

Modelo de pronóstico de potencia solar empleando L.S.T.M. con datos de entrada provenientes de simulaciones con WRF-ARW.

Solar power forecasting model with L.S.T.M. using input data from WRF- ARW simulations.

Victor Silveira¹, Sofia Ortelí², Everton de Almeida³, Gabriel Cazes⁴, Alejandro Gutiérrez⁵

Recibido: 29/06/2023 y Aceptado: 16/10/2023

ENERLAC. Volumen VII. Número 2. Diciembre, 2023

ISSN: 2602-8042 (impreso) / 2631-2522(digital)



87

1.- Instituto de Mecánica de los Fluidos e Ingeniería Ambiental, Facultad de Ingeniería, UdelaR. Uruguay, Docente grado 1
0000-0002-5021-5515
vsilveira@fing.edu.uy

2.- Instituto de Mecánica de los Fluidos e Ingeniería Ambiental, Facultad de Ingeniería, UdelaR. Uruguay, Docente grado 1
0000-0002-4533-1677
sofiao@fing.edu.uy

3.- Instituto de Mecánica de los Fluidos e Ingeniería Ambiental, Facultad de Ingeniería, UdelaR. Uruguay, Estudiante de postgrado, UdelaR.
0009-0008-6842-7154
ealmeida@fing.edu.uy

4.- Instituto de Mecánica de los Fluidos e Ingeniería Ambiental, Facultad de Ingeniería, UdelaR. Uruguay, Docente grado 4, Profesor agregado.
agcm@fing.edu.uy

5.- Instituto de Mecánica de los Fluidos e Ingeniería Ambiental, Facultad de Ingeniería, UdelaR. Uruguay, Docente grado 4, Profesor agregado.
0000-0002-0769-3861
aguti@fing.edu.uy



Resumen

Este trabajo describe un modelo de predicción de potencia solar con horizonte de pronóstico de 1 a 72 horas, mediante el acople de un modelo numérico de predicción atmosférica WRF acoplado con redes neuronales LSTM. La predicción de potencia se realiza para las plantas solares de mayor potencia instalada en Uruguay, así como para pronosticar la potencia total generada en el país. Las redes LSTM utilizan como variables de entrada las variables de radiación de onda corta, temperatura a 2 metros y la cantidad de contenido de agua líquida y vapor de agua integrado en el perfil vertical, todas variables simuladas numéricamente con WRF. Se hace uso de la declinación solar como variables adicionales. Los resultados muestran una buena capacidad de pronóstico a corto plazo.

PALABRAS CLAVE: Predicción de Potencia Solar, LSTM, WRF, Modelos Numéricos de Predicción Atmosférica, Datos reales.

Abstract

This paper presents a solar power prediction model with a forecast horizon ranging from 1 to 72 hours by combining a WRF numerical weather prediction model with LSTM neural networks. The power prediction is conducted for the highest installed capacity solar plants in Uruguay, as well as for forecasting the total power generated in the country. The LSTM networks utilize shortwave radiation variables, 2-meter temperature, and the amount of liquid water content and water vapor integrated over the vertical profile as input variables, all simulated numerically with WRF. Solar declination is used as an additional variable. The results demonstrate a strong forecasting capability in short term.

89

KEYWORDS: Solar Power Forecasting, LSTM, WRF, Numerical Weather Prediction Model, Real Data.

1. INTRODUCCIÓN

En [1] se presenta la característica del recurso solar en Uruguay, presentando las características de la variabilidad estacional.

Los operadores del sistema eléctrico deben siempre asegurar el correcto balance entre la producción y el consumo eléctrico. Actualmente, la operación segura y robusta de una red eléctrica necesita los más precisos pronósticos de potencia para lograr minimizar el uso de centrales energéticas de reserva. En el año 2010 es refrendado el plan de políticas energéticas 2005-2030. Este apunta a la independencia energética, así como a promover políticas de eficiencia energética tanto en industrias como en hogares, mediante metas a corto (2015), mediano (2020) y largo plazo (2030) [2]. El impacto de esta nueva política energética se ve reflejado a partir de 2008 con un crecimiento mantenido de la generación eólica y solar fotovoltaica, donde el rol del pronóstico, así como su precisión, se vuelven más y más relevantes [3].

