



Revista Cubana de Ciencias Informáticas

ISSN: 1994-1536

ISSN: 2227-1899

Editorial Ediciones Futuro

Herrera Casanova, Reinier; García Tamayo, Jesús G.; Bello García,  
Beatriz; León Viltres., Lesyani; Herrera Fernández, Francisco B.  
Propuesta de modelo predictivo inteligente para una planta fotovoltaica  
Revista Cubana de Ciencias Informáticas, vol. 16, núm. 1, 2022, Enero-Marzo, pp. 144-162  
Editorial Ediciones Futuro

Disponible en: <https://www.redalyc.org/articulo.oa?id=378370413010>

- ▶ Cómo citar el artículo
- ▶ Número completo
- ▶ Más información del artículo
- ▶ Página de la revista en [redalyc.org](https://www.redalyc.org)



Sistema de Información Científica Redalyc

Red de Revistas Científicas de América Latina y el Caribe, España y Portugal  
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso  
abierto

Tipo de artículo: Artículo original  
Temática: Inteligencia artificial  
Recibido: 15/12/2021 | Aceptado: 17/02/2022

## **Propuesta de modelo predictivo inteligente para una planta fotovoltaica**

### **Intelligent predictive model proposal for a photovoltaic plant**

Reinier Herrera Casanova <sup>1\*</sup> <https://orcid.org/0000-0002-3303-2063>

Jesús G. García Tamayo <sup>2</sup> <https://orcid.org/0000-0002-8158-6984>

Beatriz Bello García <sup>3</sup> <https://orcid.org/0000-0002-3943-5736>

Lesyani León Viltres. <sup>4</sup> <https://orcid.org/0000-0003-1822-2480>

Francisco B. Herrera Fernández <sup>5</sup> <https://orcid.org/0000-0002-0774-0752>

<sup>1</sup> Universidad Central “Marta Abreu” de Las Villas. Carretera a Camajuaní Km. 5½. Santa Clara. Villa Clara. Cuba. [rhcasanova@uclv.cu](mailto:rhcasanova@uclv.cu)

<sup>2</sup> Empresa de Tecnologías de la Información y la Automática UEB ATI VC. Calle Campo # 1 entre Carretera Central y Prolongación de Independencia. Reparto Virginia. Municipio Santa Clara. Provincia Villa Clara. [jesusgabrielgarciatamayo@gmail.com](mailto:jesusgabrielgarciatamayo@gmail.com)

<sup>3</sup> Universidad Central “Marta Abreu” de Las Villas. Carretera a Camajuaní Km. 5½. Santa Clara. Villa Clara. Cuba. [bbgarcia@uclv.cu](mailto:bbgarcia@uclv.cu)

<sup>4</sup> Universidad Central “Marta Abreu” de Las Villas. Carretera a Camajuaní Km. 5½. Santa Clara. Villa Clara. Cuba. [lesyani@uclv.edu.cu](mailto:lesyani@uclv.edu.cu)

<sup>5</sup> Universidad Central “Marta Abreu” de Las Villas. Carretera a Camajuaní Km. 5½. Santa Clara. Villa Clara. Cuba. [herrera@uclv.edu.cu](mailto:herrera@uclv.edu.cu)

\*Autor para la correspondencia. ([rhcasanova@uclv.cu](mailto:rhcasanova@uclv.cu))

## RESUMEN

El objetivo de este trabajo es presentar el desarrollo de una estructura de modelo dinámico para la predicción de la generación eléctrica en una planta fotovoltaica. Tradicionalmente un modelo de predicción de la generación eléctrica en este tipo de planta se basa en dos modelos, uno para la predicción de la irradiación solar y un segundo modelo para describir la relación de la irradiación solar con la potencia generada. Como variables climatológicas principales se consideran la irradiación solar y la temperatura ambiental, mientras que desde el punto de vista tecnológico se considera la limpieza de la superficie de los paneles solares, así como el punto de operación de la planta, dependiendo del período del año y la hora del día. El modelo presentado considera la irradiación solar y la temperatura ambiente como variables de entrada, al tiempo que se desarrolla la modelación no lineal existente entre la irradiación y la potencia generada, considerando como disturbios la sombra (parcial o no) sobre los módulos y la limpieza de la superficie de los paneles fotovoltaicos. El trabajo presenta una descripción tecnológica de una planta y la caracterización temporal y frecuencial de juegos de datos reales, a partir de lo cual se desarrolla la concepción de la estructura del modelo más adecuado para la aplicación de técnicas basadas en inteligencia artificial, específicamente aprendizaje profundo. Finalmente, el modelo propuesto se utiliza para realizar la predicción directa de la potencia generada basado solamente en datos históricos obtenidos en la planta fotovoltaica de la Universidad Central “Marta Abreu” de Las Villas. Los resultados obtenidos para un horizonte de predicción de mediano plazo y para diferentes épocas del año resultan acertados, lo que demuestra la efectividad del método de predicción propuesto.

