricas, indicadas con subíndice n (por ejemplo, MBEn, RMSEn, MAEn), las cuales expresan los errores como porcentaje del valor medio observado. Estas versiones permiten comparar en forma más adecuada el desempeño entre diferentes sitios o escalas sin que influyan las magnitudes absolutas de irradiancia.

Las expresiones matemáticas de cada métrica se detallan a continuación.

$$MBE = \frac{1}{N} \sum_i^N (Y_i^m - Y_i^o) \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_i^N (Y_i^m - Y_i^o)^2} \quad (2)$$

$$MAE = \frac{1}{N} \sum_i^N |Y_i^m - Y_i^o| \quad (3)$$

$$R^2 = 1 - \frac{\sum_i^N (Y_i^m - \bar{Y}_o)^2}{\sum_i^N (Y_i^m - Y_i^o)^2} \quad (4)$$

Donde Y_i^m son los valores estimados por el modelo, y Y_i^o representa el valor de referencia de tierra. \bar{Y}_o representa el valor medio de la referencia de tierra.

2.5 Resultados previos

Como punto de partida para el presente estudio, se retoman los resultados obtenidos en Iturbide et al. (2023a), donde se evaluó el desempeño del modelo de redes neuronales en la estación de Luján, lugar para el cual fue originalmente desarrollado y entrenado, sitio en el cual se implementó una validación temporal cruzada, utilizando un año como conjunto de prueba y los dos años restantes como conjunto de entrenamiento. Los años usados fueron 2019, 2020 y 2021.

El modelo utilizó las mismas variables de entrada indicadas en la Figura 1, y se comparó con otros algoritmos de aprendizaje automático. Las redes neuronales artificiales (RNA) mostraron el mejor desempeño, con errores relativos más bajos y una alta correlación con las mediciones en tierra. Estos resultados constituyen la referencia contra la cual se evaluará la extrapolación espacial en las estaciones de Paraná, Concepción del Uruguay y General Villegas.

Los valores correspondientes a cada año y el promedio de desempeño se presentan en la Tabla 1, e incluyen únicamente el desempeño del modelo de RNA en la estación de Luján.

Tabla 1: Desempeño del modelo de Redes Neuronales en Luján (Iturbide et al., 2023a)

Métrica	2019	2020	2021	Media
MBE	-5.33	-0.26	0.40	-1.73
MBEn	-1.28	-0.06	0.09	-0.41
RMSE	70.13	67.73	69.64	69.16
RMSEn	16.77	14.51	15.61	15.80
MAE	44.27	40.61	42.66	42.51
MAEn	10.57	8.80	9.87	9.75
R^2	0.94	0.95	0.94	0.95

2.6 Región de extrapolación

Con el objetivo de evaluar la capacidad del modelo para ser aplicado fuera del sitio de entrenamiento, se seleccionaron tres estaciones ubicadas en distintas provincias de Argentina, representa-

tivas de diferentes condiciones de nubosidad dentro de la región de la Pampa Húmeda. Estas estaciones son: Villegas, Concepción del Uruguay y Paraná.

La distancia entre Luján (sitio de entrenamiento) y cada una de estas estaciones es la siguiente (Figura 2):

- General Villegas: aproximadamente 400 km al oeste de Luján, en la provincia de Buenos Aires.
- Concepción del Uruguay: aproximadamente 260 km al noreste de Luján, en la provincia de Entre Ríos.
- Paraná: aproximadamente 440 km al norte de Luján, también en la provincia de Entre Ríos.

Estas ubicaciones fueron seleccionadas no solo por su distancia respecto al sitio de entrenamiento, sino también por su pertenencia a una misma región climática, lo que permite evaluar si el modelo entrenado en Luján mantiene un desempeño aceptable al aplicarse en otras estaciones de la región. La extrapolación se realiza sin ajustar los modelos a las nuevas estaciones, con el fin de analizar su capacidad de generalización fuera del dominio de entrenamiento. Para ello, el modelo se reentrena utilizando los tres años completos (2019–2021) de datos de Luján y posteriormente se aplica (sin ajuste ni calibración local) sobre cada una de las estaciones objetivo (Paraná, Concepción del Uruguay y General Villegas), empleando las variables derivadas de imágenes satelitales correspondientes a cada sitio.