El pronóstico de potencia tanto solar como eólica se han vuelto herramientas operacionales cruciales para la gestión de sistemas eléctricos nacionales, así como regionales. En particular, países como Uruguay, en que presenta una participación del 35.3% en energía eólica y 3.1% en energía solar en la generación total de energía eléctrica del país para el año 2021[4]. En función del horizonte de tiempo se tienen diferentes estrategias de pronóstico que resultan las más convenientes desde el punto de vista del desempeño, en [5] se presentan las herramientas aplicables en función del horizonte temporal y la resolución espacial, en dicho trabajo se destaca que los modelos basados en imágenes satelitales como las desarrolladas [6] pueden llegar a ser útiles hasta 6 horas, de horizonte de pronóstico. En [7] y [8] se presenta el uso de Redes neuronales LSTM (del inglés Long Short-Term Memory) para el pronóstico de la producción de energía fotovoltaica.

Los modelos de mesoescala, así como el Weather Research and Forecasting (WRF) [9], son capaces de pronosticar variables atmosféricas a corto plazo (desde 1 día a 1 una semana de horizonte de pronóstico), mejorando su habilidad de pronóstico mediante el aumento de la resolución horizontal de su dominio. Sin embargo, predecir con precisión la formación, desarrollo y disipación de fenómenos como niebla y stratuscumulus de baja altitud siguen presentando un desafío para los modelos de predicción numérica. En particular, los errores en la predicción de dichas nubes, impacta directamente la calidad del pronóstico de potencia solar [10]. En [11] se presenta el desempeño del pronóstico de la radiación en plano horizontal para un día a futuro en estaciones meteorológicas obtenido a partir del modelo

de mesoescala WRF, siendo el modelo GFS (Global Forecast System) como condiciones iniciales y de borde para su ejecución


Se han desarrollado modelos de pronóstico de potencia solar con ventana de pronóstico a 24 horas empleando redes neuronales artificiales y datos del European Centre for Medium- Range Weather Forecasts (ECMWF) [12]. En el presente trabajo, serán descritos un modelo operacional con ventana de pronóstico de 1 a 72 horas haciendo uso de Redes neuronales LSTM [13], las cuales presentan la ventaja de hacer uso de la información temporal de las variables de entrada en horas cercanas a las de pronóstico.

2. DESCRIPCIÓN DE LAS PLANTAS SOLARES

Para este trabajo, se consideran doce plantas solares, las cuales son las principales productoras de energía solar en Uruguay. Su localización se

presenta en la figura 1, en gran parte se disponen sobre la región noreste del país, debido a la mayor radiación solar disponible sobre esta región.

Figura 1: Localización geográfica de las principales plantas solares en Uruguay



Fuente: Elaboración propia

En la tabla 1 se presentan cada una de las plantas solares, detallando nombre, potencia instalada, coordenadas y alias, que será utilizado

más adelante por practicidad. La potencia solar instalada suma un total de 223.3 MW

Tabla 1: Descripción de las plantas solares

Planta Solar	Alias	Potencia (MW)	Coordenadas
DICANO	DICA	11.3	32.30 °S 58.03 °W
DEL LITORAL	DLIT	16	31.43 °S 57.86 °W
LA JACINTA	JACI	50	31.93 °S 57.91 °W
EL NARANJAL	NARA	50	31.26 °S 57.86 °W
NATELU	NATE	9.5	33.26 °S 57.99 °W
PETILCORAN	PETI	9.5	32.30 °S 58.01 °W
ARAPEY	APEY	10	30.91 °S 57.47 °W
FENIMA	FENI	9.5	32.30 °S 58.02 °W
MENAFRA	MENA	20	32.61 °S 57.99 °W
YARNEL	YARN	9.5	32.68 °S 57.61 °W
RADITON	RADI	8	32.39 °S 58.13 °W
ALTO CIELO	ALTO	20	30.42 °S 57.46 °W

