

Evaluación de desempeño y corrección de los pronósticos de radiación solar global del SAP.SMN-DET

Nota Técnica SMN 2026-216

**Germán Salazar^{1,2}, Rubén Ledesma^{1,2}, Silvina Righetti^{3,4},
Cynthia Matsudo³, Anahí Lanson⁵, María José Denegri⁵, Hamid
Bastani⁶**

¹ Universidad Nacional de Salta.

² Instituto de Investigaciones en Energía No Convencional, CONICET.

³ Dirección de Productos de Modelación Ambiental y de Sensores Remotos, Dirección Nacional de Ciencia e Innovación en Productos y Servicios, Servicio Meteorológico Nacional.

⁴ Departamento de Ciencias de la Atmósfera y los Océanos, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires.

⁵ Grupo de Estudios de la Radiación Solar, Universidad Nacional de Luján.

⁶ Organización Meteorológica Mundial.

Agosto 2026

Información sobre Copyright

Este reporte ha sido producido por empleados del Servicio Meteorológico Nacional con el fin de documentar sus actividades de investigación y desarrollo. El presente trabajo ha tenido cierto nivel de revisión por otros miembros de la institución, pero ninguno de los resultados o juicios expresados aquí presuponen un aval implícito o explícito del Servicio Meteorológico Nacional.

La información aquí presentada puede ser reproducida a condición que la fuente sea adecuadamente citada.

Resumen

En el marco del Plan de Desarrollo de Capacidades de la Organización Meteorológica Mundial y el proyecto ENANDES+ se desarrolló el miniproyecto *“Energy mini-project on AI-based performance evaluation and correction of solar radiation forecasts from the Weather Research and Forecasting (WRF) numerical prediction model (Ref. 6455259-2025/GS/PEX)”*. El objetivo del mismo fue evaluar y calibrar los pronósticos determinísticos de radiación solar global (GHI, de sus siglas en inglés) del modelo numérico operativo en el Servicio Meteorológico Nacional, aplicando una técnica de aprendizaje automático para 3 sitios de la región pampeana (Buenos Aires, Pilar y Armstrong).

La evaluación de los pronósticos a 72 horas de GHI evidenció una sobreestimación sistemática del modelo. Durante las horas del día el error relativo medio (rRMSE) se situó entre el 30% y 45%, registrándose máximos superiores a 65% durante el amanecer y atardecer. Asimismo, el modelo demostró una alta precisión para identificar condiciones de cielo claro (~90% de aciertos), pero disminuyó su desempeño considerablemente ante cielos parcialmente nublados (40%) y cubiertos (10%).

Para corregir los errores, se aplicó una técnica basada en aprendizaje automático mediante un perceptrón multicapa (MLP, de sus siglas en inglés). El modelo optimizado (MLP3) redujo drásticamente el sesgo de ~24% a valores cercanos al 0%, disminuyendo el rRMSE en aproximadamente 10%. Por último, las pruebas de validación cruzada confirmaron que la metodología presenta una transferencia intersitio estable y una robusta capacidad de generalización regional.

Abstract

Within the framework of the World Meteorological Organization's Capacity Development Plan and the ENANDES+ project, the mini-project entitled *“Energy mini-project on AI-based performance evaluation and correction of solar radiation forecasts from the Weather Research and Forecasting (WRF) numerical prediction model”* (Ref. 6455259-2025/GS/PEX) was developed. Its objective was to evaluate and calibrate deterministic global horizontal irradiance (GHI) forecasts produced by the operational numerical weather prediction model at the National Meteorological Service, using a machine learning technique at three sites in the Pampas region: Buenos Aires, Pilar, and Armstrong.

The evaluation of the 72-hour GHI forecasts revealed a systematic overestimation by the model. During daylight hours, the relative root mean square error (rRMSE) ranged from 30% to 45%, with peaks exceeding 65% around sunrise and sunset. Although the model showed high accuracy in identifying clear-sky conditions, with a success rate of approximately 90%, its performance deteriorated substantially under partially cloudy and overcast conditions, with success rates of around 40% and 10%, respectively.

To address these errors, a machine learning approach based on a multilayer perceptron (MLP) was applied. The optimized configuration (MLP3) substantially reduced the bias, from approximately 24% to values close to 0%, while decreasing the rRMSE by about 10%. Finally, cross-validation tests demonstrated that the methodology has stable inter-site transferability and robust regional generalization capabilities.

Palabras clave: radiación solar, WRF, verificación, calibración

Citar como:

Salazar, G., Ledesma, R., Righetti, S., Matsudo, C., Lanson, A., Denegri, M. J., Bastani, H., 2026: Evaluación de desempeño y corrección de los pronósticos de radiación solar global del SAP.SMN-DET. Nota Técnica SMN 2026-216.

INTRODUCCIÓN

En el marco de la reunión de marzo de 2024 de la Comisión de Servicios de la OMM (SERCOM-3), se impulsó el Plan de Desarrollo de Capacidades a Largo Plazo para Servicios Energéticos. La meta principal de esta iniciativa fue dar seguimiento y detectar brechas en los servicios meteorológicos, hidrológicos y climáticos que requiere el sector energético en los países miembros de la OMM. Asimismo, se buscó diseñar y ejecutar las acciones necesarias para responder a dichas demandas desde los Servicios Meteorológicos e Hidrológicos Nacionales (SMHN).

Uno de los pilares del plan consistió en implementar "Miniproyectos Nacionales de Energía" pensados como intervenciones a pequeña escala, viables económicamente, escalables y con rigor científico. De este modo, se buscó transformar el conocimiento teórico en herramientas de uso práctico mediante el codesarrollo de productos a medida y compartir los resultados y metodologías.

Aprovechando el marco del proyecto regional ENANDES+ (que abarca a Argentina, Bolivia, Chile, Colombia, Ecuador y Perú), se buscó resolver una necesidad puntual orientada a la generación de productos específicos para el sector energético, dando financiamiento a un Miniproyecto para Argentina a través de la contratación de una consultoría externa. El proyecto se denominó *"Energy mini-project on AI-based performance evaluation and correction of solar radiation forecasts from the Weather Research and Forecasting (WRF) numerical prediction model (Ref. 6455259-2025/GS/PEX)"* y fue llevado a cabo desde agosto de 2025 a junio de 2026. Como resultado final se entregaron insumos estandarizados: código abierto y estructurado, un documento técnico con instructivos paso a paso para reproducir la metodología, y un breve material audiovisual para la capacitación de los usuarios.

En esta nota técnica se presenta el documento del primer entregable del proyecto, donde se muestra la evaluación de desempeño de los pronósticos determinísticos de radiación solar global del Sistema de Asimilación y Pronóstico numérico del Servicio Meteorológico Nacional (SAP.SMN), junto con la metodología de calibración de los mismos basada en la aplicación de una técnica de aprendizaje automático.



ENANDES and ENANDES+ Projects

Enhancing Adaptive Capacity of Andean Communities through Climate Services in Chile, Colombia, Peru (ENANDES), and Argentina, Bolivia, Ecuador (ENANDES+)

Activity: Energy mini-project on AI-based performance evaluation and correction of solar radiation forecasts from the Weather Research and Forecasting (WRF) numerical prediction model (Ref. 6455259-2025/GS/PEX)

Deliverable N°1: First report on the evaluation of the NWP WRF forecast by SMN, using observational data from three locations

History of draft preparation and review

V1.0- Initial draft by Germán Ariel Salazar and Rubén Darío Ledesma (UNSa-INENCO-CONICET)	14/11/2025
V2.0 – Revised based on review and comments by Silvana Righetti and Cynthia Matsudo (SMN), Anahí Lanson, María José Denegri (UNLu), and Hamid Bastani (OMM)	27/11/2025
V3.0 – Revised based on review and comments by Silvana Righetti and Cynthia Matsudo (SMN), and Hamid Bastani (OMM)	03/02/2026
V4.0 - Revised based on review and comments by Silvana Righetti and Cynthia Matsudo (SMN), and Hamid Bastani (OMM)	08/04/2026
V5.0 - Revised based on review and comments by Silvana Righetti and Cynthia Matsudo (SMN), and Hamid Bastani (OMM)	30/04/2026

Autores: Dr. Germán Ariel Salazar, Lic. Rubén Darío Ledesma.

Colaboradores: Dr. Silvina Righetti (SMN), Ms. Cynthia Matsudo (SMN), Dr. Anahí Lanson (UNLu), Dr. María José Denegri (UNLu), Dr. Hamid Bastani (WMO)

ÍNDICE DE CAPÍTULOS Y SUBCAPÍTULOS

1. Propósito de la Consultoría

2. Descripción de los valores de GHI medidos en los sitios

- 2.1. Estadísticas climáticas de los sitios y de los datos medidos
- 2.2. Control de calidad aplicado a los datos de GHI medidos con frecuencia minutal
 - 2.2.1. Filtros de control de calidad utilizados
 - 2.2.2. Prueba de completitud
 - 2.2.3. Integración horaria de los datos medidos

3. Descripción de los datos pronosticados por el modelo WRF-SMN

- 3.1. Extracción y control de la completitud
- 3.2. Formato e información disponible

4. Evaluación del modelo WRF-SMN de la radiación global frente a los datos medidos

- 4.1. Métricas a utilizar para evaluar el desempeño del modelo
- 4.2. Evaluación del desempeño del pronóstico de GHI
- 4.3. Análisis de condiciones de cielo pronosticadas y medidas

5. Proceso de mejora de los pronósticos del modelo WRF-SMN

- 5.1. Conformación del conjunto de datos
- 5.2. Selección del MLP
- 5.3. División de datos para entrenamiento, validación y prueba
- 5.4. Escalado de variables
- 5.5. Entrenamiento y seguimiento del aprendizaje
- 5.6. Criterio de selección del mejor MLP
- 5.7. Análisis de correlación y elección de regresores
- 5.8. Evaluación de MLPs con diferentes regresores
- 5.9. Evaluación de validación cruzada entre sitios (cross-validation)
- 5.10. Resultado de la corrección de los errores del modelo WRF-SMN
- 5.11. Síntesis final de la aplicación de MLP

6. Resumen de los resultados

ÍNDICE DE TABLAS

Tabla 1. Información geográfica de los sitios cuyos valores de GHI medidos se compararán con los pronósticos de WRF-SMN.

Tabla 2. Valores estadísticos normales del sitio BA.

Tabla 3. Valores estadísticos normales del sitio PI.

Tabla 4. Valores estadísticos normales del sitio MJ. Los datos de esta estación se asociarán a los de Armstrong, ya que es la más cercana.

Tabla 5. Discriminación de los valores de frecuencia minutal de GHI de la base de datos medidos para el sitio Buenos Aires (BA).