3. RESULTADOS

En esta sección se presenta el desempeño del modelo extrapolado a las estaciones de Paraná, Concepción del Uruguay y General Villegas. La comparación se realiza respecto a las mediciones en tierra en cada sitio y frente a las estimaciones proporcionadas por dos modelos físicos de referencia: CAMS Radiation Service y el modelo PSM (Physical Solar Model) del NREL.

Se muestra en la Tabla 2 para cada estación los resultados en cada año correspondientes al período 2019–2021, calculados a escala 10-minutal. Se reportan las métricas estadísticas descritas en la Sección anterior, incluyendo errores absolutos (MBE, MAE,

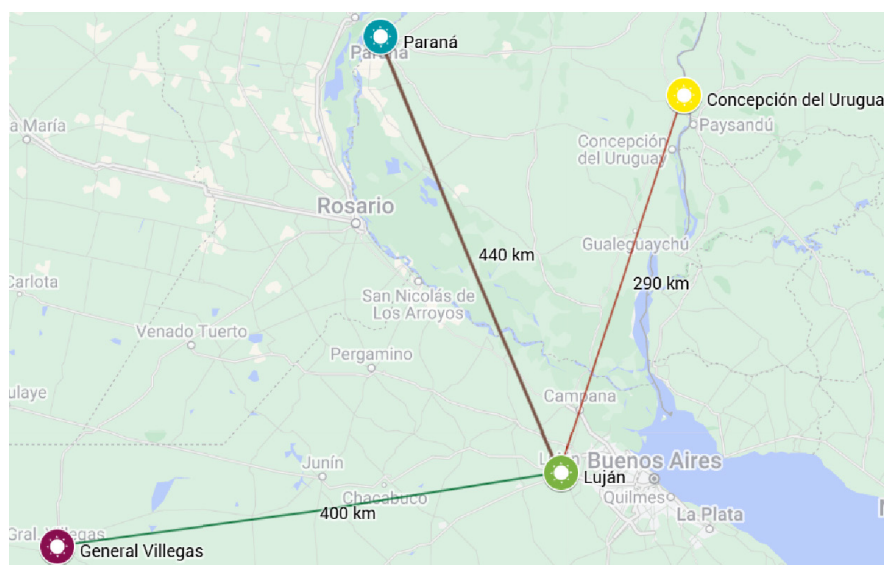


Fig. 2: Distribución de las estaciones y distancia respecto a Luján (zona de entrenamiento)

RMSE), errores normalizados (MBEn, MAEn, RMSEn) y coeficiente de determinación (R^2). Esta información permite evaluar la estabilidad del modelo en distintos años y en diferentes ubicaciones geográficas, sin ajuste posterior, y su desempeño promedio en el periodo.

Se puede observar que, en general, el modelo extrapolado logra mantener un buen nivel de desempeño en las tres estaciones de prueba, con valores de RMSEn entre 14 % y 19%, y R^2 superiores a 0.88 en todos los casos. Esto indica que, a pesar de no haber sido entrenado con datos locales, el modelo logra capturar adecuadamente la variabilidad de la irradiancia en ubicaciones distintas a Luján.

Se observa una leve pérdida de precisión respecto al sitio de entrenamiento, particularmente en los valores del sesgo medio (MBE). En la estación de Concepción del Uruguay y General Villegas, el MBE tiende a hacerse más negativo en magnitud, alcanzando valores de hasta -8.52 W/m^2 en ambos sitios en 2021. Esto indica que el modelo tiende a subestimar ligeramente la irradiancia en

ese sitio, lo cual puede atribuirse a diferencias locales en la nubosidad que no están representadas en los datos satelitales de Luján.