Fuente: Elaboración propia

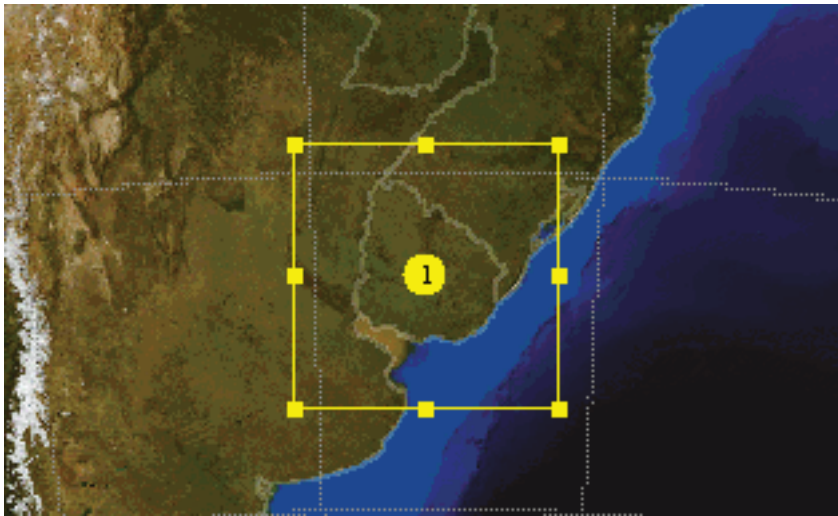
3. SIMULACIÓN GFS-WRF

Las condiciones de borde atmosféricas para la simulación WRF-ARW versión 4.3 (de ahora en más WRF) [14] son obtenidas a partir de datos provenientes de GFS (Global Forecasting System, por sus siglas en inglés) [15], resolución 0.5 grados. Para entrenar las redes LSTM, se emplea una simulación WRF con un horizonte temporal de 24 horas buscando una menor dispersión de las condiciones atmosféricas. Una vez entrenadas, la versión operativa de las redes emplea como datos de entrada WRF con un horizonte temporal de 72 horas, haciendo posible un pronóstico de potencia

a mayor plazo a cambio de mayor incertidumbre de las condiciones atmosféricas. El pronóstico operativo emplea el método EPS, que consiste en 30 simulaciones WRF con condiciones iniciales perturbadas, a diferencia del único escenario atmosférico empleado entrenar las redes.

El dominio de simulación se muestra en la figura 2, este presenta una resolución espacial de 12 km, de 150x150 nodos, centrado en las coordenadas 33.01 °S y 56.15 °W.

Figura 2: Dominio de la simulación



Fuente: Elaboración propia

Todas las simulaciones emplearon 37 niveles verticales de resolución. Las parametrizaciones

empleadas se detallan en la tabla 2:

Tabla 2: Descripción de las parametrizaciones empleadas en la simulación

Parametrización	Modelos empleados
Radiación	RRTM longwave [16] Dudhia shortwave [17] Esquemas de radiación [18]
Microfísica	Lin microphysics [19]
Suelo	Noah land surface model [20]
Cumulus	Kain-Fritsch [21] Cumulus scheme [22]
Capa Límite atmosférica	PL boundary layers scheme Mellor Yamada-Janic TKE scheme [23], [24]

Fuente: Elaboración propia

Las salidas del modelo empleadas para la calibración de las redes fueron la radiación solar neta de onda corta incidente al suelo (swdown), la temperatura a 2 metros de altura (temp.), el contenido de agua líquida (qrain) y el contenido de vapor de agua (qvap) integrados sobre todo el perfil vertical. Se requiere un post-procesamiento para obtener cada una de estas magnitudes sobre cada una de las plantas solares. El procesamiento consiste en una interpolación a partir de los nodos de la malla más cercanos a las coordenadas de la planta especificada.

El método de predicción mediante EPS (Ensembles prediction system por sus siglas en inglés) es usado a menudo para lograr estimar la incertidumbre de los pronósticos, debido a que estos están basados en varias simulaciones del mismo modelo atmosférico variando sutilmente sus condiciones iniciales, derivando en un conjunto de escenarios posibles a futuro [25]. Dada la naturaleza caótica

de la atmósfera terrestre, el método por EPS es confiable para estimar la incertidumbre de las condiciones atmosféricas a futuro.

En este estudio, son empleados los ensembles atmosféricos del modelo GFS de 0.5 grados de resolución. Estos datos son utilizados como condiciones de borde atmosféricas para el modelo WRF, teniendo como salida un total de 30 escenarios diferentes con una resolución horizontal de 12 km. Existen diversas formas de estimar la incertidumbre del pronóstico a partir de sus 30 ensembles, en este trabajo se emplea el promedio de los 30 ensembles como la potencia esperada, y se calcula un intervalo de confianza al 90%. Es decir, a cada uno de los de los 30 escenarios atmosféricos se les aplicará las redes LSTM para pronosticar 30 escenarios posibles de generación fotovoltaica, y luego se le calcula el valor medio e intervalo de confianza para cada hora de pronóstico LSTM.