Tabla 6. Discriminación de los valores de frecuencia minutal de GHI de la base de datos medidos para el sitio Armstrong (AR).

Tabla 7. Discriminación de los valores de frecuencia minutal de GHI de la base de datos medidos para el sitio Pilar (PI).

Tabla 8. Distribución de valores medidos y pronosticados de GHI por corrida, según valid_time, para BA (enero 2023).

Tabla 9. Métricas de desempeño de los valores pronosticados de GHI frente a los valores medidos para BA.

Tabla 10. Métricas de desempeño de los valores pronosticados de GHI frente a los valores medidos en PI.

Tabla 11. Métricas de desempeño de los valores pronosticados de GHI frente a los valores medidos en AR.

Tabla 12. Métricas de desempeño de los valores pronosticados (Original) y de los adaptados (MLP1) vs los valores medidos, para BA.

Tabla 13. Métricas de desempeño de los valores pronosticados (Original) y de los adaptados (MLP1, MLP2 y MLP3) frente a los valores medidos, para BA.

Tabla 14. Métricas de desempeño de los valores pronosticados (modelo) y de los adaptados (MLP1, MLP2 y MLP3) vs los valores medidos, para PI.

Tabla 15. Métricas de desempeño de los valores pronosticados (modelo) y de los adaptados (MLP1, MLP2 y MLP3) vs los valores medidos, para AR.

ÍNDICE DE FIGURAS

- Figura 1. Posiciones geográficas de las estaciones cuyos datos de GHI se analizan en este reporte.
- Figura 2a. Distribución de los valores de GHI minutales medidos en BA en 2023.
- Figura 2b. Distribución de los valores de GHI minutales medidos en BA en 2024.
- Figura 3. Distribución de los valores de GHI minutales medidos en AR en 2023.
- Figura 4a. Distribución de los valores de GHI minutales medidos en PI en 2023.
- Figura 4b. Distribución de los valores de GHI minutales medidos en PI en 2024.
- Figura 5. Comparación del GHI horario de cielo claro para BA en junio y diciembre.
- Figura 6. Evolución de la métrica rRMSE para BA en 2023, para cada leadtime.
- Figura 7. Evolución de la métrica rRMSE para PI en 2023.
- Figura 8. Evolución de la métrica rRMSE para AR en 2023.
- Figura 9. Fracciones de recall, claras y nubladas, para los tres sitios en 2023.
- Figura 10. Fracción de recall claro, parcial (nublado) y nublado en los tres sitios en 2023.
- Figura 11. Esquema de una MLP general, donde se observan 3 capas ocultas.
- Figura 12. Correlación entre las variables predichas por el modelo WRF-SMN y los valores de GHI medidos en BA.
- Figura 13. Matriz de rRMSE de la validación cruzada de MLP para los tres sitios analizados.
- Figura 14. Evolución del error rRMSE para cada leadtime L para BA 2023.
- Figura 15. Evolución del error acumulado hasta leadtime L para PI 2023.
- Figura 16. Evolución del error acumulado hasta leadtime L para AR 2023.

ÍNDICE DE ECUACIONES

Ecuación (1). Filtro superior de GHI (Nollas et al., 2023).

Ecuación (2). Filtro inferior de GHI (Nollas et al., 2023).

Ecuación (3). Filtro de índice de claridad.

Ecuación (4). Conversión de ACSWDNB a GHI pronosticado.

Ecuación (5). Error medio de bias MBE.

Ecuación (6). Error medio de bias relativo rMBE.

Ecuación (7). Raíz del error cuadrático medio RMSE.

Ecuación (8). Raíz del error cuadrático medio relativo rRMSE.

Ecuación (9). Estandarización de variables predictoras.

Ecuación (10). Función de pérdida cuadrática media del MLP.

Palabras comunes en el texto:

- **Modelo:** se refiere al modelo numérico Weather and Research Forecasting del Servicio Meteorológico Nacional (WRF-SMN)
- **Pronósticos:** valores de variables meteorológicas previstos por el modelo, con un rango de horizonte de 1 a 72 horas y frecuencia horaria.
- **Medidos:** valores de las variables meteorológicas en sitios de interés.
- **GHI:** Global Horizontal Irradiance o Irradiancia Global Horizontal. Se expresa en Watt/metro².
- **Variables:** magnitudes físicas o meteorológicas previstas por el modelo. En este informe se analizan los valores pronosticados y medidos de GHI.
- **date:** indica la fecha de inicio de la estimación (en formato AAAAmmdd), donde AAAA es el año, mm el mes y dd el día. Por ejemplo, 20230514 representa el 14 de mayo de 2023.
- **corrida:** indica a qué hora de la date comienza la previsión a 72 horas, y puede ser 00, 06, 12 o 18 UTC.
- **leadtime (L):** indica el plazo de pronóstico para esa corrida. Por ejemplo, date = 20230101 corrida = 0, leadtime = 5 quiere decir que es la previsión de la quinta hora comenzando desde el 01/01/2023 a las 00:00 UTC.
- **time_stamp:** es la fecha y hora asociadas a un dato e indican cuándo es válido o cuándo fue registrado. Por ejemplo: 23-05-01 14:00 UTC.
- **valid_time:** es la fecha y hora a las que efectivamente se asigna una previsión en la corrida. El formato es AAAA-mm-dd HH:MM, donde HH es la hora y MM los minutos. Por ejemplo, a los valores previstos para la date 20230101, corrida 0 y leadtime 5 se les asigna el valid_time 2023-01-01 05:00. Esto permite luego relacionar los valores previstos con los valores medidos.
- **Error puntual (e_i):** se define como la diferencia entre el valor observado y_i y el valor pronosticado $\hat{y}_i$.
- **Minutal:** de resolución minuto a minuto, o con frecuencia de 1 minuto.
- **Variable objetivo:** es la salida que se desea predecir; corresponde a la magnitud medida (observada) que el modelo intenta reproducir a partir de las variables predictoras de entrada.
- **Regresor:** variable de entrada que aporta información para explicar y predecir la variable objetivo. En un modelo de regresión, cada regresor actúa como una característica que contribuye a estimar el valor continuo de la variable objetivo.

Metodología (Algoritmo paso a paso)

1. **Control de calidad de datos de GHI medidos con frecuencia minutal.** Usando los filtros de Nollas et al (2023) se descartan GHI anómalos medidos con frecuencia minutal. Se determina el `valid_time` minutal, de modo que a todos los valores medidos (incluidos los valores NaN) se les asigne uno.
2. **Integración horaria de los datos de GHI medidos con frecuencia minutal.** Si no se tienen al menos 12 datos minutales válidos por hora, se descartan esos datos y se asigna NaN a esa hora. Asignación de `valid_time` horario de valores medidos.
3. **Descarga de los pronósticos horarios de WRF-SMN.** Descarga de los valores de todas las variables asociadas a las dates y corridas deseadas.
4. **Determinación de las celdas que contienen los sitios de interés.** A partir de las posiciones geográficas de los sitios a analizar, se determinan las celdas que incluyen cada sitio.
5. **Preprocesamiento antes de comparación de datos pronosticados con medidos.** Cálculo de `valid_time` horario para datos pronosticados.
6. **Preprocesamiento antes de comparación de datos pronosticados con medidos.** Conversión de la variable pronosticada ACSWDNB (radiación solar de onda corta entrante) de J/m^2 a W/m^2 .
7. **Preprocesamiento antes de comparación de datos pronosticados con medidos.** Revisión de la posible existencia de desfase entre el GHI pronosticado y el GHI medido, según el `valid_time` asignado a cada grupo. Si los momentos de salida y de puesta de sol de ambos grupos no coinciden, se desplazan los valores medidos hasta que coincidan con los valores de GHI pronosticados (revisión visual).
8. **Comparación de los valores horarios pronosticados vs. medidos, usando las métricas rMBE y rRMSE.** Cálculo de evolución del error rMBE y rRMSE en el pronóstico de GHI, para cada leadtime L, de 1 a 72 horas.
9. **Adaptación al sitio usando MLP.** Determinación de los regresores a emplear en función de las variables descargadas.
10. **Adaptación al sitio usando MLP.** Determinación del orden de regresores y su escalado.
11. **Adaptación al sitio usando MLP.** Separación aleatoria de los datos en conjuntos de entrenamiento (train), de validación (val) y de prueba (test).
12. **Adaptación al sitio usando MLP.** Cálculo de modelos MLP variando hiperparámetros.
13. **Adaptación al Sitio usando MLP.** Determinación del mejor modelo mediante la inspección de los menores valores de rMBE y rRMSE en el conjunto de prueba (test).
14. **Cross-Validation.** Medición de la evolución del error rRMSE de los valores pronosticados, ya adaptados a las 72 horas, aplicando el MLP entrenado en otros sitios con los datos de entrenamiento de cada sitio.

1. Propósito de la Consultoría.

El propósito de esta consultoría es evaluar el desempeño del modelo de predicción numérica del Servicio Meteorológico Nacional argentino (SMN), denominado Weather and Research Forecasting v4.0 (WRF-SMN) (Skamarock et al., 2020; Dillon et al., 2020), para pronósticos de variables meteorológicas, con horizontes de 1 a 72 horas, en corridas a las 00, 06, 12 y 18 UTC. Específicamente, el interés radica en la variable Irradiancia Horizontal Global solar (Global Horizontal Irradiance, GHI, siglas en inglés). Para esta evaluación, se compararán los pronósticos horarios con los valores horarios medidos en superficie en tres sitios de la región pampeana argentina.


Evaluable el desempeño, se realiza una adaptación al sitio (site adaptation en inglés) (Polo et al., 2016, 2020; Fernández-Peruchena et al., 2020) buscando minimizar las diferencias entre los valores pronosticados y los medidos de GHI en superficie. La función de adaptación se busca con aprendizaje automático (machine learning, ML, siglas en inglés), utilizando un perceptrón multicapa (MLP).

2. Descripción de los valores de GHI medidos en los sitios

Para evaluar el desempeño del modelo WRF-SMN se compararán sus pronósticos con los valores medidos en 3 sitios de la región central de Argentina: Buenos Aires (BA), Armstrong (AR) y Pilar (PI). En la Figura 1 se muestran las posiciones geográficas de cada uno. Los tres sitios se encuentran en 3 provincias distintas: BA está en la Ciudad Autónoma de Buenos Aires, AR en la provincia de Santa Fe y PI en la provincia de Córdoba. La distancia de BA y AR es de aproximadamente 360 kilómetros, mientras que de AR hasta PI hay 247 kilómetros. En la Tabla 1 se muestran la latitud, longitud y altitud sobre el nivel del mar de cada sitio.

