

# 26

Fecha de presentación: diciembre, 2022

Fecha de aceptación: febrero, 2023

Fecha de publicación: abril, 2023

## PREDICCIÓN

DE LA GENERACIÓN FOTOVOLTAICA USANDO DEEP LEARNING

### PREDICTION OF PHOTOVOLTAIC GENERATION USING DEEP LEARNING

Isidro Fraga Hurtado<sup>1</sup>

E-mail: [ifraga@ucf.edu.cu](mailto:ifraga@ucf.edu.cu)

ORCID: <https://orcid.org/0000-0002-0516-8553>

Marco Antonio Gómez Rodríguez<sup>1</sup>

E-mail: [magomez@ucf.edu.cu](mailto:magomez@ucf.edu.cu)

ORCID: <https://orcid.org/0000-0003-3182-0928>

Julio Rafael Gómez Sarduy<sup>1</sup>

E-mail: [jgomez@ucf.edu.cu](mailto:jgomez@ucf.edu.cu)

ORCID: <https://orcid.org/0000-0003-3313-6572>

Zaid García Sánchez<sup>1</sup>

E-mail: [zgarcia@ucf.edu.cu](mailto:zgarcia@ucf.edu.cu)

ORCID: <https://orcid.org/0000-0003-1989-9362>

<sup>1</sup>Universidad de Cienfuegos "Carlos Rafael Rodríguez" Cienfuegos. Cuba.

#### Cita sugerida (APA, séptima edición)

Fraga Hurtado, I., Gómez Rodríguez, M. A., Gómez Sarduy, J. R., & García Sánchez, Z. (2023). Predicción de la generación fotovoltaica usando Deep Learning. *Universidad y Sociedad*, 15(S1), 266-275.

#### RESUMEN

La intermitencia de la radiación solar y otros parámetros climáticos hacen que la generación de energía fotovoltaica tenga una alta variabilidad. Por lo tanto, la planificación de la generación se ve afectada cuando hay una penetración de potencia fotovoltaica en el sistema de más de un 10%. El pronóstico preciso a corto plazo de este tipo de generadores es importante para los operadores del sistema de potencia. Este trabajo se refiere a la obtención de un modelo de pronóstico a corto plazo para un parque fotovoltaico de la provincia de Cienfuegos. Se describen modelos basados en Deep Learning como las redes neuronales multicapas LSTM, BiLSTM y GRU para pronosticar la generación de potencia fotovoltaica para el día siguiente o la hora siguiente, a partir de datos históricos del Sistema de Supervisión y Adquisición de Datos (SCADA) y de variables meteorológicas locales. Se trabajó en entorno Matlab y se desarrollaron varios modelos de redes neuronales variando sus parámetros para seleccionar las de mejor desempeño. Dichos modelos se desarrollaron y validaron para un parque de generación fotovoltaica de 5,5 MW. La comparación entre ellos arroja que los de mayor precisión son aquellos que emplean horizontes de tiempo más cortos y redes BiLSTM.

**Palabras clave:** generación fotovoltaica, modelos de predicción, redes neuronales artificiales, fuentes renovables de energía, deep learning

#### ABSTRACT

The intermittency of solar radiation and other climatic parameters make the generation of photovoltaic energy have a high variability. Therefore, the planning of the generation is affected when the penetration of photovoltaic power is more than 10%. Accurate short-term forecasting of these types of generators is important to power system operators. This work refers to obtaining a short-term forecast model for a photovoltaic park in the province of Cienfuegos. Models based on Deep Learning such as LSTM, BiLSTM and GRU multilayer neural networks are described to forecast the generation of photovoltaic power for the next day or the next hour, based on historical data from the Supervisory and Data Acquisition System (SCADA) and of local meteorological variables. We worked in a Matlab environment and several models of neural networks were developed, varying their parameters to select the ones with the best performance. These models were developed and validated for a 5.5 MW photovoltaic generation park. The comparison between them shows that the ones with the highest precision are those that use shorter time horizons and BiLSTM networks.

**Keywords:** photovoltaic generation, prediction models, artificial neural networks, renewable energy, deep learning

## INTRODUCCIÓN

El incremento de la penetración de unidades de generación basadas en fuentes renovables de energía caracterizó la evolución de los sistemas eléctricos de potencia SEPs en las últimas décadas. Puede señalarse como principal inconveniente de este tipo de fuente la variabilidad en la entrega de potencia y su efecto en el control de frecuencia (Godoy et al, 2022, Gallego et al., 2017, Atwa & El-Saadany, 2010, Delille et al., 2012). Estudios a nivel mundial demuestran que un incremento en la penetración de estas unidades de fuentes renovables introduce varios retos técnicos en la operación de los SEPs. La estabilidad de frecuencia emerge entonces como uno de las principales restricciones a analizar a la hora de planificar la operación del SEP.