**Palabras clave:** Planta fotovoltaica; Modelo planta fotovoltaica; Predicción potencia generada; Aprendizaje profundo.

## ABSTRACT

The objective of this work is to present the development of a dynamic model structure for the prediction of electricity generation in a photovoltaic plant. Traditionally, a model for the prediction of electricity generation in this type of plant is based on two models, one for the prediction of solar irradiance and a second model to

describe the relationship between solar irradiance and generated power. The main climatological variables considered are solar irradiation and ambient temperature, while from the technological point of view, the surface cleanliness of the solar panels is considered, as well as the operating point of the plant, depending on the period of the year and the time of day. The model presented considers solar irradiation and ambient temperature as input variables, while developing the non-linear modeling between irradiation and generated power, considering as disturbances the shading (partial or not) on the modules and the cleaning of the surface of the photovoltaic panels. The work presents a technological description of a plant and the temporal and frequency characterization of real data sets, from which the conception of the structure of the most suitable model for the application of techniques based on artificial intelligence, specifically deep learning, is developed. Finally, the proposed model is used to perform the direct prediction of the generated power based only on historical data obtained in the photovoltaic plant of the Central University "Marta Abreu" of Las Villas. The results obtained for a medium-term prediction horizon and for different times of the year are accurate, which demonstrates the effectiveness of the proposed prediction method.

**Keywords** Photovoltaic plant; Photovoltaic plant model; Generated power prediction; Deep learning.

---

## Introducción

La energía solar fotovoltaica constituye en la actualidad una de las más importantes fuentes de generación de energía eléctrica dentro del grupo de las energías limpias y renovables. La dependencia que tiene la energía eléctrica generada en un parque fotovoltaico de las condiciones meteorológicas, y la alta variabilidad de estas, hacen que el problema de la predicción de la energía generada en el mismo sea una labor compleja. Sobre todo, la naturaleza intermitente de la cobertura de nubes origina que, incluso para horizontes temporales pequeños, sea difícil asegurar cual va a ser exactamente el valor de la radiación solar incidente sobre el parque en cuestión (Jiménez 2014).

La previsión solar precisa elimina el impacto de la incertidumbre de la producción de energía solar fotovoltaica, mejora la estabilidad del sistema, aumenta el nivel de penetración del sistema fotovoltaico y reduce el costo de mantenimiento de los dispositivos auxiliares. La previsión de la energía solar fotovoltaica

ha surgido como una forma brillante de abordar estas cuestiones. Además, es una acción de gran importancia y ayuda a los operadores y diseñadores del sistema de energía a modelar y gestionar las plantas solares fotovoltaicas de manera eficiente (Ahmed et al. 2020).

Desde el propio surgimiento de las plantas fotovoltaicas prácticamente se han desarrollado variadas técnicas para lograr modelos predictivos que contribuyan al perfeccionamiento de la gestión de dichas plantas. Actualmente se trabaja intensamente en la aplicación de herramientas de la Inteligencia Artificial (IA) para el desarrollo de estos tipos de modelos, basado en la demostrada capacidad de estas técnicas en el manejo de información contenida en grandes volúmenes de datos obtenidos de los sistemas objeto de trabajo.

La planta fotovoltaica de la UCLV, en la provincia de Villa Clara, posee las características necesarias para realizar trabajos de desarrollo de modelos predictivos que puedan contribuir a lo antes planteado. En particular posee un amplio grupo de mediciones de las variables necesarias, tales como: irradiación solar, temperatura ambiente, temperatura de los módulos fotovoltaicos y potencia generada. Es decir, se tienen los elementos necesarios para realizar el estudio en esta planta. Por lo tanto, este trabajo tiene como objetivo principal presentar el desarrollo de una estructura de modelo dinámico para la predicción directa de la generación eléctrica en una planta fotovoltaica, específicamente en la planta fotovoltaica de la UCLV, basado solamente en datos históricos registrados en dicha planta sin necesidad de disponer de pronósticos meteorológicos de estas variables o de otros modelos para complementar la predicción.

Diferentes publicaciones internacionales han abordado el tema de la predicción de diferentes variables asociadas a sistemas fotovoltaicos. Varios trabajos utilizan un método de predicción indirecto de la potencia fotovoltaica generada, que se basa en realizar la predicción de algunos parámetros meteorológicos (fundamentalmente la irradiación solar) y posteriormente a partir de estas predicciones y mediante un modelo de la planta fotovoltaica que generalmente es un modelo paramétrico, realizan la predicción de la potencia fotovoltaica generada.