Código	Sitio	Provincia	Latitud (°)	Longitud (°)	Altura sobre el nivel del mar (m)
BA	Buenos Aires	CABA	34.60 S	58.48 O	30
AR	Armstrong	Santa Fe	32.78 S	64.60 O	110
PI	Pilar	Córdoba	31.67 S	63.88 O	335

Tabla 1. Información geográfica de los sitios cuyos valores de GHI medidos se compararán con los pronósticos de WRF-SMN.



Figural. Posiciones geográficas de las estaciones cuyos datos de GHI se analizan en este reporte (en Google Earth®, 2025).

2.1. Estadísticas climáticas de los sitios y de los datos medidos

En la Tabla 2 se muestran las estadísticas climáticas normales 1991-2020 (Servicio Meteorológico Nacional, 2023) para BA; en la Tabla 3, las de PI; y en la Tabla 4, las de la estación Marcos Juárez (MJ), ya que en Armstrong (AR) no hay estación del SMN y es la más cercana (47 km)

En esas Tablas se muestran el promedio mensual de la temperatura (T prom.), el promedio mensual de la temperatura máxima (Tmax prom.) y el promedio mensual de la temperatura mínima (Tmin prom.). También se muestran las estadísticas de la humedad relativa (HR), similares a las usadas para la temperatura: HRmax prom., HR prom. y HRmin prom. para cada sitio y mes.

Por otro lado, se calcularon los valores de heliofanía astronómicamente posibles (HeMax Astr.) para cada mes, es decir, el número de horas de sol directo que se tendrían sin nubes. La heliofanía efectiva (HeEf prom.), que indica las horas diarias efectivas de sol directo en cada sitio, permite calcular la heliofanía relativa (HeRel prom.), definida como la relación entre la heliofanía efectiva y la heliofanía astronómicamente posible. La heliofanía relativa puede interpretarse como el porcentaje de horas de sol registradas respecto del máximo posible.

Por último, se muestran las frecuencias de ocurrencia de días con cielo nublado (FDCN) y de días con cielo claro (FDCC), ya que están directamente relacionadas con el objetivo de este reporte.

	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Anual
Tmax prom. (°C)	30.1	28.9	27	23.2	19.4	16.4	15.5	17.9	19.7	22.6	26	29	23
T prom. (°C)	24.9	23.8	22	18.2	14.8	12	11	13	14.9	17.9	20.9	23.6	18.1
Tmin Prom. (°C)	20.2	19.4	17.7	14.1	11.1	8.4	7.5	8.9	10.6	13.4	16.1	18.5	13.8
He Max Astr. (hs)	14.08	13.25	12.26	11.12	10.19	9.7	9.9	10.7	11.8	12.89	13.85	14.31	12.00
He Ef prom. (hs)	8.8	7.9	7	5.6	5.1	4.5	4.6	5.5	6	6.6	8.2	8.6	6.5
He Rel prom. (hs)	0.63	0.60	0.57	0.50	0.50	0.46	0.46	0.51	0.51	0.51	0.59	0.60	0.54
FDCN max prom.	6	6.6	7.2	9.4	11.1	11.6	12	10.8	10.3	10.4	8.2	7	110.6
FDCN prom.	13	14	15	21	17	22	21	18	14	17	13	18	136
FDCN min prom.	1	1	2	2	2	4	6	4	4	4	2	1	77
FDCC mas prom.	12.7	12.3	13.7	11.5	9.6	8.9	8.8	10.2	9.5	9.2	11.4	13	131.1
FDCC prom.	20	20	20	20	15	16	17	18	16	17	19	20	174
FDCC min prom.	7	2	3	5	2	2	3	2	3	4	5	5	104

Tabla 2. Valores estadísticos normales del sitio BA.

	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Anual
Tmax prom. (°C)	30.1	28.3	27	24	20.2	17.6	17.1	20.2	22.6	25.1	28	30	24.18
T prom. (°C)	23.7	22.1	20.6	17.3	13.7	10.6	9.6	12	14.9	18.2	21.1	23.3	17.26
Tmin Prom. (°C)	18	17	15.5	12.3	8.9	5.3	4.2	5.7	8.4	12.1	14.8	17.1	11.61
He Max Astr. (hs)	13.85	13.12	12.2	11.19	10.36	9.94	10.14	10.87	11.85	12.83	13.67	14.06	12.01
He Ef prom. (hs)	9.2	8.2	7.5	6.4	5.7	5.7	6.2	7.2	7.4	7.7	8.9	8.9	7.42
He Rel prom. (hs)	0.66	0.63	0.61	0.57	0.55	0.57	0.61	0.66	0.62	0.6	0.65	0.63	0.62
FDCN max prom.	6.9	8	8.7	10.2	12	9.2	8.9	6.8	7.3	9	7.6	7.1	101.6
FDCN prom.	13	15	19	19	22	22	18	14	15	20	14	15	141
FDCN min prom.	1	3	1	2	2	2	2	2	1	2	1	2	70
FDCC mas prom.	11.6	10.5	12.8	11.3	9.3	11.2	13.6	15.1	13.7	12	11.6	11.4	144.2
FDCC prom.	19	17	21	19	19	18	22	22	19	19	20	19	187
FDCC min prom.	7	3	7	1	1	0	8	5	7	4	6	3	109

Tabla 3. Valores estadísticos normales del sitio PI.

	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Anual
Tmax prom. (°C)	30.4	28.9	27.9	24.4	20.4	17.3	16.8	19.7	22.3	25.1	28.1	30	24.28
T prom. (°C)	23.5	22.1	20.6	17.2	13.5	10.3	9.2	11.3	14.2	17.8	20.9	22.9	16.96
Tmin Prom. (°C)	17.2	16.2	14.7	11.7	8.3	4.9	3.5	4.8	7.2	11.2	14	16.1	10.82
He Max Astr. (hs)	13.93	13.16	12.21	11.15	10.3	9.86	10.06	10.82	11.84	12.86	13.74	14.15	12.01
He Ef prom. (hs)	9.3	8.4	7.3	6	5.3	4.8	5.4	6.4	6.8	7.3	8.7	9	7.1
He Rel prom. (hs)	0.67	0.64	0.60	0.54	0.51	0.49	0.54	0.59	0.57	0.57	0.63	0.64	0.59
FDCN max prom.	5.5	6.5	6.7	9.5	10.5	10.9	9.9	7.8	7.5	9.1	7.8	6.5	98.2
FDCN prom.	13	16	14	18	18	24	17	17	13	18	16	12	120
FDCN min prom.	1	2	1	1	4	4	3	1	1	2	2	1	66
FDCC mas prom.	13.1	12.7	14.5	11.8	10.9	10.2	12.4	14.2	12.7	10.9	12.7	12.8	149.1
FDCC prom.	21	20	20	19	21	17	18	20	19	19	18	19	192
FDCC min prom.	5	3	7	2	3	1	4	4	2	3	6	2	105

Tabla 4. Valores estadísticos normales del sitio MJ. Los datos de esta estación se asociarán a los de Armstrong, ya que es la más cercana.

En el período 1991–2020, los tres sitios (BA, PI y AR) muestran ciclos estacionales muy similares en la variable HeMax Astr.: el valor anual es prácticamente idéntico (~12.0 h) y las diferencias mensuales son despreciables. Esto indica que las discrepancias entre sitios en radiación solar disponible no provienen de la geometría Sol-Tierra, sino de procesos atmosféricos (nubosidad y humedad) y, en menor medida, de rasgos locales. La comparación de HeEf y HeRel indica que, aunque los tres sitios comparten casi el mismo máximo astronómico, BA presenta una HeEf anual menor (6.5 h) que PI (7.4 h) y AR (7.1 h), y también una HeRel anual menor (0.54 frente a 0.62 en PI y 0.59 en AR). En términos físicos, esto implica que BA, en promedio, convierte una fracción menor de su potencial astronómico en horas de brillo solar efectivo, lo que es compatible con una mayor frecuencia de nubosidad y/o condiciones atmosféricas que reducen la insolación directa.

En promedio anual, BA resulta el sitio más nublado (FDCN = 110.6 días/año) y el menos “claro” (FDCC = 174 días/año), mientras que AR aparece como el más claro (FDCC = 192 días/año) y el menos nublado (FDCN = 98.2 días/año). PI queda en posición intermedia (FDCC = 187 días/año, FDCN = 101.6 días/año), más cercano a AR que a BA en términos de “claridad” media. Importante: estos FDC describen la cantidad/frecuencia de días por mes (climatología), no la persistencia o rachas de días claros/nublados.

En temperatura, PI y AR se comportan de manera muy parecida, especialmente en Tmax prom. y T prom., mientras que BA se diferencia principalmente por las temperaturas mínimas. En términos anuales, BA presenta Tmin prom. = 13.8 °C, claramente superior a PI (11.6 °C) y AR (10.8 °C), con brechas que se amplifican en invierno (por ejemplo, en julio BA supera a PI/AR por ~3–4 °C). En contraste, la Tmax anual es menor en BA (23.0 °C) que en PI y AR (24.2–24.3 °C, respectivamente), lo que sugiere un régimen térmico con noches más templadas, y máximas con menor intensidad térmica diurna.

En conjunto, BA, PI y AR integran un grupo climáticamente homogéneo a escala regional, con diferencias principalmente asociadas a la nubosidad y al comportamiento nocturno de la temperatura.

2.2. Control de calidad aplicado a los datos de GHI medidos con frecuencia minutal.

Los datos medidos analizados corresponden a 2023 y 2024.

2.2.1. Filtros de control de calidad utilizados.

El control de calidad de los datos de GHI medidos con frecuencia minutal se realiza para filtrar valores anómalos o raros. Los filtros de la Baseline Solar Radiation Network (BSRN; <https://bsrn.awi.de/data/quality-checks/>) son una metodología ampliamente reconocida como un marco de referencia para el control de calidad de datos radiométricos, pero requieren tres componentes: irradiancia solar global (GHI), irradiancia solar directa normal (DNI) e irradiancia solar difusa (DHI). En este caso, solo se dispone de datos de GHI medidos. Por eso, se aplicaron los filtros únicamente a los valores de la GHI (Nollas *et al.*, 2023).

$$GHI < 1.5 S_{Esc} (\cos SZA)^{1.2} + 100 \text{ W/m}^2 \quad (1)$$

$$GHI > (6.5331 - 0.065502 SZA + 1.831 \times 10^{-4} SZA^2) / (1 + 0.001113 SZA) \quad (2)$$

$$k_t < 1.4 \quad (3)$$

donde S es el factor de corrección de la distancia Tierra-Sol, Esc es el valor de la constante solar (1361.1 W/m²) y SZA es el ángulo solar cenital, definido como el ángulo entre el cenit y la posición aparente del Sol. k_t es el índice de claridad definido como la razón entre la GHI medida en superficie y la GHI extraterrestre (por encima de la atmósfera). Los GHI medidos que cumplan estas condiciones se consideran aptos; de lo contrario, no se toman en cuenta para procesos posteriores.