No solo la variabilidad de la potencia entregada afecta la operación de la red, sino que estas tecnologías basadas en fuentes renovables, especialmente las basadas en energía solar y algunas tecnologías eólicas, reducen la inercia del SEPs lo que compromete su operación estable. Medidas para reducir el riesgo de inestabilidad de frecuencia se estudian en SEPs, la mayoría de estas encaminadas a la conexión de sistemas de almacenamiento que restituyan de manera rápida la afectación provocada en el SEPs. (Saleh et al., 2019, Saleh et al, 2020, Betancourt et al, 2020, IEEE, 2008, Saleh et al, 2017, Saleh, Aldik and Castillo-Guerra, 2017, Esmaili et al, 2013). Estos problemas se acentúan a medida que se incrementa la participación de estas tecnologías en la generación, siendo incluso este aspecto la limitante fundamental de la penetración de las fuentes renovables en los SEPs.

Especial atención debe prestarse a los SEPs aislados pues estos generalmente están compuestos por unidades de generación de baja inercia y por tanto la penetración de fuentes renovables de energía puede deteriorar la robustez del SEP Godoy et al, 2022, Gallego et al, 2017, Atwa y El-Saadany, 2010, Delille et al, 2012). Otras de las investigaciones recientes se enmarcan en lograr una exactitud adecuada en la predicción del comportamiento de la generación variable y que este sea tenido en cuenta en las estrategias para el cubrimiento económico del gráfico de carga.

Dotar al operador de la red eléctrica de herramientas que permitan predecir a corto plazo el comportamiento de la generación renovable se convierte en un tema esencial en las investigaciones relacionadas con los SEPs. En (Yang et al., 2017) se plantea que la predicción futura de la potencia a entregar por las plantas solares fotovoltaicas (PSFV), puede reducir de manera efectiva los efectos

adversos sobre el sistema que ocasiona la conexión a red de este tipo de fuentes y ayudar a los operadores del sistema a ajustar la planificación en tiempo real y poder coordinar la generación de PSFV y otras fuentes de generación. Todo esto con el fin de garantizar la seguridad de la operación del SEP. Por lo tanto, el pronóstico de la generación eléctrica de los sistemas solares fotovoltaicos, tanto en las grandes redes de potencia como en las microrredes, juega un papel clave para la operación eficiente, económica, estable y sostenible del suministro de electricidad (Yang et al., 2017).

En el 2014, se estimó que la penetración fotovoltaica excedía el 1% en 19 países de la Unión Europea (UE), con Italia en primer lugar (7,9%) seguida de Grecia y Alemania con 7,6% y 7% respectivamente. Diferentes escenarios de la Agencia Internacional de Energía (IEA por sus siglas en inglés) predicen que para el 2030 la generación PSFV alcanzará 1,5-5% del consumo eléctrico global y del 10-25% de la demanda de la UE. Por esta razón, se estableció como obligatorio en muchos países del mundo el pronóstico con un día antes de la generación fotovoltaica (Italia, Alemania, España, Rumania, USA y Japón, entre otros) (Pierro et al., 2016).

Los centros de control del sistema eléctrico que gobiernan la operación de un SEPs al cual se pretenda conectar un incremento de generación solar es imprescindible contar con herramientas que permitan la realización de predicciones con buen nivel de exactitud para la toma de decisiones acertadas sobre aspectos claves tales como el ajuste de las fuentes de generación convencionales, programación de arranques, requerimientos de almacenamiento y planificación en general.

El pronóstico de la potencia de salida de los sistemas solares fotovoltaicos es muy difícil porque está altamente relacionado con las circunstancias externas tales como radiación solar y otros parámetros climáticos que cambian muy rápidamente en una localidad.

Una revisión de la literatura relacionada con el tema revela que a partir de 2011 las publicaciones de nuevos modelos de predicción fotovoltaicos y los estudios acerca de sus características han crecido considerablemente (Muñoz, 2014). En todos los casos, las estrategias utilizadas para el desarrollo del modelo son similares a las utilizadas para pronosticar otras magnitudes de los sistemas eléctricos como carga horaria, carga máxima y precio de la energía en el mercado (Rocha & Alves, 2005, Amjady & Keynia, 2008, Amjady & Keynia, 2009, Amjady & Keynia, 2011, Sajjad et al., 2013, Gómez et al., 2016 & Peña et al., 2019).

Son varios los trabajos que reportan el empleo de nuevas técnicas o combinación de herramientas propias de tecnologías disruptivas, por ejemplo, herramientas de Machine Learning o Deep Learning para la predicción fotovoltaica conformando modelos híbridos que alcanzan una precisión adecuada. (Ramsami & Oree, 2015, Pierro et al., 2016, Gómez et al., 2016, Li et al., 2016, Yang et al., 2017, Raabe, 2016, Amjady & Keynia, 2008, Amjady & Keynia, 2009, Sudheer & Suseelatha, 2014, Sajjad et al., 2013 & Tesfaye et al., 2018).

En función del horizonte de tiempo del pronóstico, es mejor utilizar modelos numéricos de predicción meteorológica del tiempo, conocidos como Numerical Weather Prediction (NWP) Models o modelos basados en datos históricos. Los primeros se emplean mayormente para horizontes de tiempo entre 24 y 48 horas, mientras los segundos son más eficaces para plazos de pocas horas (Muñoz, 2014).