En la referencia (Qing, Niu 2018) se presenta un modelo basado en redes denominadas de gran memoria a corto plazo, identificadas por LSTM (por sus siglas en inglés) para la predicción de la irradiación solar del día siguiente mediante datos meteorológicos. Como entradas al modelo se consideran la temperatura, la humedad, la visibilidad, la velocidad del viento, el tipo de clima y el punto de rocío. El desempeño de este modelo resultó mejor que el de otros modelos basados en regresión del menor cuadrado lineal, (LLSR por sus

siglas en inglés) y basados en redes neuronales de alimentación directa, (FFNN por sus siglas en inglés) con un valor del error cuadrático medio (RMSE por sus siglas en inglés) menor de 18.34%.

Otros trabajos combinan modelos de predicción basados en técnicas de inteligencia artificial con modelos estadísticos o modelos físicos como el modelo de predicción numérica del tiempo (NWP por sus siglas en inglés).

En las referencias (Lima et al. 2016; Agoua, Girard, Kariniotakis 2018) se presenta una metodología estadística espacio-temporal para pronosticar la producción de energía de una planta específica desde unos pocos minutos hasta 6 horas más adelante. Se consideraron dos conjuntos de datos para dar cabida a diferentes condiciones climáticas y densidades espaciales de las plantas fotovoltaicas instaladas. El error cuadrático medio normalizado (nRMSE por sus siglas en inglés) se mejoró en un 20 % en comparación con otras técnicas de pronóstico.

La referencia (Massidda, Marrocu 2017) propone un modelo de predicción basado en la integración de ejes de regresión adaptativa multilinear con la predicción meteorológica numérica (NWP por sus siglas en inglés) para pronosticar la potencia generada en una planta fotovoltaica en el día siguiente. El modelo de regresión desarrollado utiliza datos históricos de producción de energía y los pronósticos meteorológicos disponibles del modelo NWP. Sobre la base del análisis de la simulación los resultados fueron favorables.

La referencia (Wolff et al. 2016) presenta un modelo de regresión de vectores de apoyo (SVR por sus siglas en inglés) para predecir la potencia de una planta fotovoltaica para un horizonte de tiempo de corto plazo de 15 minutos hasta 5 horas. Utiliza como entradas mediciones de potencia fotovoltaica y pronóstico de la irradiancia solar del NWP. El modelo es capaz de generar buenas predicciones para condiciones de cielo claro y nublado con un valor del RMSE menor de 15%. Los resultados obtenidos se comparan con un modelo físico. Por su parte la referencia (Sivaneasan, Yu, Goh 2017) presenta un modelo de predicción de la potencia fotovoltaica generada en una instalación fotovoltaica a largo plazo basado en redes neuronales artificiales y la lógica difusa. Utiliza como variables de entrada la temperatura, el punto de rocío, la velocidad y dirección del viento y la irradiación solar. El modelo propuesto se compara con otros modelos de predicción y en todos los casos presentó un comportamiento superior con un valor del porcentaje medio de error absoluto (MAPE por sus siglas en inglés) de 29.60 %.

En otras publicaciones se presentan varios modelos que permiten realizar una predicción directa de la potencia generada en la instalación fotovoltaica basado en el conocimiento de los datos históricos de la planta.

En la referencia (Raza et al. 2019) se desarrolla un modelo de predicción basado en un conjunto de redes neuronales, (NNE por sus siglas en inglés) entrenado mediante optimización por enjambre de partículas, (PSO por sus siglas en inglés) para predecir la potencia del día siguiente en una red inteligente. El modelo desarrollado utiliza como entradas datos históricos de la potencia fotovoltaica, la irradiancia solar, la velocidad del viento, la temperatura y la humedad. El desempeño del modelo fue medido contra otros cinco modelos de predicción y el modelo NNE resultó superior con un valor del MAPE de 9.75%.

La referencia (Jinsong Zhang et al. 2018) propone un modelo LSTM para predecir la potencia fotovoltaica. El modelo propuesto se compara con otros dos modelos y demostró ser el de mejor desempeño con un valor del RMSE menor de 21%.

Por su parte la referencia (Wen et al. 2019) presenta un modelo LSTM acoplado con una red neuronal profunda. El modelo se utiliza para predecir la carga y la potencia fotovoltaica generada en una red inteligente. El desempeño del modelo se compara con otros modelos y se obtiene un resultado satisfactorio con un valor del MAPE de 7.43 %.