3.1 Comparación de modelos

Con el objetivo de contextualizar el desempeño del modelo de redes neuronales extrapolado, se lo compara con las estimaciones provistas por dos modelos físicos ampliamente utilizados: CAMS Radiation Service y el Physical Solar Model (PSM) del NREL. A continuación, en la Tabla 3, se presentan los resultados por estación para cada modelo.

Los modelos físicos CAMS y NREL muestran desempeños similares, aunque NREL tiende a presentar un rendimiento ligeramente superior en la mayoría de las estaciones y años analizados. Por ejemplo, en Paraná, el coeficiente de determinación (R^2) alcanzó valores de 0.90 para NREL en 2020, mientras que CAMS llegó hasta 0.89 en el mejor caso. Del mismo modo, los errores porcentuales RMSEn fueron más bajos en NREL, con valores de hasta 20.60 %, frente a 23.51 % observados en CAMS.

Tabla 2: Resultados de la extrapolación del modelo RNA para las 3 estaciones evaluadas. Los valores absolutos se expresan en W/m^2

Modelo	Estación	Año	MBE	MAE	RMSE	MBEn	MAEn	RMSEn	R^2
RNA	Concepción (Test)	2019	-1.62	50.49	74.64	-0.37	11.60	17.15	0.94
		2020	-5.74	63.78	87.04	-1.31	14.65	18.33	0.88
		2021	-8.36	57.46	81.12	-1.92	13.20	17.01	0.93
	Paraná (Test)	2019	-4.21	47.80	71.88	-0.97	10.98	16.51	0.94
		2020	-3.90	45.60	69.54	-0.89	10.47	14.73	0.94
		2021	-0.3	48.31	75.72	-0.07	11.10	16.50	0.93
	Villegas (Test)	2019	-5.10	57.31	78.96	-1.17	13.17	17.85	0.93
		2020	-3.35	49.53	69.48	-0.76	11.38	14.20	0.95
		2021	-8.52	55.87	78.06	-1.95	12.83	16.26	0.94

Tabla 3: Desempeño de los modelos CAMS y NREL. Los valores absolutos se expresan en W/m^2

Modelo	Estación	Año	MBE	MAE	RMSE	MBEn	MAEn	RMSEn	R^2
CAMS	Concepción	2019	-7.90	81.63	134.51	-1.82	18.75	30.63	0.81
		2020	-20.39	91.66	152.46	-4.07	18.29	28.86	0.77
		2021	-22.68	82.51	134.92	-4.75	17.29	27.69	0.82
	Paraná	2019	-19.37	69.86	113.98	-4.45	16.06	26.19	0.85
		2020	-14.43	62.40	103.19	-3.06	13.23	21.87	0.89
		2021	-12.57	64.15	108.50	-2.73	13.90	23.51	0.86
	Villegas	2019	-3.95	84.98	118.56	-0.89	19.20	26.79	0.86
		2020	-10.97	78.83	109.73	-2.24	16.12	22.44	0.89
		2021	-20.40	76.64	110.70	-4.25	15.96	23.05	0.89
NREL	Concepción	2019	7.57	79.35	133.35	1.74	18.22	30.63	0.81
		2020	-5.44	87.31	144.64	-1.09	17.42	28.86	0.79
		2021	-4.35	82.21	132.08	-0.91	17.23	27.69	0.82
	Paraná	2019	6.86	64.67	108.69	1.58	14.86	24.98	0.87
		2020	6.98	53.99	97.21	1.48	11.44	20.60	0.90
		2021	10.53	59.89	107.95	2.28	12.98	23.40	0.87
	Villegas	2019	11.68	87.16	131.39	2.64	19.70	29.69	0.82
		2020	12.44	70.98	108.09	2.54	14.52	22.10	0.89
		2021	-1.18	78.70	125.29	-0.25	16.39	26.09	0.85

En Concepción del Uruguay, CAMS presentó un sesgo negativo más pronunciado, con valores de MBE de -22.68 W/m^2 en 2021, mientras que NREL mostró un sesgo más acotado, de -4.35 W/m^2 para el mismo año. Además, los errores absolutos también fueron menores en NREL (por ejemplo, RMSE de 132.08 W/m^2 frente a 134.92 W/m^2 de CAMS).