En Cuba se ha investigado en la mejora del pronóstico de radiación solar utilizando modelos numéricos de predicción del clima combinados con técnicas de post-procesamiento que se aplican a su salida, específicamente la técnica Model Output Statistics (MOS) (Borrajero et al., 2016).

Aunque se aprecia una tendencia al empleo de NWP, se han desarrollado modelos incluso que prescinden de utilizar datos de clima (González et al., 2016). Este tipo de modelos dan la posibilidad de obtener pronósticos razonables a partir solamente de valores de la potencia generada en instantes pasados y pueden ser usados como una línea base para comparar modelos más complejos.

Muñoz plantea que los modelos basados únicamente en datos históricos se usan tanto para plazos muy cortos (menos de tres a cuatro horas) como para horizontes en torno a las 24 horas (Muñoz, 2014).

El objetivo de este trabajo es comparar varios modelos de predicción que emplean redes neuronales multicapas LSTM, BiLSTM y GRU con horizontes de tiempo de corto plazo (24 h) y de muy corto plazo (1 hora).

## DESARROLLO

### Proceso general de desarrollo del modelo

En esta investigación se tomó como caso de estudio un parque PV conectado a red con capacidad instalada de 5,5 MWp. El mismo está compuesto por 19 400 paneles fotovoltaicos conectados en 5 arreglos con dos inversores cada uno. La generación promedio diaria de esta instalación fotovoltaica es de 26 MWh aproximadamente. Para su correcta explotación, cuenta con un sistema

SCADA en el que se registran las mediciones de potencia horaria (MW) entre otras variables eléctricas y operacionales como la temperatura de los módulos. Además, cuenta con una pequeña estación meteorológica con instrumentación para medir variables como temperatura ambiente ( $^{\circ}\text{C}$ ), velocidad del viento (m/s) y radiación solar incidente ( $\text{W}/\text{m}^2$ ).

En esta investigación se considera como potencia de salida del parque la suma de las mediciones de potencia de cada inversor, es decir se desarrolla un modelo para la generación total de la instalación.

Siguiendo la línea de Tesfaye et al. (2018), en Gómez et al. (2021) se siguió una estrategia en la modelación de desarrollar un modelo híbrido con transformada wavelet discreta (DWT) pero utilizando redes neuronales artificiales. Una diferencia sustancial es que la estrategia de modelación se basó únicamente en valores pasados reales, mientras Tesfaye, Zhang y Zheng emplean históricos de predicciones de variables meteorológicas. Es decir, en esta investigación se utilizaron solamente datos históricos de mediciones locales tanto de producción como de variables meteorológicas, lo que sirve de punto de partida para incorporar en el futuro predictores numéricos del clima y mejorar la precisión.

En este trabajo se realiza el pronóstico usando redes recurrentes multicapas (Deep Learning) lo que mejora la precisión con relación a los modelos anteriores.

### Ambiente de trabajo

La modelación se lleva a cabo empleando Matlab. Matlab es un entorno de computación y desarrollo de aplicaciones totalmente integrado, orientado para llevar a cabo proyectos en donde se encuentren implicados elevados cálculos matemáticos y la visualización gráfica de los mismos. Este ambiente integra análisis numérico, cálculo matricial, proceso de señal y visualización gráfica en un entorno completo donde los problemas y sus soluciones son expresados del mismo modo en que se escribirían adicionalmente, sin necesidad de hacer uso de la programación tradicional.

Dispone también en la actualidad de un amplio abanico de programas de apoyo especializado, denominado Toolboxes, que extienden significativamente el número de funciones incorporadas en el programa principal. Estos Toolboxes cubren en la actualidad prácticamente casi todas las áreas principales en el mundo de la ingeniería y la simulación, destacando entre ellos el toolbox de proceso de imágenes, así como los de señales, control robusto, estadística, análisis financiero, matemáticas simbólicas, redes neurales, lógica difusa, identificación de sistemas,

simulación de sistemas dinámicos, etc. Es un entorno de cálculo técnico, con elevadas capacidades en computación y visualización numérica por lo que va a ser la base del desarrollo del modelo de pronóstico de generación PV de esta investigación.

### Completamiento de la información

Cuando se obtiene la información de campo (mediciones históricas de la potencia y de las variables meteorológicas), es inevitable que esta se encuentre incompleta, con valores perdidos producto de fallas en los sensores o mantenimiento de la instalación.

Para completar la información faltante se han propuesto varias técnicas, entre ellas una metodología para la incorporación de datos faltantes que emplea el análisis de series de tiempo basado en modelos de espacio de estado (Adaro et al, 2008, Adaro et al, 2014).