En (Rui Zhang et al. 2018) se utiliza un modelo basado en redes neuronales de convolución profunda (DCNN por sus siglas en inglés) para predecir la potencia de una instalación fotovoltaica. La exactitud del modelo se compara con un modelo persistente y un modelo SVR resultando superior con un valor normalizado del MAPE de 11.80%.

Lo anterior demuestra una tendencia al empleo de técnicas de aprendizaje profundo en este tipo de trabajos de desarrollo de modelos predictivos por los resultados que se alcanzan.

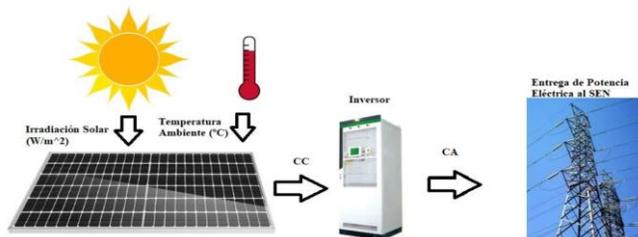
Inspirado en los antecedentes de investigación anteriores, en el presente trabajo se proponen dos modelos de predicción basados en técnicas de inteligencia artificial con aprendizaje profundo (LSTM y CNN) para realizar la predicción directa de la potencia fotovoltaica generada utilizando solamente un conjunto de mediciones históricas de la planta bajo estudio. Este trabajo se diferencia de los anteriores en la metodología utilizada y en la estructura del modelo predictivo que se propone para realizar la predicción de la potencia fotovoltaica generada, sin necesidad de disponer de predicciones de modelos meteorológicos o de otros modelos de predicción. También se diferencia en la estructura y el tratamiento de los datos históricos

recopilados. Además, el método de predicción propuesto permite obtener resultados satisfactorios en cuanto a la calidad de las predicciones realizadas.

## Metodología

### Características de la planta fotovoltaica

La planta fotovoltaica objeto de trabajo en esta investigación se encuentra localizada en la Universidad Central "Marta Abreu" de Las Villas. Esta planta posee una potencia nominal de 1.1 MW y fue puesta en marcha en el año 2019. La planta fotovoltaica está compuesta por 200 bandejas con sus correspondientes módulos de paneles fotovoltaicos conectados en serie y agrupadas en bloques, produciendo en conjunto los 700 V que necesitan los inversores para efectuar la conversión de corriente directa a corriente alterna. A su vez estos se conectan a una celda de mediana tensión que permite entregar toda la potencia generada a la red del Sistema Electroenergético Nacional (SEN). En la figura 1 se muestra un esquema general simplificado.



**Fig. 1** – Esquema general simplificado del PSFV de la UCLV.

[Fuente: Elaboración propia]

Los módulos de paneles solares empleados en este PSFV son de la serie HT72-166M con una potencia de salida seleccionable en un rango de 435 W a 455 W. En la arquitectura de la planta se emplean dos inversores de 500 kW de potencia activa, cada uno de tres fases con topología de circuito de puente completo (Beristáin Jimenez 2021) para la conversión de CC/CA, con un voltaje de entrada de 700 V de CC y de salida de 400 V de CA, su corriente de salida es de 720 A con una frecuencia de 60 Hz. Para monitorear el rendimiento energético de la instalación fotovoltaica se encuentra instalado un piranómetro (tipo SMP10), inclinado en el

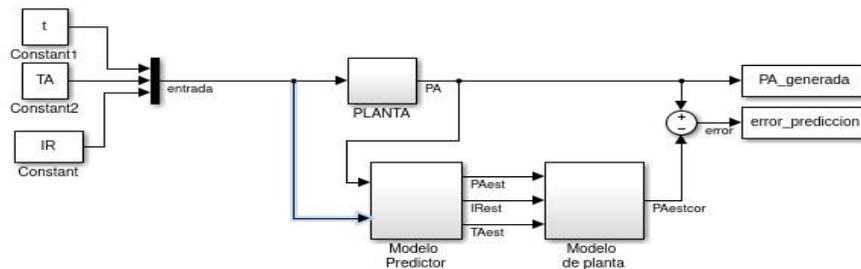
mismo ángulo que los paneles para medir la irradiación del plano de matriz, que es la irradiación total que reciben los paneles dada su inclinación. Este piranómetro, con un campo de visión de  $180^\circ$  y gama de medición hasta  $2000 \text{ W/m}^2$ .

También se encuentran instalados dos medidores de temperatura basados en sensores PT100. El primero de estos sensores está dedicado a la medición de la temperatura ambiental y el otro dedicado a la medición de la temperatura de los módulos de paneles. Para la medición de la potencia activa y reactiva que se entrega a la red eléctrica es empleado un medidor P2000 trifásico de clase 1.0 con altos valores de precisión.