En Villegas, las diferencias se mantuvieron: NREL logró errores normalizados inferiores a 26 %, mientras que CAMS se ubicó por encima de ese umbral en todos los años. Aunque ambas aproximaciones presentan limitaciones a esta escala temporal, en términos generales NREL mostró una mejor capacidad de ajuste y menor sesgo sistemático.

3.2 Análisis de los errores según la condición de cielo

Para realizar un análisis más detallado del desempeño de los 3 modelos en las 3 estaciones, analizamos las métricas según las

condiciones de cielo en tres categorías: despejado, parcialmente nublado y nublado con el criterio que se muestra en la tabla 4.

El comportamiento de los modelos es consistente entre estaciones. En adelante nos centraremos en la estación Paraná; las conclusiones se extienden a las restantes. La Figura 3 presenta los resultados para Paraná, con series de 10 minutos para cada categoría de k_t .

Los tres modelos sobreestiman para cielo nublado y subestiman en cielo despejado, mientras que para la condición de cielo parcialmente nublado CAMS subestima y RNA y NREL sobreestiman.

El modelo de la RNA es el que presenta menores errores salvo en el caso de MBE y MAE en la condición de cielo despejado. Cabe destacar que la RNA no utiliza un modelo de cielo claro como entrada, a diferencia de CAMS y NREL, que calculan in-

Tabla 4: Condición de cielo, criterio de k_t y cantidad de datos por sitio

Condición de cielo	Criterio de k_t	Cantidad de datos		
		General Villegas	Paraná	Concepción del Uruguay
Despejado	$k_t > 0.8$	12258 (22,70%)	18040 (28,14%)	18617 (31,71%)
Parcialmente nublado	$0.3 < k_t < 0.8$	32106 (59,45%)	37319 (55,41%)	28810 (49,07%)
Nublado	$k_t \leq 0.3$	9638 (17,85%)	11078 (16,45%)	11287 (19,22%)