En Carbajal et al, (2010) se describe otro método para el completamiento de datos faltantes de precipitación diaria utilizando la "Transformada Wavelets" (TW). Este consiste en la descomposición y reconstrucción de la señal, a dos niveles, usando el Wavelet Haar. El programa desarrollado utiliza la señal que resulta del filtro de baja frecuencia, proveniente de la estación a ser corregida y el detalle o señal de alta frecuencia proveniente de una estación vecina, la que proporciona el detalle aleatorio que se usa en el llenado de datos faltantes. La selección de la estación vecina se basó en la similitud de la distribución acumulada de ambas señales previamente estandarizadas. Así mismo, Castaño, (2007) propone un método que permite la identificación del modelo y estimación conjunta de datos faltantes aplicado a series de tiempo de demanda de electricidad empleando un modelo ARIMA.

Ahora bien, en esta investigación, los valores horarios perdidos o que se saltan de cualquiera de las variables del parque fotovoltaico se sustituyen por un dato equivalente como en (Tesfaye, et al., 2018). Para ello se siguió la siguiente técnica de llenado:

$$x_i = \lambda_1 x_{i-24} + \lambda_2 x_{i+24} \quad (1)$$

Donde:

$x_i$ : representa el valor del dato del punto de muestreo  $i$

$\lambda_1$  y  $\lambda_2$ : son los pesos para el cálculo, que se toman iguales a 0,5 de manera similar a como se hace por (Tesfaye, et al., 2018)

$x_{i-24}$  y  $x_{i+24}$ : representan los valores del dato al mismo tiempo del día previo y del día siguiente respectivamente.

Las mediciones de campo se disponen en hojas de cálculo Excel para cada una de las variables, se completan, y posteriormente se importan al Workspace del Matlab para su procesamiento.

Cada variable es importada como una matriz con un número de filas igual a los días considerados (365 días para un año) y 24 columnas correspondientes a cada hora del día desde la 1:00 hasta las 24:00 h. El paso siguiente es convertir esta matriz en un vector fila que representa la serie temporal de la variable. Es decir, se crean tres vectores de igual tamaño, denominados P, Ir y T, que son los valores horarios de potencia generada (en MW), radiación solar (en W/m<sup>2</sup>) y temperatura ambiente (en °C), respectivamente.

### RESULTADOS

El paso más importante a la hora de seleccionar el modelo de predicción definitivo entre todos los desarrollados es el correspondiente a su evaluación. A continuación, se muestran los resultados de pronosticar con varios modelos comparando su eficacia a partir de la raíz del error medio cuadrático (RMSE). Este indicador de error se calcula como:

$$RMSE = \sqrt{\sum_{t=1}^N \frac{1}{N} \cdot (P(t) - \hat{P}(t))^2} \quad (\text{MW}) \quad (2)$$

Siendo:

$P(t)$ : valor real (medido) de la potencia fotovoltaica generada en el instante  $t$ , en MW

$\hat{P}(t)$ : predicción de la potencia fotovoltaica generada para el instante  $t$ , en MW

$N$ : es el número de observaciones, 24 - para el caso de predicción de la potencia horaria de un día.

### Modelo híbrido empleando DWT con redes feedforward backpropagation y redes de regresión generalizada

Los autores ya probaron con anterioridad modelos híbridos que combinan DWT con redes feedforward backpropagation y redes de regresión generalizada (Gómez et al., 2021). En esta modelación híbrida, las series temporales se descomponen mediante transformada wavelet en un conjunto de subseries. Estas subseries dan mejores características de comportamiento que las series originales debido a que permiten un tratamiento separado de las componentes de la señal, sobre todo las de mayor frecuencia que representan las variaciones rápidas.

El error del pronóstico con redes feedforward backpropagation fue  $RMSE=0,7375$  MW y con redes de regresión generalizada  $RMSE=0,7667$  MW.

### Modelo empleando redes LSTM

Las redes LSTM son una subcategoría de redes neuronales recurrentes y emplean celdas de memoria adicionales capaces de almacenar los estados. Por lo tanto, este tipo de redes son muy potentes para la predicción de series temporales (Raabe, 2016). Para propósitos de comparación se investigó con redes LSTM y redes LSTM bidireccionales (BiLSTM). Como una mejora en la estructura de las redes LSTM, las BiLSTM constan de dos partes: una capa forward y otra capa backward. La salida de este tipo de redes en el tiempo  $t$  está relacionada no solo con la entrada de la red en el tiempo  $t$  sino también con la salida de las neuronas ocultas en el instante  $t-1$  y  $t+1$ . Las figuras 1 y 2 muestran la estructura de las redes LSTM y BiLSTM respectivamente. En la figura 3 se muestra el esquema del procedimiento seguido para construir el modelo de predicción con estas redes.