### **Estructura del modelo predictivo**

La estructura más usada de predicción de potencia generada en plantas fotovoltaicas se basa fundamentalmente en dos modelos, uno para la estimación de la irradiación en un horizonte de predicción determinado, complementado con otro modelo, generalmente una ecuación estática, para calcular la potencia generada a partir de la irradiación estimada.

La idea de aplicar técnicas de inteligencia artificial es determinar un modelo global que se base además en los valores de la potencia generada, los cuales contienen toda la información del comportamiento de la planta en las condiciones reales de operación. La figura 2 muestra la estructura general del modelo propuesto para la predicción de la potencia generada y su relación con la planta fotovoltaica. Consiste en un modelo principal, con tres entradas independientes, la Irradiación  $IR$ , la temperatura del aire  $TA$  y el tiempo que transcurre,  $t$ ; y  $n$  valores pasados de la potencia real generada por la planta. A partir de esta entrada combinada, el modelo principal proporciona una predicción del comportamiento de la potencia generada,  $PA_{est}$ , de la irradiación estimada  $IR_{est}$  y la temperatura del aire  $TA_{est}$  para las próximas 24 horas.



**Fig. 2** – Estructura general del modelo de predicción.

[Fuente: Elaboración propia].

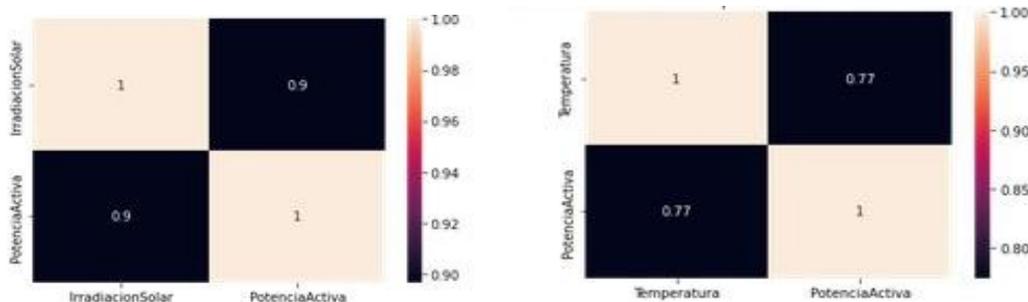
Se aplica un modelo auxiliar que describe el comportamiento tecnológico de la planta, con la misión de corregir la predicción realizada por el modelo principal, tomando en consideración otros disturbios que puedan estar presentes local y temporalmente. El error de predicción sería en base a la comparación de la potencia estimada corregida  $PA_{estcorr}$  con la potencia real generada.

### **Análisis de los datos para la obtención del modelo**

Se dispone de una base de datos que contiene mediciones de varias variables de interés por un período de tiempo de dos años. La principal variable del modelo digital es la irradiación solar porque influye de lleno en la generación de energía y físicamente es la fuente primaria de energía, la cual se convierte en energía eléctrica (Paulescu et al. 2013).

Otra entrada a tener en consideración es la variable temperatura ambiente la cual influye en la eficiencia de conversión de la energía solar-fotovoltaica en energía eléctrica (Paulescu et al. 2013). Para el desarrollo del modelo se obtuvieron los juegos de datos de la potencia activa, la temperatura ambiente y la irradiación solar de una base de datos SQL ubicada en el PSFV de la UCLV. Los datos comprenden las mediciones de estas tres variables en cada hora durante los años 2019 y 2020. En esta base de datos se pudo constatar pérdidas en las mediciones de los datos, para un total de 80 días (1920 juegos de datos) totalmente en blanco que se decidieron eliminar ya que afectaba el comportamiento de las tres variables; también se detectaron algunas mediciones nulas puntuales que se corrigieron mediante el procesamiento de los datos, así como valores

anormales en estas variables. Se pudo evidenciar la fuerte correlación existente entre las variables de entrada y la variable de salida utilizando la correlación de *Spearman*, ya que las relaciones entre las variables eran monótonas. En los resultados mostrados se observa que existe una fuerte correlación entre las variables de entrada y la variable de salida como se muestra en la figura 3.



**Fig. 3** – Matriz de correlación entre la Potencia Activa y la Irradiación Solar (izquierda) y – Matriz de correlación entre la Potencia Activa y la Temperatura Ambiente (derecha).

[Fuente: Elaboración propia].

### Obtención de la curva de comportamiento aproximada de la planta fotovoltaica

Es posible obtener una curva aproximada para la generación de potencia activa de la planta fotovoltaica en función de la irradiación solar. La figura 4 muestra un gráfico de dispersión de irradiación vs potencia activa y la curva aproximada de comportamiento para estos datos específicos.