Los valores diurnos de GHI pueden determinarse a partir del ángulo SZA, ya que corresponden a $SZA < 90^\circ$ o a $\cos SZA > 0$.

Se realiza una inspección visual para determinar si los datos medidos están en horario UTC o en GMT-3.

2.2.2. Prueba de completitud

El análisis de completitud se realiza para determinar si la cantidad de datos de GHI medidos coincide con la esperada y, de no ser así, en qué proporción difieren. Por ejemplo, si un sensor mide cada 1 minuto, es de esperarse que en un año normal registre 525600 datos (527040 si es año bisiesto), por lo que, si tiene menos o más datos que esa cantidad, se deberá investigar la razón de esa variación.

La Tabla 5 (así como la Tabla 6 y la Tabla 7) discrimina:

- La cantidad de datos esperada (Esperados) para el año completo.
- La cantidad de registros medidos que presentan time-stamp del año 2023 o 2024 (Presentes).
- La cantidad de datos cuya time-stamp aparece, pero no hay valor medido (Faltantes).
- La cantidad de datos duplicados, es decir, cuando se repite la misma time-stamp (Duplicados).
- La cantidad de datos medidos presentes (OK). De los duplicados se escoge solo uno para ponerlo como OK.
- El porcentaje que representan los datos OK sobre los esperados (% OK).
- El porcentaje que representan los datos OK sobre los esperados para horas del día (% OK día).
- El porcentaje que representan los datos OK sobre los esperados para horas de noche (% OK noche).

i) **BA:** Se analizaron los datos medidos entre el 01/01/2023 a las 00:00 y el 31/12/2024 a las 23:59 UTC. Los datos medidos tienen una frecuencia de muestreo de 1 minuto.

Año	# datos esperados	# datos presentes	# datos OK	# datos faltantes	# datos duplicados	% datos OK	% OK día	% OK noche
2023	525600	529859	524061	1539	5798	99.71	49.71	50.00
2024	527040	524113	524099	2941	14	99.44	49.62	49.81

Tabla 5: Discriminación de los valores de frecuencia minatural de GHI de la base de datos medidos para el sitio Buenos Aires (BA)

Los resultados de la Tabla 5 indican que los datos medidos en BA en 2023 y 2024 están prácticamente completos, es decir, no hay “lagunas” que puedan afectar el valor de la integración horaria.

Para mostrar la evolución de la GHI se usará un gráfico del tipo “snake skin” (cuero de serpiente) que permite visualizar en un solo plano el ciclo diurno, la estacionalidad y el impacto de la nubosidad sobre el GHI, facilitando la detección de patrones climáticos, anomalías y problemas de calidad de datos. En el costado derecho se observa la referencia de los valores minutales de GHI, siendo negro el color para GHI=0 (nocturno) y el rango ascendente que va de colores oscuros a más claros. En las Figuras 2a y 2b se muestra la cantidad de datos faltantes (marcados en blanco) en BA, lo que evidencia una tasa de completitud muy alta.





Figura 2a. Distribución de los valores de GHI minutales medidos en BA en 2023. En blanco se observan los datos faltantes. En el polígono rojo se resaltan sombreado por árboles y/o edificios.



Figura

2b. Distribución de los valores de GHI minutales medidos en BA en 2024. En blanco se observan los datos faltantes.

Los gráficos de GHI para Buenos Aires reproducen el ciclo anual esperado: mayor duración del día y máximos de irradiancia en verano, y una franja diurna más corta y de menor intensidad en invierno. La estructura intra-diurna muestra una alta variabilidad, compatible con nubosidad intermitente. Los datos faltantes se evidencian como trazos blancos verticales; en 2023 destaca un faltante mayor alrededor de inicios de mayo y, en 2024, un quiebre marcado cerca de inicios de agosto, además de faltantes mayores distribuidos a lo largo del año. En conjunto, las figuras sugieren consistencia física del registro, pero requieren reportar la completitud diurna para interpretar métricas mensuales/anuales sin sesgo por faltantes.


Resulta interesante observar el sombreado por árboles y/o edificios (Figura 2a), probablemente debido a la proximidad del sitio donde está instalado el sensor.

ii) **AR:** Los datos medidos se comienzan a analizar a partir del 31/03/2023 a las 15:00 y terminan el 31/12/2023 a las 23:59 HOA. Antes de la fecha de inicio no hay suficiente cantidad de datos para que puedan ser considerados. La frecuencia de medición es de 1 minuto. En la Tabla 6 se aprecia que esta estación presenta problemas en el registro de sus datos (faltantes $\approx 37\%$ de los datos totales), lo que deja $\sim 63\%$ de los datos para el análisis. De esos, solo el 30% son datos de día.

Año	# datos esperados	# datos presentes	# datos OK	# datos faltantes	# datos duplicados	% datos OK	% OK día	% OK noche
2023	525600	331726	329637	195963	2089	62.72	30.28	32.44

Tabla 6: Discriminación de los valores de frecuencia minutal de GHI de la base de datos medidos para el sitio Armstrong (AR).

La Figura 3 muestra una especie de degradación de la resolución de las regiones diurna y nocturna (en comparación con las Figuras 2a y 2b). Esto se debe a la presencia sistemática de datos faltantes que, al visualizarse como celdas en blanco, reducen la intensidad cromática durante las horas diurnas y debilitan el tono negro característico del periodo nocturno. También reproduce el ciclo anual esperado: la franja diurna se estrecha hacia junio–julio y se ensancha hacia octubre–diciembre, con máximos diarios centrados en torno al mediodía. Se observan días con irradiancia elevada en primavera y verano, y valores menores en invierno.




3. Distribución de los valores de GHI minutales medidos en AR en 2023. En blanco se observan los datos faltantes.

iii) PI: Los datos medidos tienen frecuencia de registro de 1 minuto desde el 01/01/2023 a las 00:00 hasta el 31/12/2024 a las 23:59, para GMT -3 (HOA). En esta estación, en 2023, casi el 89% de los datos están OK, de los cuales el 44% corresponden a datos de día. Para 2024, estas proporciones disminuyen a 76% y 38%, respectivamente (ver Tabla 7).

Año	# datos esperados	# datos presentes	# datos OK	# datos faltantes	# datos duplicados	% datos OK	% OK día	% OK noche
2023	525600	466732	466732	58868	0	88.80	43.83	44.97
2024	527040	401133	400716	126324	417	76.03	37.67	38.36

Tabla 7: Discriminación de los valores de frecuencia minutal de GHI de la base de datos medidos para el sitio Pilar (PI)



4a. Distribución de los valores de GHI minutales medidos en PI en 2023. En blanco se observan los datos faltantes.




Figura 4b. Distribución de los valores de GHI minutales medidos en PI en 2024. En blanco se observan los datos faltantes.

Los gráficos de GHI para Pilar, de las Figuras 4a y 4b, reproducen el ciclo anual esperado en la duración del día y la intensidad de la irradiancia, con máximos en verano y mínimos en invierno. Sin embargo, la serie presenta una alta intermitencia: los faltantes (trazos blancos) son frecuentes y se presentan en bloques extensos, particularmente durante enero–marzo en ambos años y nuevamente hacia octubre–noviembre (especialmente en 2023).

2.2.3 Integración horaria de los datos medidos.

Los datos de GHI medidos tienen una frecuencia minutal, por lo que, para compararlos con los valores previstos por el modelo WRF-SMN, estos deben integrarse al formato horario. Para ello, se adopta la convención de asignar a la hora HH:00 el promedio de los valores minutales de HH:00 a HH:59. Por ejemplo, el promedio de los valores minutales de GHI de las 14:00 a las 14:59 se asigna a la `time_stamp` 14:00.

Dado que el proceso de control de calidad identifica y excluye mediciones potencialmente erróneas (por fallas de registro, valores físicamente inconsistentes, artefactos instrumentales o problemas de sincronización temporal), la cantidad de observaciones minutales disponibles por hora puede ser menor que 60. Por ello se adoptó un criterio mínimo de completitud para asegurar la representatividad estadística del promedio horario de GHI. En línea con Salazar *et al.* (2020), se requirieron un mínimo de 3 datos válidos en cada intervalo de 15 minutos. Así, una hora (4 intervalos consecutivos de 15 minutos) se considera válida para el cálculo del promedio horario únicamente si todos los intervalos cumplen dicha condición (al menos 12 observaciones minutales válidas por hora).

3. Descripción de los datos pronosticados por el modelo WRF-SMN.

3.1. Extracción y control de la completitud.

Los datos utilizados provienen del conjunto SMN Hi-Res Weather Forecast over Argentina, disponible en el repositorio de datos abiertos de Amazon Web Services (AWS). Se comprobó que los pronósticos contienen la serie completa, sin valores faltantes: 8760 `time_stamps` por año para cada variable estimada.

Los datos de pronóstico analizados en este reporte corresponden únicamente a 2023 y 2024.

3.2. Formato e información disponible.

La región geográfica abarcada por el modelo comprende toda la República Argentina continental, sin incluir el territorio antártico. La resolución espacial de cada celda es de 4 km.

El modelo ofrece sus pronósticos en archivos de datos en formato NetCDF (Network Common Data Form), adecuado para datos multidimensionales. Estos archivos tienen la etiqueta `WRFDETAR_01H_YYYYMMDD_CO_HDC.nc`, donde YYYYMMDD indica el año (YYYY), mes (MM) y día (DD) de inicio del pronóstico, CO indica la corrida y HDC indica la leadtime, es decir, la hora para la que se realiza el pronóstico. El modelo ofrece 4 corridas inicializadas a las 00:00, 06:00, 12:00 y 18:00 UTC, con pronósticos horarios a 72 horas.

Las variables meteorológicas presentes en los archivos son las siguientes:

- i) precipitación acumulada en 10 min o 1 hora (PP),
- ii) humedad relativa a 2 metros (HR2),
- iii) temperatura ambiente a 2 metros (T2),
- iv) dirección de viento a 10 metros (dirViento10),
- v) magnitud de viento a 10 metros (magViento10),
- vi) presión en superficie (PSFC),
- vii) radiación de onda larga entrante (ACLWDNB),
- viii) radiación de onda larga saliente (ACLWUPB),
- ix) radiación de onda corta entrante (ACSWDNB),
- x) temperatura de suelo en la capa 0-10 cm (TSLB),
- xi) humedad del suelo en la capa 0-10 cm (SMOIS).