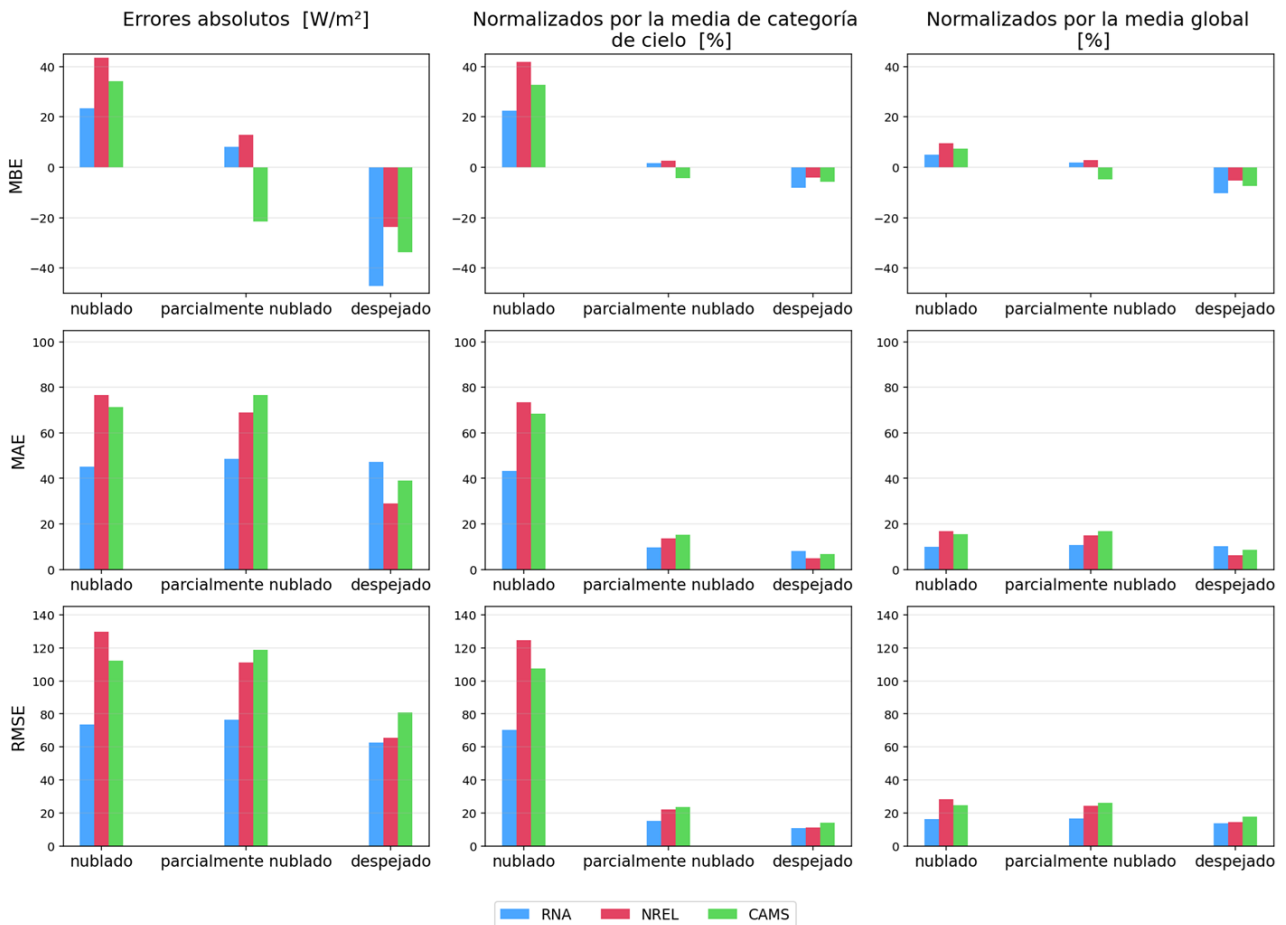


Fig. 3: Comparación de MBE, MAE y RMSE de tres modelos (RNA, NREL, CAMS) según la condición de cielo definida por k_t 10-min (nublado, parcialmente nublado, despejado). De izquierda a derecha se muestran los errores en absoluto (W/m^2) y sus versiones normalizadas por la media de cada categoría de cielo y por la media global (%).

ternamente su cielo claro a partir de información atmosférica (vapor de agua, ozono y aerosoles). Finalmente, los porcentajes de error normalizados por la irradiancia media de cada categoría resultan altos en cielo nublado debido a que su irradiancia promedio es sustancialmente menor en comparación con las condiciones despejadas o parcialmente nubladas.

Por último, mostramos los distintos modelos comparados con la serie de tierra para días con distintas condiciones de nubosidad en la estación Paraná.

En el día completamente despejado, RNA subestima ligeramente el pico de mediodía, mientras que NREL y CAMS reproducen casi a la perfección la curva correspondiente al cielo claro. Sin embargo, en días nublados o parcialmente nublados, la RNA es la única que sigue las variaciones rápidas de irradiancia (picos y valles), frente a NREL, que tiende a sobreestimar en los picos de nubosidad y CAMS, que los subestima o suaviza en mayor medida. Este comportamiento se explica porque RNA aprende directamente de los índices de nubosidad multiescala derivados de imágenes satelitales sin emplear información un modelo de cielo claro, mientras que NREL y CAMS utilizan información satelital sólo local y parámetros atmosféricos para generar internamente su cielo claro.”

Cabe mencionar que el período de estudio incluye el año 2020, durante el cual la reducción global en la actividad humana asociada a la pandemia pudo haber afectado, en cierta medida, los patrones de nubosidad y aerosoles. Sin embargo, en el análisis de este trabajo no se observaron variaciones significativas en las métricas de desempeño del modelo atribuibles a dicho año, por lo que los resultados globales se consideran representativos del período completo.