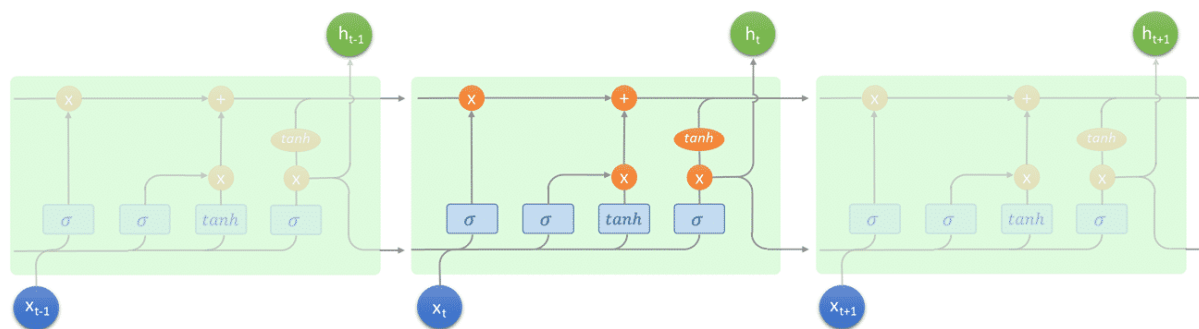


Figura 1. Estructura de la red LSTM

Fuente: los autores




Figura 2. Estructura de la red BiLSTM

Fuente: los autores

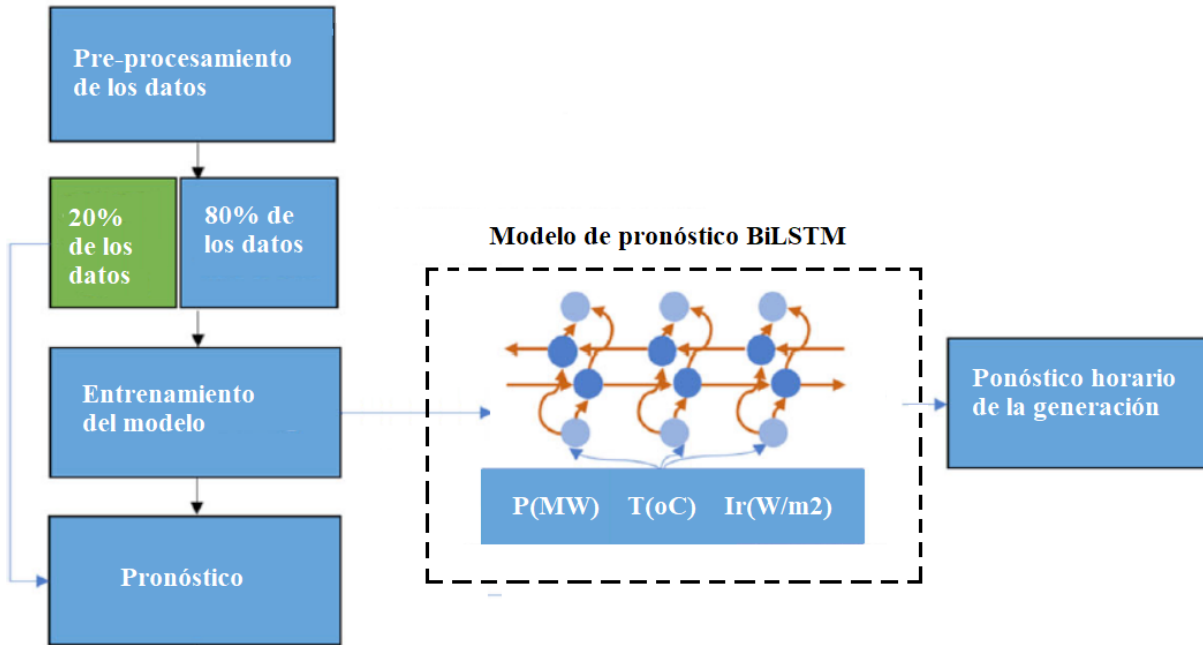


Figura 3. Estructura general de la estrategia de pronóstico de la generación del parque fotovoltaico con redes BiLSTM.

Fuente: los autores

### Modelo empleando redes GRU

Las redes GRU (Gated recurrent unit) están compuestas por unidades GRU y son un tipo especial de red neuronal recurrente descritas en 2014 por Kyunghyun (Kyunghyun et al, 2014). Ver su estructura en la figura 4. Las redes GRU son más simples que las LSTM, debido a que tienen menos parámetros, carecen de puerta de salida, se capacitan más rápido y son más eficiente en su ejecución.

Por ello las redes GRU han demostrado que presentan un mejor rendimiento en conjuntos de datos más pequeños. Sin embargo, las redes LSTM al operar con conjuntos de datos más amplios, pueden ser más expresivas y proporcionar mejores resultados ante contextos complejos.




Figura 4. Estructura de la red GRU

Fuente: los autores

Primero se realiza el preprocesamiento de los datos (completamiento de datos perdidos, vectorización (implícito en Matlab) y normalización), se separan los datos en un conjunto de entrenamiento (80%) y un conjunto de validación, se entrena la red y se emplea para realizar el pronóstico de acuerdo al horizonte de tiempo del modelo. Las variables utilizadas son la propia serie de potencia generada por el parque fotovoltaico y variables meteorológicas como la temperatura y la radiación solar.