4. LONG SHORT-TERM MEMORY NETWORKS


4.1 Variables de entrada

La salida del modelo consiste en la potencia generada por la planta solar para la hora indicada. Para las fases de entrenamiento, validación y test, es necesario aportar la potencia real generada por cada planta solar.

Los datos de entrada de las redes son las variables atmosféricas de mayor relevancia para la generación solar. Estas son la radiación solar de onda corta incidente neta (swdown) — directamente proporcional con la potencia generada—, la temperatura a 2 m de la superficie (temp) —que afecta al rendimiento de los paneles solares—, el contenido de agua líquida (qrain) y gaseosa (qvap) integradas sobre los primeros

1000 m de altura —indicadores de la presencia de nubes—. A su vez, se emplea una variable extra, consistente en la declinación solar, esta variable está completamente determinada por el día y la hora del año. Dada la naturaleza del modelo de inteligencia artificial, es necesario aportar información de la variación temporal de cada una de estas variables. A partir de pruebas con el set de datos de calibración, se obtiene una ventana temporal de 24 horas hacia el pasado y 3 horas hacia el futuro respecto a la hora del pronóstico L.S.T.M, esta ventana se construye para cada una de las variables simuladas con el WRF y se emplea para pronosticar la potencia de la hora h, ver figura 3.

Figura3: Ventana temporal para redes LSTM, set de calibración



Una vez generados los datos de entrada para las redes, se eliminan las entradas correspondientes

a horas nocturnas, tanto para la calibración como para el uso operativo de las mismas.

4.2 Datos de entrenamiento, validación y test

Se disponen datos tanto de potencia generada, así como de variables simuladas mediante WRF para el período 01/09/2018 – 31/07/2022, es decir, 3 años y 11 meses (1430 días). La división de los datos se realiza de la siguiente forma:

Entrenamiento 01/09/2018 - 31/08/2020
 Validación 01/09/2020 – 31/07/2021
 Test 01/08/2021 – 31/07/2022

En la división de datos de entrenamiento y validación, se toma en consideración la naturaleza estacional de los datos. Por este motivo se asignan años completos, evitando posibles sesgos en el pronóstico debido a la falta de información estacional.

Para la preparación de los datos de entrada, se toma en consideración que los datos más apartados de la hora de la inicialización serán cada vez menos precisos debido a las incertidumbres asociadas a las condiciones atmosféricas.

Para generar los datos de entrada de las redes, se le aplica la ventana temporal para todos los días de simulación del set de calibración, mientras que para la variable de salida (potencia fotovoltaica), se emplea la potencia generada por la planta para la hora de pronóstico L.S.T.M.

4.3 Procedimiento de calibración

La calibración del modelo se hace variando los parámetros disponibles para las redes LSTM. Estos son, número de neuronas, cantidad de épocas, ventana temporal, función de pérdidas.

Los datos de validación se emplean para verificar que el modelo no sobre ajuste ni sub- ajuste. Finalmente, el desempeño del modelo se evalúa utilizando los datos de test, donde se calcula el

sesgo (BIAS), error medio absoluto (MAE), la raíz del error cuadrático medio (RMSE) y la correlación (COR).

Los parámetros encontrados que mejoran el desempeño del modelo se disponen en la siguiente tabla, y fueron obtenidos usando el set de calibración para la planta JACI:

Tabla 3: Descripción de los parámetros empleados en las redes LSTM

Loss	MAE	Activation Function	tanh
Neuronas	20	Activation dense	linear
Épocas	70	Horas hacia el pasado	24
Batch size	70	Horas hacia el futuro	3

Fuente: Elaboración propia

5. RESULTADOS DE LA FASE DE TEST Y DISCUSIÓN

5.1 Resultados para plantas individuales

En la tabla 4 se muestran los valores de BIAS, MAE, RMSE y COR obtenidos para cada una de las plantas solares durante el período de test, estimadores normalizados según la potencia nominal de cada planta:

Tabla 4: Resultados de la predicción con los datos test para cada planta sola

Plantas	BIAS [%]	MAE [%]	RMSE [%]	Correlación [%]
ALTO	3.09	8.58	15.1	90.96
APEY	0.93	9.52	15.2	88.55
DICA	0.87	8.75	13.8	88.72
DLIT	0.94	9.26	15.6	88.62
FENI	-0.53	8.81	13.8	88.65
JACI	1.39	11.18	19.3	84.28
MENA	-1.44	10.25	15.9	87.89
NARA	2.7	10.46	17.9	86.37
NATE	0.79	8.15	13.6	90.3
PETI	-2.47	11.53	16.3	84.34
RADI	4.36	11.71	19.7	81.01
YARN	0.69	7.88	13.3	90.96

Fuente: Elaboración propia

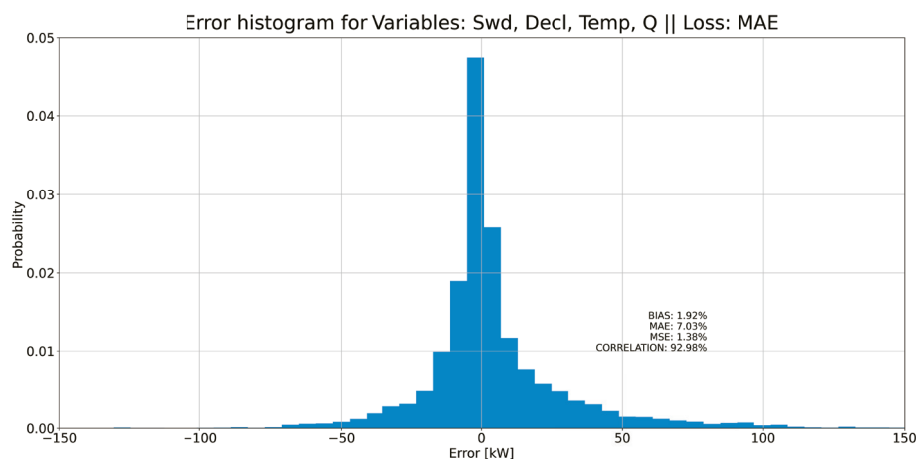
95

5.2 Resultados del pronóstico global

Es relevante a nivel nacional conocer la potencia global generada por todas las principales plantas solares instaladas en el territorio, así como su producción individual. Se pronostica la potencia total generada mediante la suma de la producción

individual de cada planta solar. En la figura 4 se muestra el histograma del error para el período de test, incluyendo los estimadores de error normalizados según la potencia total instalada.

Figura 4: Histograma de error para la suma de la producción de las plantas solares en Uruguay.




Fuente: Elaboración propia

5.3 Ejecución operativa del modelo calibrado

Una vez calibradas las redes LSTM, se toma un período más reciente para ilustrar su funcionamiento en condiciones operativas para un horizonte de 72 horas, ver figura 5.

Se toma el caso de ejemplo de la planta solar JACI, en la figura 6 se muestra la evolución temporal para el día 24/03/2023.

Figura 5: Ventana temporal para redes LSTM, pronóstico operativo



Fuente: Elaboración propia


En la figura 6a se observa cada uno de los 30 ensambles generados mediante pequeñas perturbaciones en las condiciones iniciales de la atmósfera. Estos consisten en 30 escenarios atmosféricos diferentes, que brindan la información de la variabilidad atmosférica. Se le aplica la red L.S.T.M. a los mismos de forma de obtener 30 escenarios posibles de potencia en las plantas. Con esta información, se puede brindar, además del valor medio de potencia, su intervalo de confianza.

calcula el intervalo de confianza al 90% a partir de los 30 ensambles. Se puede apreciar el aumento en la dispersión de los resultados para el segundo día de pronóstico, esto refleja la incertidumbre atmosférica respecto a las condiciones de nubosidad del segundo día, afectando la radiación incidente sobre los paneles fotovoltaicos.

Se toma el caso de ejemplo de la planta solar JACI, en la figura 6 se muestra la evolución temporal para el día 24/03/2023.

Por otro lado, se presenta la figura 6b, donde se

Figura 6: Pronóstico operativo para la planta solar JACI para el día 24/03/2023: a) Pronóstico medio en conjunto con los 30 ensambles y b) Pronóstico medio y el percentil 5 y 95 de los ensambles.




Fuente: Elaboración propia

El error medio absoluto y el sesgo según la hora de pronóstico para la misma planta se presentan en la siguiente figura. El período elegido corresponde al

04/03/2023 – 22/05/2023, valores normalizados según la potencia nominal de la planta.