4. CONCLUSIONES

El modelo de redes neuronales (RNA) con información multiescala superó de forma consistente a los modelos físicos CAMS y NREL en todas las estaciones y métricas evaluadas. Mientras que los errores porcentuales $RMSE_n$ de CAMS y NREL oscilaron en-

tre 22 % y 30 %, la RNA logró reducir esos valores hasta el rango de 14 % a 18 %, dependiendo de la estación y el año.

En Paraná, por ejemplo, el modelo RNA alcanzó un $RMSE_n$ de 14.73 % en 2020 y un R^2 de 0.944, en contraste con los 20.60 % y 0.90 de NREL y los 21.87 % y 0.89 de CAMS para el mismo período. Esta ventaja se repite en Concepción del Uruguay, donde la RNA mantuvo el $RMSE_n$ en torno al 17–18 %, frente a valores superiores al 27 % en los modelos físicos.

Además del menor error, el modelo basado en RNA presentó un sesgo más contenido. Mientras CAMS mostró sesgos negativos extremos como -22.68 W/m^2 (Concepción, 2021), la RNA se mantuvo entre -1.6 y -8.3 W/m^2 , lo que representa una mayor neutralidad frente a sesgos del modelo.

En conjunto, estos resultados demuestran que la RNA no solo generaliza con éxito fuera del sitio de entrenamiento dentro de una zona climática afín, sino que logra aprovechar la información multiescala para lograr una mejor precisión y menor error sistemático que los modelos físicos tradicionalmente utilizados para estimación de irradiancia. Al estratificar por condición de cielo, la RNA presenta los menores MBE/MAE/RMSE en nublado y parcialmente nublado, mientras que en cielo despejado la red es superada por NREL y CAMS en las métricas MBE Y MAE. Este comportamiento es consistente con su diseño: la RNA aprende a partir de índices de nubosidad satelital y no incorpora un modelo de cielo claro, lo que es determinante cuando el cielo está despejado.

Por otra parte, la extrapolación espacial alcanzada en este trabajo demuestra la robustez del enfoque propuesto, incluso en estaciones ubicadas a más de 440 km de distancia. No obstante, a futuro será relevante evaluar el modelo en regiones aún más alejadas o climáticamente distintas, y explorar nuevas estrategias de entrenamiento. Una posibilidad prometedora sería entrenar con datos combinados de toda la Red Solarimétrica Nacional y extender la serie satelital a más años, lo que podría incrementar la capacidad de generalización del modelo a escala regional o nacional.