Debe destacarse que las variables de radiación (ACLWDNB, ACLWUPB y ACSWDNB) se presentan como valores acumulados, en unidades del sistema SI (J/m^2); es decir, para $t = 0$, la radiación es 0 J/m^2 y, para $t = 72 \text{ h}$, es la suma de todos los valores anteriores.

Debe tenerse en cuenta que cada archivo contiene el pronóstico de una sola corrida y de un solo leadtime para toda la región geográfica. Dado que una corrida completa abarca 72 horas, es crucial construir correctamente la estructura temporal de la variable (o variables) pronosticada para su comparación con los valores medidos.

Para esto, a partir de la información temporal que ofrece cada archivo en su etiqueta, se determinan las siguientes variables temporales:

- **date** indica la fecha de inicio del pronóstico, por ejemplo, 20230514 representa el 14 de mayo de 2023, que se obtiene directamente de la etiqueta *YYYYMMDD*.
- **corrida** indica a qué hora de la **date** comienza la previsión a 72 horas, y puede ser 00, 06, 12 o 18. Se obtiene de CO.
- **leadtime** indica el plazo de pronóstico para esa corrida. Por ejemplo, **leadtime** = 5 indica que es el pronóstico de la quinta hora comenzando desde el 01/01/2023 a las 00:00. **leadtime** se obtiene de HDC.
- **valid_time** es la fecha y hora a las que efectivamente se asigna un pronóstico en la corrida. Por ejemplo, a los valores previstos para date 20230101, corrida 0 y leadtime 5 se les asigna el valid_time 2023-01-01 05:00. Si date es 20230101, corrida 0 y leadtime 29, se les asigna el valid_time 2023-02-01 05:00.

Para convertir ACSWDNB, expresado en J/m^2 (energía por unidad de área), a GHI en W/m^2 (potencia por unidad de área), hay que considerar el incremento temporal del campo acumulado. Para cada leadtime L ($L = 0, 1, \dots, 72$), el valor de GHI se calcula como la diferencia entre dos valores acumulados consecutivos, normalizada por la duración del intervalo temporal (3600 s):

$$\text{GHI}_{\text{pronosticado},L} = (\text{ACSWDNB}_L - \text{ACSWDNB}_{L-1}) / 3600 \quad (4)$$

De este modo, cada pronóstico queda asociado a un valid_time específico, lo que permite emparejarlo directamente con la medición correspondiente en ese instante.

4. Evaluación del modelo WRF-SMN de la radiación global frente a los datos medidos.

Los valores pronosticados se obtuvieron utilizando el criterio de “vecinos más próximos” a partir de la latitud y la longitud de cada uno de los tres sitios. La celda más cercana a la latitud y la longitud del sitio a analizar se determina como la celda con la menor distancia euclídea a su centro.

4.1. Métricas a utilizar para evaluar el desempeño del modelo.

Las métricas a usar son el Error Medio de Bías (Mean Bias Error, MBE, siglas en inglés) y la Raíz del Error Cuadrático Medio (Root Mean Square Error, RMSE, siglas en inglés). También se expresaron los errores como porcentajes (rMBE y rRMSE), dividiéndolos entre la media de los valores medidos.

$$\text{MBE} = \frac{1}{N} \sum_{i=1}^N (y_{i,\text{modelado}} - y_{i,\text{medido}}) \quad (5)$$

$$rMBE = \frac{MBE}{\bar{y}_{medido}} \cdot 100 \quad (6)$$

Un valor de rMBE igual a cero indica la ausencia de sesgo entre los valores pronosticados y los medidos. Valores positivos de rMBE indican sobreestimación con respecto a las observaciones, mientras que valores negativos indican subestimación. Esta métrica cuantifica el sesgo sistemático del conjunto de pronósticos.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{i,modelado} - y_{i,medido})^2} \quad (7)$$

$$rRMSE = \frac{RMSE}{\bar{y}_{medido}} \cdot 100 \quad (8)$$

El rRMSE indica el porcentaje de dispersión del error entre los datos medidos y los predichos. El rRMSE penaliza errores grandes.

4.2. Evaluación del desempeño del pronóstico de GHI.

La comparación se realiza en función del *valid_time*, por lo que un mismo valor medido puede asociarse a múltiples pronósticos provenientes de distintas corridas del modelo. La Tabla 8 muestra un ejemplo para BA, donde un mismo GHI_{medido} se corresponde con varios GHI_{pron} generados desde las corridas 0, 6, 12 y 18 UTC, y un mismo *valid_time* puede repetirse hasta 12 veces. Por ejemplo, el GHI_{medido} correspondiente al 01/01/2023 23:00 se asocia a dos pronósticos, uno de la corrida 0 UTC y otro de la 12 UTC.

valid_time	GHI medido	GHI pron. 1-0	GHI pron. 1-12	GHI pron. 2-0
01/01/2023 00:00		0		
01/01/2023 01:00		0		
01/01/2023 02:00		0		
01/01/2023 03:00		0		
01/01/2023 04:00		0		
01/01/2023 05:00		0		
01/01/2023 06:00		0		
01/01/2023 07:00		0		
01/01/2023 08:00		0		
01/01/2023 09:00	7	1		
01/01/2023 10:00	39	98		
01/01/2023 11:00	115	316		
01/01/2023 12:00	171	485		
01/01/2023 13:00	224	709	618	
01/01/2023 14:00	309	813	518	
01/01/2023 15:00	310	769	636	
01/01/2023 16:00	165	941	638	
01/01/2023 17:00	101	1038	754	
01/01/2023 18:00	79	795	437	
01/01/2023 19:00	89	296	311	
01/01/2023 20:00	66	187	179	
01/01/2023 21:00	32	144	110	
01/01/2023 22:00	13	71	91	
01/01/2023 23:00	7	14	15	
02/01/2023 00:00	3	0	0	0
02/01/2023 01:00		0	0	0
02/01/2023 02:00		0	0	0
02/01/2023 03:00		0	0	0
02/01/2023 04:00		0	0	0
02/01/2023 05:00		0	0	0
02/01/2023 06:00		0	0	0
02/01/2023 07:00		0	0	0
02/01/2023 08:00		0	0	0
02/01/2023 09:00	2	0	1	1
02/01/2023 10:00	20	41	57	70
02/01/2023 11:00	90	141	266	223
02/01/2023 12:00	383	350	563	566
02/01/2023 13:00	723	707	774	780

Tabla 8. Distribución de valores medidos y pronosticados de GHI por corrida, según valid_time, para BA (enero 2023).

La evaluación del pronóstico de GHI hasta 72 horas del sistema WRF-SMN requiere considerar la fuerte dependencia estacional de esta variable. La Figura 5 muestra el GHI de cielo claro para días próximos a los solsticios de invierno y verano en BA, evidenciando dos diferencias principales: los niveles máximos de irradiancia son menores en invierno debido al mayor ángulo cenital solar, y la duración del día es más corta, lo que reduce la ventana temporal en la que la irradiancia es distinta de cero. En verano ocurre lo contrario: mayor altura solar, valores máximos más altos y días más extensos.

La GHI es nula durante la noche y, durante el día, depende de la geometría solar, que determina valores angulares como SZA, el ángulo diario y el ángulo horario, los cuales se calculan a partir de la posición geográfica del sitio, el día del año y la hora del día. Además, la GHI depende de la variabilidad nubosa, que introduce cambios abruptos a escala horaria. La variación estacional en la duración del día y en la distribución de las horas de irradiación, con irradiancia significativa, modifica el conjunto de datos evaluado y puede sesgar las métricas si no se controla adecuadamente, cuando se hace por leadtime.





Figura 5. Comparación del GHI horario de cielo claro para BA en junio y diciembre.

La verificación del modelo WRF-SMN se realiza considerando todos los valores diurnos.

Con el objetivo de evaluar la evolución del error entre los valores pronosticados y los medidos, se calculan los estadísticos presentados en la sección 4.1 de forma independiente para cada leadtime y cada corrida. En la Tabla 9 se muestran las métricas de MBE y RMSE, así como sus versiones porcentuales, y se comparan, por corrida, los valores de pronóstico con los valores medidos en BA correspondientes a 2023 y 2024. La corrida 00 UTC presenta el menor error de sesgo (rMBE = 23.75%) y la corrida 06 UTC el mayor (24.74%). Para el rRMSE la corrida 12 UTC es la que menor error presenta (45.61 %) mientras que la corrida 06 UTC es la que muestra error mayor (47.10 %).

Corrida (UTC)	MBE (W/m²)	RMSE (W/m²)	rMBE (%)	rRMSE (%)
00	84.32	164.25	23.75	46.26
06	86.09	163.91	24.74	47.10
12	87.24	162.02	24.56	45.61
18	85.18	162.83	24.61	47.04

Tabla 9. Métricas de desempeño de los valores pronosticados de GHI frente a los valores medidos para BA.



Figura

6. Evolución de la métrica rRMSE para BA en 2023, para cada leadtime.

En la Figura 6 se observa la evolución del rRMSE del pronóstico horario de GHI para Buenos Aires durante 2023, en función del horizonte de predicción y separada por las corridas (00 UTC, 06 UTC, 12 UTC y 18 UTC). Los valores de error superiores al 160% están asociados a momentos de amanecer en los que el sombreado del sitio afecta las mediciones. Los valores de error más altos también están asociados al atardecer, superando el 80%. El error fuera de estos momentos se ubica entre 30% y 45% en cada corrida. En esa región, dentro del rango del 30% al 45%, se identifica una zona de “estabilidad” diurna, es decir, donde el error rRMSE muestra un comportamiento estable en cada corrida, con pequeñas diferencias entre valores consecutivos de leadtime, lo que indica una evolución temporal continua y sin saltos bruscos. Por último, se observa un leve grado de degradación del pronóstico a medida que se aleja de $L = 1$.

Corrida (UTC)	MBE (W/m ²)	RMSE (W/m ²)	rMBE (%)	rRMSE (%)
00	74.15	162.20	18.94	41.43
06	79.57	166.37	20.73	43.35
12	78.14	163.97	19.99	41.96
18	78.77	166.43	20.67	43.68

Tabla 10. Métricas de desempeño de los valores pronosticados de GHI frente a los valores medidos en PI.

En la Tabla 10 se muestran las métricas para los datos pronosticados de PI comparados contra los medidos, durante 2023 y 2024. Los valores son menores en todos los casos comparándolos con los de BA. El sesgo porcentual presenta su menor valor para la corrida 00 UTC (18.94 %), mientras que la corrida 06 UTC presenta el valor más alto (20.73 %). Para el rRMSE la corrida 00 UTC es la que presenta el mínimo rRMSE (41.43%) y la corrida 18 UTC es la que presenta el error mayor rRMSE (43.68%).




Figura 7. Evolución de la métrica rRMSE para PI en 2023.