Figura 7: Desempeño del modelo pronosticando la potencia generada en la planta JACI para un horizonte de 72 horas




Fuente: Elaboración propia

Se presenta para la potencia generada global la evolución temporal para el día 04/03/2023 para un horizonte de 72 horas en la figura 8, así el error medio absoluto y el sesgo (normalizados

según la potencia total instalada), según la hora de pronóstico durante el período 04/03/2023 – 22/05/2023 en la figura 9.


97

Figura 8: Pronóstico operativo para la potencia total instalada para el día 24/03/2023: a) Pronóstico medio en conjunto con los 30 ensambles y b) Pronóstico medio y el percentil 5 y 95 de los ensambles.



Fuente: Elaboración propia

Figura 9: Desempeño del modelo pronosticando la potencia total instalada para un horizonte de 72 horas.



Fuente: Elaboración propia

98

6. CONCLUSIONES

En este trabajo se presenta un modelo de pronóstico de potencia solar generada por las principales plantas solares fotovoltaicas del territorio uruguayo, empleando el modelo de simulación atmosférica, W.R.F.-A.R.W., acoplado con un modelo de inteligencia artificial de pronóstico de series temporales, L.S.T.M.

Se detalla el procedimiento empleado de calibración, así como las variables atmosféricas de mayor relevancia para el pronóstico de potencia solar, así como las parametrizaciones que obtuvieron el mayor desempeño al momento de pronosticar la potencia generada mediante las redes neuronales, haciendo uso de un histórico de 4 años para lograr el cometido.

Mediante el análisis de resultados, se concluye que es posible obtener un pronóstico de potencia

solar con un error medio absoluto de 7.03% y RMSE 11.94% para las primeras 24 horas, calculado solamente durante las horas de en las cuales se percibe radiación solar incidente.

El modelo de pronóstico operativo permite estimar la incertidumbre asociada a las condiciones atmosféricas mediante el uso del sistema de predicción mediante ensembles (EPS), aportando un indicador de la confiabilidad del pronóstico y siendo una información de suma importancia a los operadores de carga del suministro eléctrico.