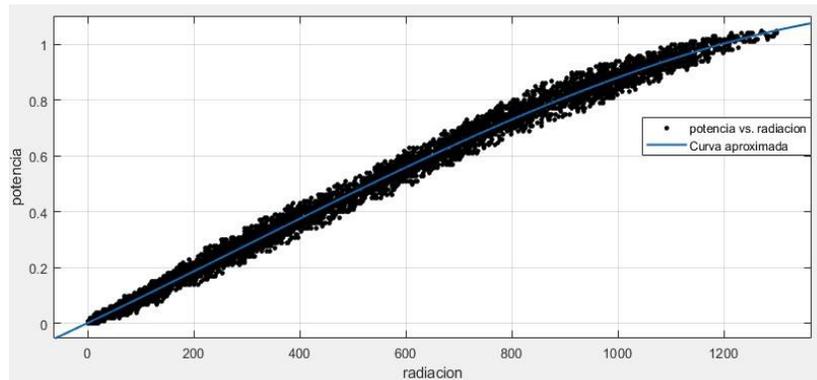
La ecuación de la curva está dada por la expresión (1):

$$P(r) = p_1r^3 + p_2r^2 + p_3r + p_4 \quad (1)$$

Donde:

- $P \rightarrow$  Potencia activa del parque (MW)
- $r \rightarrow$  Irradiación solar  $\left(\frac{W}{m^2}\right)$

Los valores de los coeficientes son:  $p_1 = -0.008589$ ,  $p_2 = -0.006695$ ,  $p_3 = 0.348$  y  $p_4 = 0.3612$ . En este caso el valor del RMSE es de 1.9%. Esta curva permite para determinados valores de irradiación solar obtener una aproximación bastante buena de la generación de potencia activa en la planta fotovoltaica analizada.

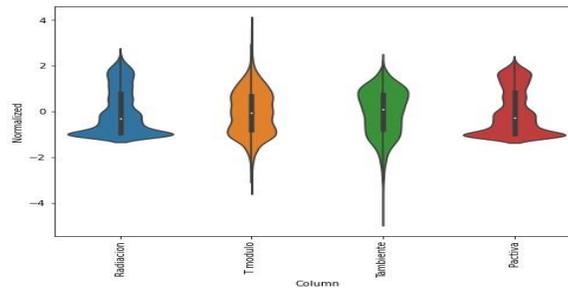


**Fig. 4** – Gráfico de dispersión de irradiación vs potencia y curva de comportamiento aproximada para el PSFV de la UCLV. [Fuente: Elaboración propia].

## Algoritmo predictivo

### Resultados y discusión de la aplicación del algoritmo predictivo

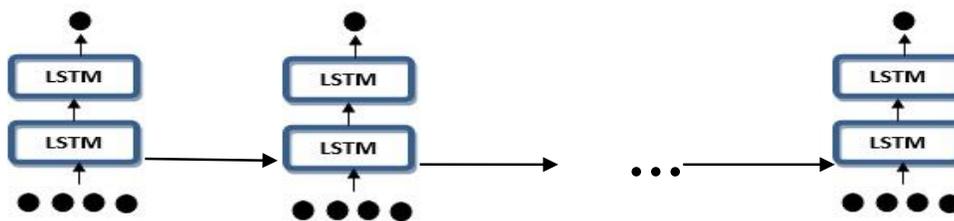
Se aplican los modelos de Redes Neuronales Profundas LSTM y CNN al problema de predicción de series temporales multivariado con múltiples pasos en el tiempo. Para la transformación de los datos se aplican varias etapas de preprocesamiento: se eliminan los atributos que no aportan información relevante para la predicción; se sustituyen los valores inconsistentes (nulos y no numéricos) por el valor promedio del atributo al que correspondiera y finalmente se estandarizaron los valores (Ver figura 5) para influir en igual medida en la predicción posibilitando que el modelo converja en menor cantidad de iteraciones.