En el caso de PI, la Figura 7 muestra un comportamiento similar al de BA en rRMSE, pero sin errores superiores al 90% en los momentos de amanecer y atardecer. El error en la región de estabilidad se encuentra entre el 30% y el 40%, para todas las corridas. También se aprecia la degradación del pronóstico a medida que se aleja de $L = 1$.

En la Tabla 11 se muestran las métricas de comparación entre los pronósticos del modelo y los medidos en AR durante 2023. El sesgo nuevamente es menor para la corrida 00 UTC (23.12 %) y la corrida 18 UTC presenta el valor máximo (24.90 %). El mayor error rRMSE (49.58 %) ocurre para la corrida 18 UTC y el menor error (47.74 %) ocurre para la corrida 00 UTC.

Corrida (UTC)	MBE (W/m ²)	RMSE (W/m ²)	rMBE (%)	rRMSE (%)
00	81.93	169.18	23.12	47.74
06	89.08	177.86	24.07	48.07
12	85.64	170.52	24.21	48.20
18	91.53	182.23	24.90	49.58

Tabla 11. Métricas de desempeño de los valores pronosticados de GHI frente a los valores medidos en AR.




Figura 8. Evolución de la métrica rRMSE para AR en 2023.

Para AR (Figura 8) se aprecia un error significativo asociado a los momentos de atardecer, especialmente para $L = 58$ de la corrida de 12 UTC. Estos errores se deben a problemas en los datos medidos que pasaron los filtros de calidad, pero presentan valores inferiores a los esperados y generan el salto en el error que se aprecia en la Figura 8. El error en la región de estabilidad diurna se sitúa entre 35% y 45%. Al igual que en los demás sitios, se observa un aumento del error del pronóstico a medida que el horizonte se aleja del inicio.

Por último, debe tenerse en cuenta que, para todos los sitios, aunque el *valid_time* sea el mismo, cada corrida alcanza ese instante tras un número distinto de horas de pronóstico. En consecuencia, los errores difieren: los pronósticos de corto plazo (por ejemplo, 24 hs o 36 hs) presentan una menor diferencia respecto de los medidos, mientras que los de mayor plazo (por ejemplo, 48 hs o 72 hs) acumulan una mayor incertidumbre, especialmente en presencia de nubosidad. Este comportamiento se observa en todos los sitios analizados.

4.3 Análisis de condiciones de cielo pronosticadas y medidas.

Se realizó un análisis, utilizando todas las corridas, para establecer la correspondencia entre la condición del cielo pronosticada y la medida, clasificándola en 2 categorías: claro (despejado) y nublado (no despejado). Esa clasificación se basa en el valor del índice de claridad k_c , definido como $GHI_i/GHI_{CC,i}$, donde GHI es la irradiancia medida o estimada y GHI_{CC} es la irradiancia para cielo claro estimada. La condición de cielo se clarificará como claro para $k_c \geq 0.9$ y no claro para $k_c < 0.9$ (Salazar *et al*, 2019).




Figura 9. Fracciones de recall, claras y nubladas, para los tres sitios en 2023.

La Figura 9 muestra la fracción de aciertos de cada sitio usando solo los datos de 2023. Para el sitio AR la estadística se muestra desde junio, ya que antes de ese mes la cantidad de datos medidos no es representativa. El término recall se refiere a la fracción de aciertos del modelo respecto del estado real del cielo medido. Por ejemplo, BA_recall_claro indica la fracción de los estados de cielo claro reales que el modelo detectó como claros; de manera análoga, se calcula BA_recall_nublado para los cielos no despejados. Se observa que el modelo tiene mayor capacidad para detectar momentos de cielo claro (fracción de acierto > 0.80) que para detectar momentos de cielo nublado (entre 0.6 y 0.2).

Para ampliar el análisis de los momentos de cielo no despejados, se aumentó el número de categorías de clasificación: ahora se clasifica como cielo nublado a los $k_c < 0.3$, cielo parcialmente nublado a los momentos con $0.3 < k_c < 0.9$ y cielo claro a los $k_c > 0.9$, mostrándose los resultados en la Figura 10. Se observa que el modelo presenta dificultades para pronosticar momentos de cielo cubierto, con un bajo porcentaje de aciertos en la franja de 0.3 a 0. Los aciertos mejoran para los momentos de cielo parcialmente nublado, pero sin superar el 0.5 de fracción de aciertos.




Figura 10. Fracción de recall claro, parcial (nublado) y nublado en los tres sitios en 2023.

En resumen, el modelo acierta alrededor del 90% cuando predice momentos de cielo claro o despejado, pero ese porcentaje disminuye a menos del 50% para momentos parcialmente nublados y aún más cuando se trata de pronosticar momentos nublados (menos del 30%).

5. Proceso de mejora de los pronósticos del modelo WRF-SMN.

Establecido el error que presenta el pronóstico del modelo respecto de los datos medidos en la región pampeana, se procede a diseñar un proceso que permita reducir dicho error mediante herramientas de aprendizaje automático, como los perceptrones multicapa (MLP, por sus siglas en inglés).

5.1 Conformación del conjunto de datos

En una primera etapa, se integraron dos fuentes de información. Por un lado, se incorporaron los datos horarios de GHI medida y el correspondiente ángulo cenital solar (SZA) para cada hora. Por otro lado, se consideraron los valores horarios de las 11 variables meteorológicas provistas por el sistema WRF-SMN:

- precipitación acumulada en 10 min o 1 hora (PP),
- humedad relativa a 2 metros (HR2),
- temperatura ambiente a 2 metros (T2),
- dirección de viento a 10 metros (dirViento10),
- magnitud de viento a 10 metros (magViento10),
- presión en superficie (PSFC),
- radiación de onda larga entrante (ACLWDNB),
- radiación de onda larga saliente (ACWUPB),
- radiación de onda corta entrante (ACSWDNB),
- temperatura de suelo en la capa 0-10 cm (TSLB),
- humedad del suelo en la capa 0-10 cm (SMOIS).

Se las empareja con las observaciones mediante `valid_time` para los datos pronosticados y el correspondiente para los datos medidos.

5.2 Selección del MLP

Como siguiente paso, se eligió un Multilayer Perceptron (MLP) (Figura 11) implementado con `scikit-learn` que es una librería científica en Python (<http://scikit-learn.org/>).




Figura 11. Esquema de una MLP general, donde se observan 3 capas ocultas, así como una de entrada y otra de salida (Wikipedia).

El modelo MLP utilizado para el procesamiento de los datos del WRF-SMN consiste en una red neuronal feed-forward con dos capas ocultas de 5 y 10 neuronas, respectivamente. Se emplea la función de activación ReLU, que introduce no linealidad y favorece una convergencia estable durante el entrenamiento. La optimización se realiza con Adam, con una tasa de aprendizaje inicial de 0.001, lo que permite actualizar los pesos de manera eficiente a lo largo de las iteraciones. Se fija un máximo de 500 iteraciones e incorpora, además, la detención anticipada: este mecanismo monitorea el desempeño en un subconjunto de validación y detiene el entrenamiento cuando no se registran mejoras adicionales, lo que reduce el riesgo de sobreajuste. En conjunto, esta configuración define la capacidad de representación del modelo y asegura un proceso de optimización robusto y controlado. Además, presenta un bajo costo computacional, lo que lo hace adecuado para la experimentación y la calibración.

Este procedimiento fue publicado por Salazar *et al.* (2025) y muestra que no es necesario diseñar redes complejas para obtener resultados acertados.

Es relevante señalar que el MLP opera bajo un enfoque no secuencial: el modelo no explota dependencias temporales ni define relaciones del tipo t , $t+1$, $t+2$, etc. Cada conjunto de valores modelados (los regresores) y de la variable objetivo, obtenidos para un tiempo dado t , se considera una instancia independiente en el espacio de entrada. En consecuencia, la red estima una función de mapeo estática que captura regularidades en la distribución conjunta de las variables, sin incorporar estructura temporal.

5.3 División de datos para entrenamiento, validación y prueba

Los sets de entrenamiento (train) y validación (val) están directamente relacionados con el proceso de aprendizaje del MLP, siendo el set val el que indica cuándo el mismo debe detenerse. Pero determinar la mejor MLP solo usando las métricas del set de entrenamiento conduciría a un sobreajuste (overfitting), ya que la MLP se ha especializado en esos datos (se ha entrenado con ellos y los “conoce”). Es por eso que se aplica la MLP encontrada con el train y val, a un set que el MLP no ha “visto”: el set de prueba (test). De esa manera se evita el sobreajuste y la métrica resulta más representativa de la realidad.

El conjunto de datos horarios aleatorios extraídos en cada sitio se dividió en:

- i) 40% entrenamiento (train),
- ii) 10% validación (val),
- iii) 50% prueba (test).

En el caso de PI y BA, esta división se realizó con base en los datos horarios de 2023 y 2024. Para AR, se hizo con los datos disponibles de 2023. La configuración (40-10-50) puede ajustarse a otros valores, según las necesidades.

Se aclara que no se utilizó una partición menor para el conjunto de test porque, al disponer AR de una serie de datos de apenas ~ 7 meses, reducir el tamaño del test puede sesgar la evaluación: la métrica se vuelve menos representativa y tiende a aumentar el error. Para mantener la comparabilidad del análisis entre los tres sitios, en este caso se optó por emplear un test del 50%.

5.4 Escalado de variables

Antes de entrenar el modelo MLP, todas las variables predictoras se estandarizaron para favorecer la convergencia del algoritmo de optimización y evitar que los predictores de mayor magnitud numérica dominaran el proceso de ajuste. En particular, cada predictor x se transformó como

$$x' = \frac{x - \mu_x}{\sigma_x} \quad (9)$$

donde μ_x y σ_x son la media y el desvío estándar calculados exclusivamente con el conjunto de entrenamiento; luego, los mismos parámetros se aplicaron al conjunto de validación (y test, si corresponde), garantizando consistencia y evitando fuga de información.

5.5. Entrenamiento y seguimiento del aprendizaje

El entrenamiento del MLP se realizó minimizando una función de pérdida que cuantifica el error entre los valores observados y los estimados por la red. Para un conjunto de N muestras, con y_i la irradiancia observada e $\hat{y}_i$ la predicción del modelo, se utilizó la pérdida cuadrática media:

$$\mathcal{L}(\theta) = \frac{1}{N} \sum_{i=0}^N (y_i - \hat{y}_i)^2 \quad (10)$$

donde θ representa el conjunto de pesos y sesgos del modelo. Esta función penaliza con mayor intensidad los errores grandes y resulta adecuada para problemas de regresión continua, como la estimación de GHI. Durante el proceso de entrenamiento se monitoreó, en cada época, la pérdida de entrenamiento $\mathcal{L}_{train}$ y la pérdida de validación $\mathcal{L}_{val}$. Este seguimiento permite verificar la estabilidad del aprendizaje, identificar posibles signos de sobreajuste (por ejemplo, disminución sostenida de $\mathcal{L}_{train}$ junto con aumento de $\mathcal{L}_{val}$) y seleccionar la configuración del modelo con mejor capacidad de generalización.