7. REFERENCIAS

- [1] Abal, G, D'Angelo, M, Cataldo, J y Gutiérrez, A. (2011.). Mapa solar del Uruguay versión 1.0 : Memoria Técnica. Udelar. CSIC.
- [2] Ministerio de Industria Energía y Minería - Dirección Nacional de Energía. (Año de publicación). Políticas Energéticas 2005-2030. MINISTERIO DE INDUSTRIA, ENERGÍA Y MINERÍA (MIEM). (2005). Política Energética Uruguay 2005-2030. Recuperado de <http://www.eficienciaenergetica.gub.uy/documents/20182/22528/Pol%C3%ADtica+Energ%C3%A9tica+2005-2030/841defd5-0b57-43fc-be56-94342af619a0>
- [3] Couto, A., Schimeczek, C., Algarvio, H., Preto, I., Kochems, J., & Santos, T. (2021). New forecast tools to enhance the value of VRE on the electricity markets.
- [4] ADME - Administración del Mercado Eléctrico. (2013). Informe Anual 2021. Administración del Mercado Eléctrico. (2013). ADME. Informe Anual 2021. Recuperado de https://adme.com.uy/db-docs/Docs_secciones/nid_526/Informe_Anual_2021.pdf
- [5] Widén J, Carpman N, Castellucci V, Lingfors D, Olauson J, Remouit F, Bergkvist M, Grabbe M, Waters R, Variability assessment and forecasting of renewables: A review for solar, wind, wave and tidal resources, Renewable and Sustainable Energy Reviews, Volume 44, 2015, 356-375, ISSN 1364-0321.
- [6] Coteloro-Rola, M y Alonso-Suárez, R. (2020.). Pronóstico de la irradiación solar horaria en Uruguay y sur de Brasil utilizando redes neuronales recurrentes. EN: Anales del VIII Congresso Brasileiro de Energia Solar, Fortaleza, Brasil, 26-30 de Octubre de 2020. 11 p.
- [7] Qing, X., & Niu, Y. (2018). Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. Energy, 148, 461-468. <https://doi.org/10.1016/j.energy.2018.01.177>.
- [8] Lee, W., Kim, K., Park, J., Kim, J., & Kim, Y. (2018). Forecasting Solar Power Using Long-Short Term Memory and Convolutional Neural Networks. IEEE Access, 10.1109/ACCESS.2018.2883330.
- [9] Skamarock, W. C., y coautores. (2008). Description of the Advanced Research WRF Version 3 (Informe Técnico No. NCAR/TN-475+STR).
- [10] Köhler, C., Steiner, A., Saint-Drenan, Y.-M., Ernst, D., Bergmann-Dick, A., Zirkelbach, M., Ben Bouallègue, Z., Metzinger, I., & Ritter, B. (2017). Critical weather situations for renewable energies – part b: Low stratus risk for solar power. Renewable Energy, 101, 794–803.
- [11] Teixeira-Branco, V., Alonso-Suárez, R., Almeida, E., Porrini, C., Gutiérrez, A., & Cazes, G. (2018). Evaluación del pronóstico de irradiación solar diaria en Uruguay utilizando el modelo WRF [Preprint]. Publicado en los Anales del VII Congresso Brasileiro de Energia Solar (CBENS), 2018.
- [12] Cornaro, C., Pierro, M., & Bucci, F. (2015). Master optimization process based on neural networks ensemble for 24-h solar irradiance forecast. Solar Energy, 111, 297–312.
- [13] Hochreiter, Sepp & Schmidhuber, Jürgen. (1997). Long Short-term Memory. Neural computation. 9. 1735-80. 10.1162/neco.1997.9.8.1735.
- [14] WRF - Weather Research and Forecasting (WRF) Model. (2022). Skamarock, W. C., & Coautores. (2008). A description of the Advanced Research WRF version 3 (NCAR Tech. Note NCAR/TN-4751STR, 113 pp.). <https://doi.org/10.5065/D68S4MVH>.
- [15] GFS - Global Forecast System. (2022). NOAA Global Forecast System (GFS). (Fecha de acceso). Recuperado de <https://registry.opendata.aws/noaa-gfs-bdp-pds>. NOAA. (2018). Global Forecast System (GFS) [0.5 Deg.]. Disponible en <https://www.ncei.noaa.gov/access/metadata/landing-page/bin/iso?id=gov.noaa.ncdc:C00634> (consultado el 8 de octubre de 2018).

- [16] Mlawer, E. J., Taubman, S. J., Brown, P. D., Iacono, M. J., & Clough, S. A. (1997). Radiative transfer for inhomogeneous atmosphere: RRTM, a validated correlated-k model for the long-wave. *Journal of Geophysical Research*, 102(d14), 16663–16682.
- [17] Lacis, A. A., & Hansen, J. E. (1974). A parameterization for the absorption of solar radiation in the earth's atmosphere. *Journal of Atmospheric Sciences*, 31(1), 118–133.
- [18] Stephens, G. L. (1978). Radiation profiles in extended water clouds. Part II: Parameterization schemes. *Journal of Atmospheric Sciences*, 35(1), 2123–2132.
- [19] Lin, Y.-L., Farley, R. D., & Orville, H. D. (1983). Bulk parameterization of the snow field in a cloud model. *Journal of Climate and Applied Meteorology*, 22, 1065-1092.
- [20] Chen, F., & Dudhia, J. (2001). Coupling an advanced land-surface/hydrology model with the Penn State/NCAR MM5 modeling system. Part I: Model description and implementation. *Monthly Weather Review*, 129(1), 569–585.
- [21] Kain, J. S. (2004). The Kain-Fritsch convective parameterization: An update. *Journal of Applied Meteorology and Climatology*, 43(1), 170–181.
- [22] Kain, J. S., & Fritsch, J. M. (1990). A one-dimensional entraining/detraining plume model and its application in convective parameterization. *Journal of Applied Meteorology and Climatology*, 47(23), 2784–2802.
- [23] Mellor, Y. T. (1974). A hierarchy of turbulence closure models for planetary boundary layers. *Journal of Atmospheric Science*, 31, 1791–1806.
- 100 [24] Mellor, Y. T. (1982). Development of a turbulence closure model for geophysical fluid problems. *Reviews of Geophysics and Space Physics*, 20, 851–875.
- [25] Sperti, S., Alessandrini, S., & Monache, L. (2016). An application of the ECMWF Ensemble Prediction System for short-term solar power forecasting. *Solar Energy*, 133, 437–450.