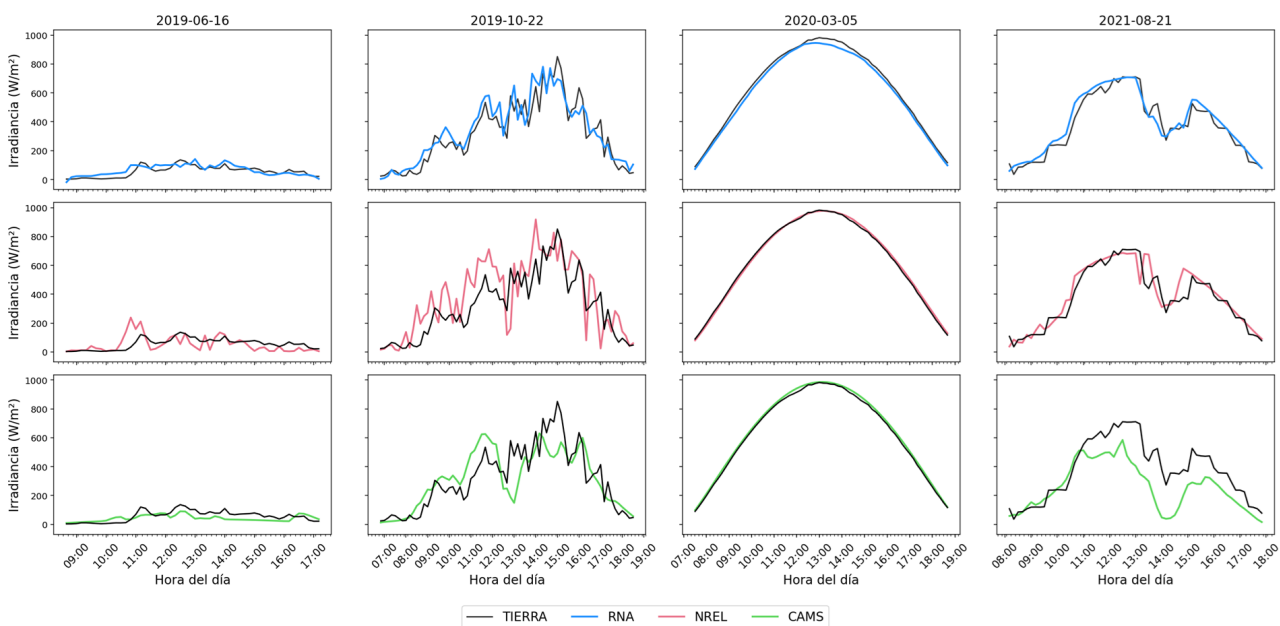


Fig. 4: Comparación de GHI 10-min de tierra con RNA (red entrenada con índices de nubosidad satelital), NREL y CAMS en cuatro días con distintas condiciones de nubosidad.

REFERENCIAS

- Alonso-Suárez, R., Abal, G., Righini, R., Nollas, F. M., Ramos-Martins, F., de Castro Vilela, O., ... y Zilles, R. (2024). Recomendaciones y Buenas Prácticas para la Medición y Registro de la Radiación Solar en Territorio.
- Iturbide, P., Alonso-Suarez, R., Ronchetti, F. (2023a). An Analysis of Satellite-Based Machine Learning Models to Estimate Global Solar Irradiance at a Horizontal Plane. In: Naiouf, M., Rucci, E., Chichizola, F., De Giusti, L. (eds) Cloud Computing, Big Data & Emerging Topics. JCC-BD&ET 2023. Communications in Computer and Information Science, vol 1828. Springer, Cham. https://doi.org/10.1007/978-3-031-40942-4_9
- Iturbide, P., Orsi, X., Denegri, M., Fioretti, S., Luza, S., Stern, V., Ruiz P., Alonso-Suarez R. y Ronchetti, F. (2023b). Modelos de machine learning para estimar la radiación solar horizontal en la Pampa Húmeda con información satelital multiescala. Avances en Energías Renovables y Medio Ambiente.
- Laguarda, A., Alonso-Suárez, R., y Abal, G. (2018). Modelo semi-empírico de irradiación solar global a partir de imágenes satelitales GOES. Anales del VII Congresso Brasileiro de Energia Solar.
- Lefèvre, M., Oumbe, A., Blanc, P., Espinar, B., Qu, Z., Wald, L., Homscheidt, M. S., y Arola, A. (2013). McClear: a new model estimating downwelling solar radiation at ground level in clear-sky conditions. Atmospheric Measurement Techniques, European Geosciences Union, 6 , 2403–2418. doi:10.5194/amt-6-2403-2013.
- Long, C. N., y Shi, Y. (2008). An automated quality assessment and control algorithm for surface radiation measurements. The Open Atmospheric Science Journal, 2(1).
- Perez, R., Ineichen, P., Seals, R., y Zelenka, A. (1990). Making full use of the clearness index for parameterizing hourly insolation conditions. Solar Energy, 45(2), 111-114.
- Qu, Z., Oumbe, A., Blanc, P., Espinar, B., Gesell, G., Gschwind, B., Klüser, L., Lefèvre, M., Saboret, L., Schroedter-Homscheidt, M., y Wald, L. (2017). Fast radiative transfer parameterisation for assessing the surface solar irradiance: The Heliosat-4 method. Meteorologische Zeitschrift, 26(1):33–57