En este trabajo se probaron redes profundas (5 capas recurrentes) de este tipo para horizontes de tiempo de 24 horas y de una hora, siendo los resultados para el día seleccionado (28 de junio de 2020) los mostrados en la figura 5 para 24 horas y en la figura 6 para una hora. En el caso de que se pronostique con LSTM para el día siguiente, el RMSE es de 0,622 MW con errores máximos de hasta 2 MW. Cuando se acorta el horizonte de tiempo, el error máximo se reduce, pero sigue cercano a los 2 MW. Los resultados para el caso de las redes GRU se muestran en las figuras 7 y 8 con un comportamiento similar a las LSTM.

Como se reporta en la literatura, se puede apreciar que el pronóstico es más preciso a medida que se acorta el horizonte de tiempo y empleando redes BiLSTM (figuras 9 y 10). Puede verse en la figura 10 que existe una gran concordancia entre el pronóstico y la generación real. En este caso, cuando se acorta el horizonte de tiempo para realizar pronósticos para la hora siguiente, el error se reduce a 0,1848 MW. Para este horizonte de pronóstico el error máximo no supera los 0,25 MW.




Figura 5. Pronóstico de la potencia generada con red tipo LSTM para 24 horas.

Fuente: los autores




Figura 6. Pronóstico de la potencia generada con red tipo LSTM para 1 hora.

Fuente: los autores

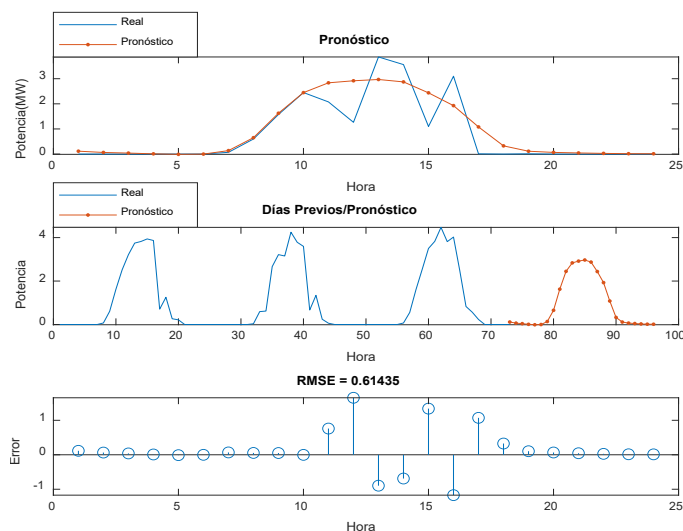


Figura 7. Pronóstico de la potencia generada con red tipo GRU para 24 horas.

Fuente: los autores

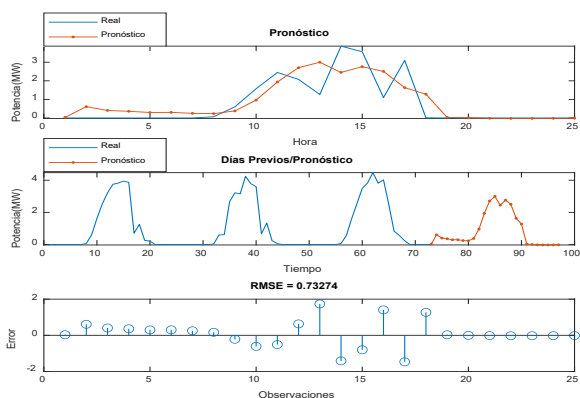


Figura 8. Pronóstico de la potencia generada con red tipo GRU para 1 hora.

Fuente: los autores

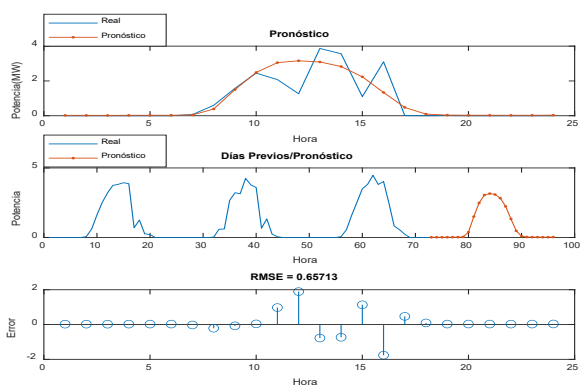


Figura 9. Pronóstico de la potencia generada con red tipo BiLSTM para 24 horas.

Fuente: los autores




Figura 10. Pronóstico de la potencia generada con red tipo BiLSTM para 1 hora.

Fuente: los autores

## CONCLUSIONES

La bibliografía consultada muestra que el desarrollo de modelos de pronóstico de la generación fotovoltaica es un tema de investigación, desarrollo y despliegue intensivo en todo el mundo en los últimos años por las implicaciones técnicas y económicas que tiene en la operación de los sistemas de potencia. Estas investigaciones dejan patente que el uso de herramientas de inteligencia artificial ya sea para modelos de regresión o clasificación (redes neuronales, máquinas de soporte vectorial, redes profundas), permiten simular el comportamiento de la producción horaria del sistema solar fotovoltaico de una forma más precisa que las técnicas clásicas debido a que logran solventar las no linealidades que presentan estos sistemas.