5.6. Criterio de selección del mejor MLP

El MLP final se selecciona mediante la combinación de las métricas rRMSE y rMBE. Se busca así minimizar la dispersión del error, reduciendo el rRMSE, y minimizar el sesgo, reduciendo el rMBE.

5.7. Análisis de correlación y elección de regresores.

Se propone analizar la correlación y la contribución de cada variable pronosticada por el modelo, con el fin de seleccionar cuáles se utilizarán como predictores (regresores) en el proceso de aprendizaje. Este análisis permite reducir la complejidad del modelo, reteniendo únicamente las variables que aportan información relevante y contribuyen a disminuir el error entre los valores medidos y los pronosticados.

A modo de ejemplo, en la Figura 12 se muestra la correlación lineal de Pearson entre las variables presentes en el WRF-SMN para BA y los valores de GHI medidos durante el periodo 2023-2024. Se observa que los valores de la GHI modelados (GHI_Wm2) por WRF-SMN presentan una correlación superior al 80% con los datos medidos, al considerar todas las corridas. Valores elevados y positivos del coeficiente de correlación indican que ambas variables comparten una variabilidad temporal similar, mientras que valores cercanos a cero o negativos reflejan una relación débil o inversa, respectivamente.




Figura 12. Correlación entre las variables predichas por el modelo WRF-SMN y los valores de GHI medidos en BA.

El objetivo del reporte no es abordar la temática del feature analysis (Guyon y Elisseeff, 2003) que implica analizar la contribución de cada variable de la Figura 12 en el resultado final de la adaptación al sitio de GHI_Wm2. Sin embargo, analizaremos casos particulares que dan una idea clara de lo que se quiere explicar respecto de la elección de los regresores y de los resultados obtenidos.

5.8. Evaluación de MLPs con diferentes regresores.

Se probaron 3 tipos diferentes de MLP, usando la división de datos mostrada en la sección 5.3:

MLP1: la variable objetivo es GHI_{medido} y el regresor es GHI_Wm2.

MLP2: la variable objetivo es GHI_{medido} y los regresores son T2, TSLB y GHI_Wm2.

MLP3: la variable objetivo es GHI_{medido} y los regresores son T2, TSLB, y GHI_Wm2, pero analizados por corridas (00, 06, 12, 18 UTC).

En la Tabla 12 se presentan, a modo de ejemplo, las métricas del proceso de adaptación usando la MLP1 sobre los datos de BA, mostrando los resultados de train, val y test. El método *Original* consiste en comparar los pronósticos originales del WRF-SMN con los valores medidos. MLP1 se refiere a la comparación de los pronósticos ya adaptados por el MLP1 con los valores medidos.

set	Método	MBE (W/m^2)	RMSE (W/m^2)	rMBE (%)	rRMSE (%)
train	<i>Original</i>	93.57	169.89	24.93	45.27
train	MLP1	3.32	136.41	0.88	36.17
val	<i>Original</i>	91.6	169.02	24.23	44.7
val	MLP1	1.78	133.38	0.46	35.09
test	<i>Original</i>	92.35	169.52	24.15	44.33
test	MLP1	2.99	136.81	0.78	35.95

Tabla 12. Métricas de desempeño de los valores pronosticados (Original) y de los adaptados (MLP1) vs los valores medidos, para BA.

La Tabla 12 compara el desempeño del producto Original frente al modelo MLP1 en train, val y test. En los tres conjuntos, el Original presenta un alto sesgo positivo y muy estable ($MBE \sim 92 - 94 W/m^2$; $rMBE \sim 24\%$), lo que indica una sobreestimación sistemática. Al aplicar MLP1, ese sesgo se reduce drásticamente ($MBE \sim 1.8 - 3.3 W/m^2$; $rMBE < 1\%$), es decir, una disminución del orden de $\sim 96\% - 98\%$. Además, MLP1 mejora la dispersión del error: el RMSE baja de $\sim 169 W/m^2$ a $\sim 133-137 W/m^2$ (reducción de $\sim 19-21\%$) y el rRMSE cae de $\sim 44-45\%$ a $\sim 35-36\%$. La mejora es consistente en train/val/test, lo que sugiere una buena capacidad de generalización y la ausencia de un sobreajuste marcado; aun así, persiste un RMSE residual ($\sim 135 W/m^2$) asociado a la variabilidad no explicada por el modelo.

En las Tablas 13, 14 y 15 solo se muestran los resultados del set test de cada sitio.

set	Método	MBE (W/m^2)	RMSE (W/m^2)	rMBE (%)	rRMSE (%)
test	<i>Original</i>	92.35	169.52	24.15	44.33
test	MLP1	2.99	136.81	0.78	35.95
test	MLP2	5.44	134.76	1.43	35.41
test	<i>Original_corr 0</i>	90.31	168.69	23.50	43.90
test	MLP3_corr 0	-1.60	135.94	-0.42	35.38
test	<i>Original_corr 6</i>	93.22	171.76	24.84	45.77
test	MLP3_corr 6	1.11	136.02	0.30	36.25
test	<i>Original_corr 12</i>	94.06	169.39	24.52	44.16
test	MLP3_corr 12	-2.41	134.80	-0.63	35.15
test	<i>Original_corr 18</i>	92.00	169.10	24.68	45.36
test	MLP3_corr 18	-1.35	134.97	-0.36	36.21

Tabla 13. Métricas de desempeño de los valores pronosticados (Original) y de los adaptados (MLP1, MLP2 y MLP3) frente a los valores medidos, para BA.

En BA (Tabla 13), todos los MLP mejoran las métricas de pronóstico del WRF-SMN respecto al pronóstico Original. En el caso del MLP1 y MLP2, el rMBE mejora el sesgo original pasando de $\sim 24\%$ a $\sim 1\%$, y el rRMSE presenta una mejora de $\sim 10\%$. Finalmente, en el MLP3 las corridas muestran rMBE cercanos a 0% y un rRMSE comparable al de MLP1 y MLP2. El MLP2 es mejor que el MLP1. MLP3 es mejor que MLP2 en ciertas corridas (00 y 12 UTC).

set	Método	MBE (W/m ²)	RMSE (W/m ²)	rMBE (%)	rRMSE (%)
test	Original	83.76	170.00	20.10	40.79
test	MLP1	-2.78	142.29	-0.66	34.20
test	MLP2	-4.67	138.63	-1.12	33.32
test	Original_corr 0	81.76	172.48	19.32	40.77
test	MLP3_corr 0	-2.16	141.55	-0.51	33.46
test	Original_corr 6	86.41	172.00	21.08	41.95
test	MLP3_corr 6	-8.71	138.33	-2.05	32.67
test	Original_corr 12	85.49	171.24	20.19	40.45
test	MLP3_corr 12	9.83	138.33	-2.05	32.67
test	Original_corr 18	86.48	172.12	20.96	41.73
test	MLP3_corr 18	9.83	138.90	2.38	33.67

Tabla 14. Métricas de desempeño de los valores pronosticados (modelo) y de los adaptados (MLP1, MLP2 y MLP3) vs los valores medidos, para PI.

En PI (Tabla 14), todos los modelos MLP mejoran las métricas del pronóstico original del WRF-SMN. Para el MLP1, el rMBE reduce el sesgo de ~20% a ~ -0.5% y el rRMSE mejora ~7%. Para el MLP2, el rMBE pasa de ~20% a ~-1% y el rRMSE mejora aproximadamente 7.5 %. Finalmente, en el MLP3 las corridas muestran rMBE oscilante entre -2% y 2% y un rRMSE comparable al de MLP1 y MLP2. Nuevamente, el MLP2 es mejor que el MLP1. MLP3 es mejor que MLP2 en ciertas corridas (06 y 12 UTC).

set	Método	MBE (W/m ²)	RMSE (W/m ²)	rMBE (%)	rRMSE (%)
test	Original	89.81	178.8	24	47.78
test	MLP1	-6.06	147	-1.62	39.46
test	MLP2	-6.83	144.76	-1.83	38.86
test	Original_corr 0	83.05	170.04	22.65	46.38
test	MLP3_corr 0	-7.06	141.25	-1.92	38.53
test	Original_corr 6	91.7	180.15	23.98	47.12
test	MLP3_corr 6	1.56	148.03	0.41	38.72
test	Original_corr 12	89.57	172.99	24.25	46.84
test	MLP3_corr 12	-3.33	139.83	-0.9	37.86
test	Original_corr 18	93.79	185.8	24.41	48.35
test	MLP3_corr 18	-4.77	152.5	-1.24	39.69

Tabla 15. Métricas de desempeño de los valores pronosticados (modelo) y de los adaptados (MLP1, MLP2 y MLP3) vs los valores medidos, para AR.

En AR (Tabla 15), todos los modelos MLP mejoran las métricas del pronóstico original del WRF-SMN. Para el MLP1, el rMBE reduce el sesgo de 24% a -1.6% y el rRMSE presenta una mejora de 8%. Para el MLP2 y MLP3 los valores son similares a los de MLP1, sin que se destaque significativamente ninguna corrida por sobre las demás. En este sitio, MLP2 es mejor que MLP1. MLP3 es mejor que MLP2 en ciertas corridas (00, 06 y 12 UTC).

5.9 Evaluación de validación cruzada entre sitios (cross-validation)

Se ofrecerá una herramienta para comparar modelos entrenados con datos de un sitio y, posteriormente, analizarlos introduciendo datos de test de otros. De esa manera se puede evaluar la generalización espacial del modelo. Esto permitirá cuantificar la pérdida de desempeño y evaluar si el modelo es transferible o específico de cada sitio.

En este caso, la Figura 13 muestra el rRMSE entre modelos MLP entrenados y validados en cada sitio y luego aplicado usando los sets de test en los otros sitios. Por ejemplo, si aplicamos el MLP_PI (el modelo entrenado y validado con los datos de PI) a los datos de testeo de PI, el rRMSE es del 32%; y si aplicamos el mismo modelo a los datos de validación de BA, el rRMSE es del 38%.




Figura 13. Matriz de rRMSE de la validación cruzada de MLP para los tres sitios analizados.