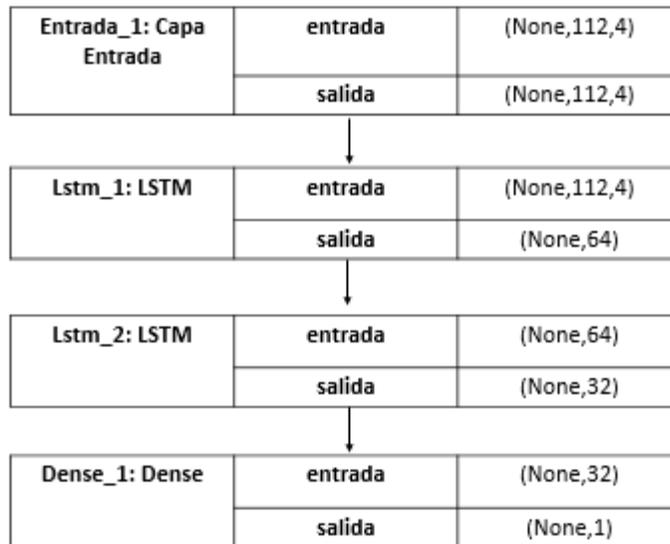
**Fig. 5** – Atributos estandarizados. [Fuente: Elaboración propia]

Para el entrenamiento y la prueba de ambos modelos se distribuyeron los datos de manera tal que el 80% se utilice para el entrenamiento y el 20 % para la prueba del modelo. A partir del conjunto de entrenamiento se crea una estructura de 112 entradas (Número de días pasados que se utilizan para predecir el futuro) lo que corresponde a 8 días con 14 mediciones cada día tomadas de (6:00 am – 8:00 pm) y un salto de 14 mediciones a predecir en el futuro.

En la figura 6 se muestra el primer modelo de red neuronal. La capa de entrada conformada por 4 neuronas que representan los atributos (Irradiación, Temperatura Ambiente, Temperatura Módulo, Potencia Activa) por cada una de las 112 horas presentes en cada ejemplo de entrenamiento, dos capas LSTM (Qing, Niu 2018), la primera con 64 neuronas y la segunda con 32 neuronas, la salida es la generación de energía del día siguiente pasadas las 112 horas (figura.7).

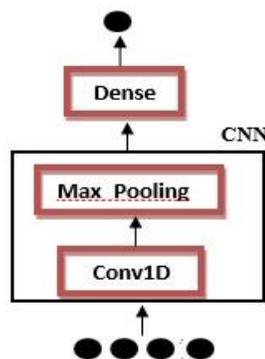


**Fig. 6** – Modelo LSTM. [Fuente: Elaboración propia]

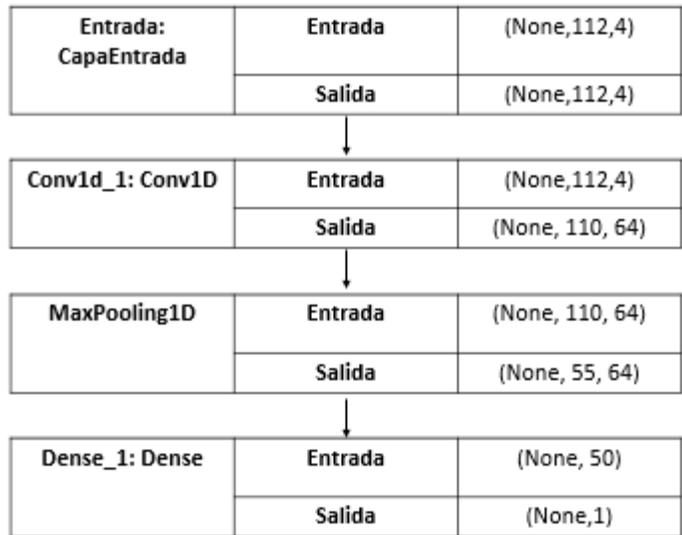


**Fig. 7** – Estructura por capa Modelo LSTM [Fuente: Elaboración propia]

La figura 8 representa el segundo modelo con una topología de red CNN (Rui Zhang et al. 2018) con una capa Convolutiva (Conv1D) de 1 dimensión de 64 filtros, seguida de una capa de reducción por agrupamiento (*max\_pooling*) con tamaño dos y una capa Densa de 50 neuronas. La capa de entrada igual a la de la figura 7.