Inicialmente se investigó en el uso de un modelo híbrido basado en datos pasados, que combina redes neuronales con preprocesamiento de la información primaria usando DWT y que requiere un mínimo de variables explicativas, información disponible en el sistema SCADA y variables meteorológicas medidas localmente en el parque fotovoltaico (producción, radiación solar y temperatura ambiente del día previo). Se demuestra que los modelos basados en Deep Learning tienen mejor precisión, siendo el mejor el que emplea redes BiLSTM, que son herramientas muy potentes para la predicción de series temporales, y además se acorta el horizonte de tiempo a una hora. El RMSE que se consigue con estas redes es de 0,185 MW mientras que con los demás modelos supera los 0,6 MW.

## REFERENCIAS

- Adaro, J; Nieto, M. B.; Zizzias, J.; Marchesi, J. (2008). *Una metodología para datos faltantes en la medición de la radiación solar*. II Congresso Brasileiro de Energia Solar e III Conferência Regional Latino-Americana da ISES - Florianópolis, 18 a 21 de noviembre de 2008.
- Adaro J.A., Marchesi J.O. y Zizzias J.H. (2014). Tratamiento para datos faltantes en series de radiación solar. *Revista Tecnología y Ciencia, Año 12 N° 25, 60-65*.
- Amjady, N. Ã., & Keynia, F. (2009). Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm. *Energy, 34*, 46–57. <https://doi.org/10.1016/j.energy.2008.09.020>



- Amjady, N., & Keynia, F. (2008). Electrical Power and Energy Systems Day ahead price forecasting of electricity markets by a mixed data model and hybrid forecast method. *International Journal of Electrical Power and Energy Systems*, 30(9), 533–546. <https://doi.org/10.1016/j.ijepes.2008.06.001>
- Amjady, N., & Keynia, F. (2011). A New Neural Network Approach to Short Term Load Forecasting of Electrical Power Systems. *Energies*, 488–503. <https://doi.org/10.3390/en4030488>
- Atwa, Y. M.; El-Saadany, E. F. (2010). Optimal Allocation of ESS in Distribution Systems with a High Penetration of Wind Energy, *IEEE Trans. on Power Systems*, Vol. 25, No. 4, pp. 1815–1822.
- Betancourt, O. A.; García, Z.; Saleh, A.; Hill, E. F.; Zhao, X.; Sánchez, F. P. (2020). Battery Energy Storage Systems for Primary Frequency Regulation in Island Power Systems. *Proceeding 2020 IEEE/IAS 56th Industrial and Commercial Power Systems Technical Conference (I&CPS)*, Las Vegas, NV, USA, 2020, pp. 1-10, doi: 10.1109/ICPS48389.2020.9176784.
- Borrajero, I., Baró, A., Peláez, J. C., & Fernández, M. H. (2016). *Título del proyecto : Pronóstico de la radiación solar y potencia a generar en las plantas fotovoltaicas conectadas a la red eléctrica nacional. Informe de resultado: Uso del WRF-Solar y el post-procesamiento MOS para el pronóstico de la radiación solar* .
- Carbajal, M.; Yarleque, C.; Posadas, A.; Sivestre, E.; Mejía, A.; Quiroz, R. (2010). reconstrucción de datos faltantes de precipitación pluvial diaria mediante Transformada Wavelet. *Revista Peruana Geo-Atmosférica RPGA* (2), 76-88.
- Castaño, E. (2007). Reconstrucción de datos de series de tiempo: una aplicación a la demanda horaria de electricidad. *Revista Colombiana de Estadística*, 30(2), 247-263.
- Delille, G.; Franois, B.; Malarange, G. (2012). Dynamic Frequency Control Support by Energy Storage to Reduce the Impact of Wind and Solar Generation on Isolated Power System's Inertia. *IEEE Trans. on Sustainable Energy*, Vol. 3, No. 4, pp. 931–939.
- Esmaili, A.; Novakovic, B.; Nasiri, A.; Abdel-Baqi, O. (2013). A Hybrid System of Li-Ion Capacitors and Flow Battery for Dynamic Wind Energy Support. *IEEE Trans. on Industry Applications*, Vol. 49, No. 4, pp. 1649–1657.
- Gallego, Y.; Casas, L.; García, Z.; Rivas, Y. (2017). Impacto de la implementación de paneles fotovoltaicos en el sistema eléctrico Cayo Santa María. *Energética Vol 38*, no 2 issn: 1815-5901.
- Godoy, M.; García, Z.; Hernández, H.; Cueto, J.A.; Silva, J. I.; Crespo, G. (2022). Frequency response analysis under faults in weak power systems. *International Journal of Electrical and Computer Engineering IJECE*. Vol 12, No 2, pp 1077-1088. Abril 2022. <http://doi.org/10.11591/ijece.v12i2.pp1077-1088>.
- Gómez, J. R., Di Santo, K. G., & Saidel, M. A. (2016). Linear and non-linear methods for prediction of peak load at University of São Paulo. *Measurement*, 78, 187–201. <https://doi.org/10.1016/j.measurement.2015.09.053>
- Gómez Rodríguez, M. A., Gómez Sarduy, J. R., Lorenzo Ginori, J. V., Fonte González, R., & García Sánchez, Z. (2021). Pronóstico de la generación eléctrica de sistemas fotovoltaicos. Un inicio en cuba desde la universidad. *Revista Universidad y Sociedad*, 13(1), 253-265.
- González, J. A., Waczowicz, S., Reischl, M., Mikut, R., & Hagenmeyer, V. (2016). Photovoltaic power forecasting using simple data-driven models without weather data. *Computer Science - Research and Development*. <https://doi.org/10.1007/s00450-016-0316-5>
- IEA. (2019). *World Energy Outlook 2019*.
- IEEE (2008). Application Guide for IEEE Standard for Interconnecting Distributed Resources With Electric Power Systems, IEEE Std. 1547.2-2008, 2008.
- IRENA. (2013). *SMART GRIDS AND RENEWABLES A Guide for Effective Deployment* (Issue November). [www.irena.org](http://www.irena.org)
- Li, Y., He, Y., Su, Y., & Shu, L. (2016). Forecasting the daily power output of a grid-connected photovoltaic system based on multivariate adaptive regression splines. *Applied Energy*, 180, 392–401. <https://doi.org/10.1016/j.apenergy.2016.07.052>
- Muñoz, A. (2014). *Modelos de predicción a corto plazo de la generación eléctrica en instalaciones fotovoltaicas*. Universidad de La Rioja.
- Peña, J. A., Viego, P. R., Gómez, J. R., & Padrón, E. A. (2019). Pronóstico del consumo pico para la gestión del energética de la Universidad de Cienfuegos. *Revista Universidad y Sociedad*, 11(4), 220–228.