Estas métricas corresponden a un train, val y test de **40-10-50** y usan solo 3 regresores: GHI_Wm2, T2 y TSLB. Dado que AR solo tiene 7 meses de datos significativos (junio – diciembre), los RMSE asociados a ese sitio deben interpretarse como el desempeño del modelo en un período específico del año, no como una caracterización anual completa comparable con BA y PI (que tienen ~2 años). En términos simples: en AR, el modelo está siendo entrenado y evaluado con una muestra más corta y estacionalmente incompleta, por lo que el error puede estar más influido por las condiciones predominantes en esos meses (por ejemplo, episodios de nubosidad o variabilidad más marcada) y por una menor diversidad de situaciones que el modelo llega a prever.

La validación cruzada entre sitios indica que el RMSE está dominado principalmente por el sitio de validación y, en menor medida, por el sitio de entrenamiento: dentro de cada columna (AR, PI, BA) los valores varían poco entre modelos entrenados en distintos sitios, lo que sugiere una transferencia entre sitios estable y buena capacidad de generalización. En cambio, las diferencias sistemáticas entre columnas reflejan que la “dificultad” del problema depende de las condiciones propias del sitio evaluado (p. ej., régimen de nubosidad, variabilidad local y representatividad de los predictores), destacándose PI con los RMSE más bajos, mientras que AR y BA presentan errores mayores.

5.10. Resultado de la corrección de los errores del modelo WRF-SMN

Una vez procesados los pronósticos del modelo WRF-SMN, se dispone de 72 valores horarios de GHI por cada corrida. Como se indicó previamente, se aplicará la técnica de adaptación al sitio, cuya finalidad es emplear una MLP para corregir (reducir el error) de esos 72 pronósticos utilizando como referencia la GHI medida en tres sitios. En este esquema, la red se entrena vinculando cada valor de GHI pronosticado para un determinado valid_time — independientemente de la corrida — con su valor medido correspondiente, de modo de aprender una corrección sistemática aplicable a los pronósticos.

A continuación, se mostrarán los gráficos de evolución del error rRMSE de los valores pronosticados en cada sitio, comparados con los medidos, así como los corregidos mediante el MLP3 entrenado con los datos de cada sitio. También se realiza una validación cruzada, incorporando los resultados obtenidos al entrenar los MLP en los sitios restantes.

Las curvas gruesas de la Figura 14 muestran que, en BA, el rRMSE depende fuertemente del leadtime y exhibe máximos recurrentes ligados al ciclo diurno (en particular cerca de amanecer/atardecer), con diferencias entre las corridas, tal como se mostró originalmente en la Figura 6. En comparación, las curvas finas (MLP entrenado y validado en BA/AR/PI aplicado a los datos de BA) tienden a reducir y suavizar esos picos y a disminuir el error a lo largo del horizonte, lo que evidencia una adaptación efectiva y una transferencia entre sitios razonablemente robusta. Para BA, el menor rRMSE se obtiene con el MLP entrenado con datos de BA y testeado con datos de BA.




Figura 14. Evolución del error rRMSE para cada leadtime L para BA 2023. Se han agregado las curvas de rRMSE obtenidas con los modelos entrenados en otros sitios, aplicados a los datos de BA.

En la Figura 15 se observa el análisis para PI, y se advierte un comportamiento similar al de BA, aunque con errores menores para el amanecer/atardecer. Aquí también se aprecia una transferencia robusta entre sitios. Aquí el menor rRMSE se obtiene con el MLP entrenado con datos de PI y testeado con datos de PI.




Figura 15. Evolución del error acumulado hasta leadtime L para PI 2023. Se han agregado las curvas de rRMSE obtenidas con los modelos entrenados en otros sitios, aplicados a los datos de PI.




Figura 16. Evolución del error acumulado hasta leadtime L para AR 2023. Se han agregado las curvas de rRMSE obtenidas con los modelos entrenados en otros sitios, aplicadas a los datos de AR.

En la Figura 16 se observan los datos para AR, y el comportamiento es el mismo que en los sitios anteriores. Nuevamente, el menor rRMSE se obtiene con el MLP entrenado y validado con datos de AR y testeado con datos de AR.

En todos los sitios se observa que la corrección mediante MLP reduce el error respecto del pronóstico original al compararlo con las mediciones. En términos generales, el menor rRMSE se obtiene cuando el modelo se entrena y se valida en el mismo sitio, lo que confirma la ventaja del ajuste local. Sin embargo, el hecho de que los modelos entrenados en otros sitios logren desempeños del mismo orden sugiere que existe una estructura de comportamiento común entre los sitios, lo que permite una transferencia entre ellos razonablemente estable.

5.11. Síntesis final de la aplicación de MLP

La combinación de validación cruzada entre sitios (entrenamiento en un sitio y evaluación en otro) y análisis de correlación proporciona una base robusta para cuantificar las mejoras obtenidas y avanzar hacia una calibración regional de pronósticos solares, mediante IA aplicada a la adaptación al sitio.

6. Resumen de los resultados:

- Los tres sitios analizados (BA, PI y AR) presentan estadísticas climáticas similares entre sí, dado que se ubican en la Región Pampeana y comparten un marco regional común. Las diferencias observadas se explican principalmente por modulaciones locales.
- El análisis del error por leadtime y por corrida muestra que los errores se disparan en el amanecer/atardecer con picos de hasta más de 130% (BA). Esto se debe a que en esos momentos los valores de GHI son bajos, lo que provoca un aumento del rRMSE. Esto sucede en todos los sitios.
- El análisis del error por leadtime y por corrida también muestra que el centro del bloque diurno (alrededor del mediodía) presenta errores entre 30% y 40%. Ese es el error estadístico del modelo como pronosticador en la región central diurna.
- La evolución del error de los pronósticos a 72 horas (degradación) muestra, en corridas, una ligera tendencia a incrementarse ($\sim 5\%$) a medida que el pronóstico se aleja del leadtime $L = 1$.
- El análisis del grado de acierto del modelo respecto del estado nuboso (despejado, parcialmente despejado y cubierto), utilizando como indicador el índice de claridad (k_c) muestra que acierta un 90% en pronosticar cielo claro, pero esa eficiencia disminuye significativamente para cielo parcialmente nublado (40%) o de cielo cubierto (10%).
- En todos los sitios, la corrección mediante MLP reduce el error frente al pronóstico original; el menor rRMSE se obtiene cuando el modelo se entrena y valida localmente, y el mejor desempeño global corresponde a MLP3.

- Debe destacarse que la validación cruzada entre sitios indica que el rRMSE está determinado principalmente por el sitio de evaluación y, en menor medida, por el de entrenamiento. En conjunto, los resultados evidencian una transferencia estable y una buena capacidad de generalización de los MLP.

Referencias:

SMN Hi-Res Weather Forecast over Argentina. Accedido el 12/10/2025 desde <https://registry.opendata.aws/smn-ar-wrf-dataset>

Amazon Web Services. (2025). SMN Hi-Res Weather Forecast over Argentina [Dataset]. Recuperado el 12 de noviembre de 2025 de <https://registry.opendata.aws/smn-ar-wrf-dataset>

Skamarock, W., et al (2020). A Description of the Advanced Research WRF Version 4. University Corporation for Atmospheric Research. https://www2.mmm.ucar.edu/wrf/users/docs/technote/v4_technote.pdf

Dillon, M. E., C. Matsudo, Y. García Skabar, M. Sacco, 2020: Implementación del sistema de pronóstico numérico en el HPC: Configuración de los pronósticos determinísticos. Nota Técnica SMN 2020-78.

Baseline Surface Radiation Network (BSRN). (s.f.). Quality checks. <https://bsrn.awi.de/data/quality-checks/>

Fernández-Peruchena, C. M., Polo, J., Martín, L., & Mazorra, L. (2020). Site-adaptation of modeled solar radiation data: The SiteAdapt procedure. *Remote Sensing*, 12(13), 2127. <https://doi.org/10.3390/rs12132127>

Nollas, F. M., Salazar, G. A., & Gueymard, C. A. (2023). Quality control procedure for 1-minute pyranometric measurements of global and shadowband-based diffuse solar irradiance. *Renewable Energy*, 202, 40–55. <https://doi.org/10.1016/j.renene.2022.11.056>

Polo, J., Fernández-Peruchena, C., Salamalikis, V., Mazorra-Aguilar, L., Turpin, M., Martín-Pomares, L., Kazantzidis, A., Blanc, P., & Remund, J. (2020). Benchmarking on improvement and site-adaptation techniques for modeled solar radiation datasets. *Solar Energy*, 201, 469–479. <https://doi.org/10.1016/j.solener.2020.03.040>

Salazar, G., Gueymard, C., Galdino, J. B., de Castro Vilela, O., & Fraidenraich, N. (2020). Solar irradiance time series derived from high-quality measurements, satellite-based models, and reanalyses at a near-equatorial site in Brazil. *Renewable and Sustainable Energy Reviews*, 117, 109478. <https://doi.org/10.1016/j.rser.2019.109478>

Servicio Meteorológico Nacional. (2023). Estadísticas climatológicas normales: República Argentina — Período 1991–2020 (847 pp.).

<http://scikit-learn.org/>

Google Earth (2025)

Salazar G, Gueymard C, Ledesma R, Castro Vilela O (2025). Site Adaptation for Global Horizontal Irradiance in Argentina Using a Multilayer Perceptron. ISES Solar World Congress.

Guyon I., Elisseeff A. (2003). An introduction to variable and feature selection. *J. Mach. Learn. Res.* 3, (3/1/2003), 1157–1182.

Instrucciones para publicar Notas Técnicas

En el SMN existieron y existen una importante cantidad de publicaciones periódicas dedicadas a informar a usuarios distintos aspectos de las actividades del servicio, en general asociados con observaciones o pronósticos meteorológicos.

Existe no obstante abundante material escrito de carácter técnico que no tiene un vehículo de comunicación adecuado ya que no se acomoda a las publicaciones arriba mencionadas ni es apropiado para revistas científicas. Este material, sin embargo, es fundamental para plasmar las actividades y desarrollos de la institución y que esta dé cuenta de su producción técnica. Es importante que las actividades de la institución puedan ser comprendidas con solo acercarse a sus diferentes publicaciones y la longitud de los documentos no debe ser un limitante.

Los interesados en transformar sus trabajos en Notas Técnicas pueden comunicarse con Ramón de Elía (rdelia@smn.gov.ar), Luciano Vidal (lvidal@smn.gov.ar) o Martin Rugna (mrugna@smn.gov.ar) de la Dirección Nacional de Ciencia e Innovación en Productos y Servicios, para obtener la plantilla WORD que sirve de modelo para la escritura de la Nota Técnica. Una vez armado el documento deben enviarlo en formato PDF a los correos antes mencionados. Antes del envío final los autores deben informarse del número de serie que le corresponde a su trabajo e incluirlo en la portada.

La versión digital de la Nota Técnica quedará publicada en el Repositorio Digital del Servicio Meteorológico Nacional.