- Pierro, M., Bucci, F., Felice, M. De, Maggioni, E., Moser, D., Perotto, A., Spada, F., & Cornaro, C. (2016). Multi-Model Ensemble for day ahead prediction of photovoltaic power generation. *Solar Energy*, *134*, 132–146.
- Raabe, N. (2016). *Deep Learning for Solar Power Forecasting – An Approach Using Autoencoder and LSTM Neural Networks*.
- Ramsami, P., & Oree, V. (2015). A hybrid method for forecasting the energy output of photovoltaic systems. *Energy Conversion and Management*, *95*, 406–413.
- Rocha, A. J., & Alves, A. P. (2005). Feature Extraction via Multiresolution Analysis for Short-Term Load Forecasting. *IEEE TRANSACTIONS ON POWER SYSTEMS*, *20*(1), 189–198.
- Sajjad, K., Khavaninzadeh, M., & Keynia, F. (2013). Applying Wavelet to ANN based short-term load forecasting: A case study of Zanjan power pystem. *International Journal of Electrical and Electronics Engineering Research*, *3*(2), 209–216.
- Saleh, S. A.; Pijnenburg, P.; Castillo-Guerra, E. (2017). Load Aggregation From Generation-Follows-Load to Load-Follows-Generation. *IEEE Trans. on Industry Applications*, Vol. 53, No. 3, pp. 833–842.
- Saleh, S. A.; Aldik, A. A.; Castillo-Guerra, E. (2017). Distributed Energy Storage Unit-Based Active Demand Response for Residential Loads. *Proceeding of the 52nd IEEE IAS Annual Meeting Conference (IAS'17)*, Cincinnati, OH, October 2017.
- Saleh, A.; Meng, R. J.; García, Z.; Betancourt, O. A.; Ozkop, E. (2019). The Selection of Locations and Sizes of Battery Storage Systems Using the Principle Component Analysis and Center-of-Inertia. *IEEE Industry Applications Society Annual Meeting*, Baltimore, MD, USA, 2019, pp. 1-10S. doi: 10.1109/IAS.2019.8911980.
- Saleh, A.; Ozkop, E.; Meng, R. J.; García, Z.; Betancourt, O. A. (2020). Selecting Locations and Sizes of Battery Storage Systems Based on the Frequency of the Center of Inertia and Principle Component Analysis. *IEEE Transactions on Industry Applications*, vol. 56, no. 2, pp. 1040-1051, March-April 2020/S. doi: 10.1109/TIA.2019.2960003.
- Sudheer, G., & Suseelatha, A. (2014). A wavelet-nearest neighbor model for short-term load forecasting. *Energy Science & Engineering*, 1–9. <https://doi.org/10.1002/ese3.48>
- Tesfaye, A., Zhang, J., & Zheng, D. (2018). Short-term photovoltaic solar power forecasting using a hybrid Wavelet-PSO-SVM model based on SCADA and Meteorological information. *Renewable Energy*, *118*.
- Yang, X., Xu, M., Xu, S., & Han, X. (2017). Day-ahead forecasting of photovoltaic output power with similar cloud space fusion based on incomplete historical data mining. *Applied Energy*, *206*(September), 683–696. <https://doi.org/10.1016/j.apenergy.2017.08.222>