**Fig. 8** – Modelo CNN. [Fuente: Elaboración propia]



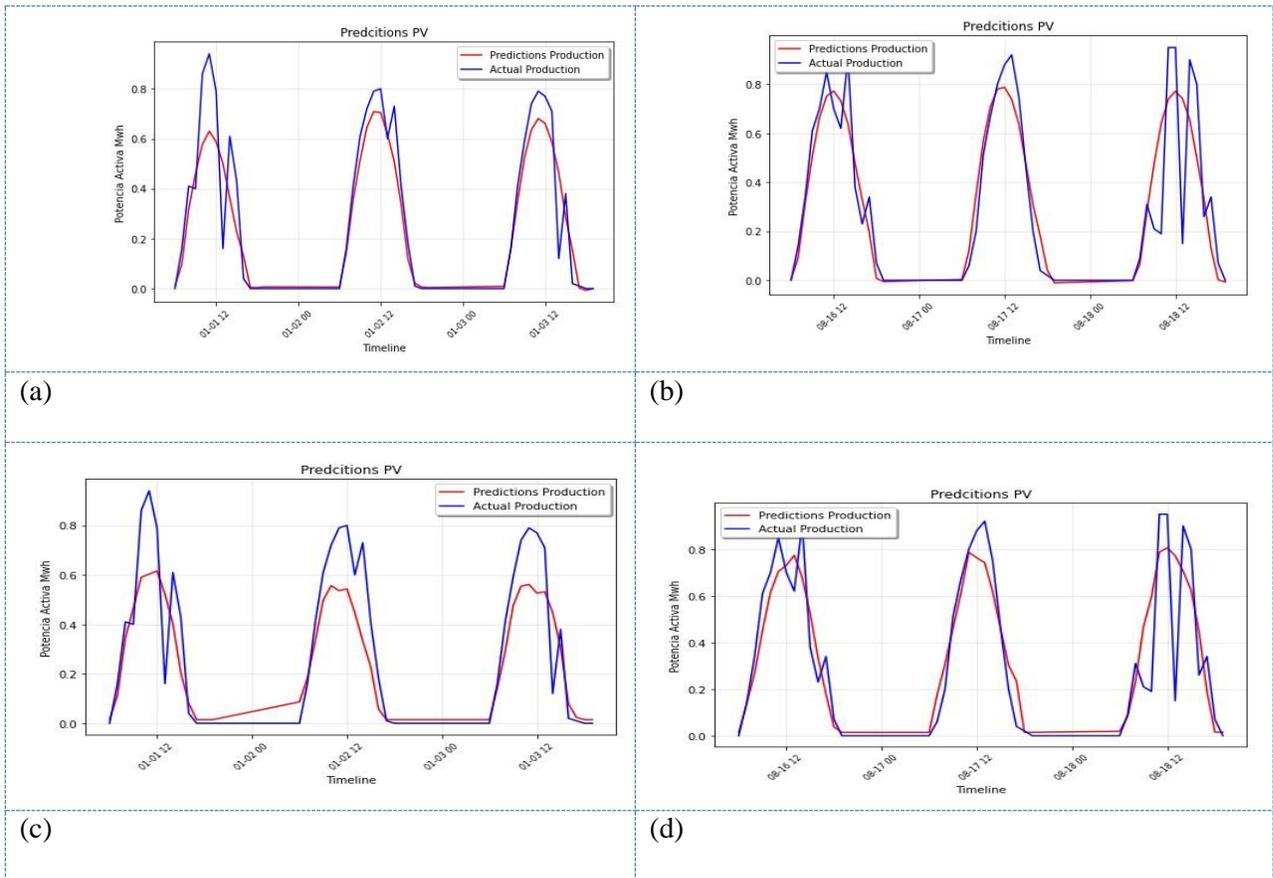
**Fig. 9** – Estructura por capa Modelo CNN [Fuente: Elaboración propia]

En la tabla 1 se muestra el error cuadrático medio de la predicción al aplicar los modelos representados en las figuras 7 y 9.

**Tabla 1** - Valores del error cuadrático medio (MSE). [Fuente: Elaboración propia].

| <b>Modelo</b> | <b>MSE (MW)</b> | <b>MSE (%)</b> | <b>MSE (kW)</b> |
|---------------|-----------------|----------------|-----------------|
| LSTM          | 0.0357          | 3.57           | 35.70           |
| CNN           | 0.0378          | 3.78           | 37.80           |

En la figura 10 se muestra la predicción (color rojo) y la producción real de potencia activa (color azul) para tres días consecutivos (en enero y agosto) de la planta fotovoltaica de la UCLV para los modelos LSTM y CNN respectivamente.



**Fig. 10** – Comparación ente la predicción de generación PV (color rojo) y los valores reales de generación PV (color azul).

[Fuente: Elaboración propia].

En este caso al tratarse de predicciones de más de 24 horas (se predicen tres días en el futuro) se pueden considerar como predicciones a largo plazo. En el caso (a) se utiliza el modelo LSTM para predecir los días 1, 2 y 3 de enero 2020. En el caso (b) se emplea nuevamente el modelo LSTM para predecir la generación de potencia activa en los días 16, 17 y 18 de agosto 2020. En el caso (c) se utiliza el modelo CNN para realizar la predicción en los días 1, 2 y 3 de enero 2020. En el caso (d) se emplea también el modelo CNN para realizar la predicción en los días 16, 17 y 18 de agosto 2020. En cada uno de los casos se utiliza 8 días anteriores para la predicción.

Los resultados obtenidos muestran que ambos modelos presentan un comportamiento acertado, aunque de manera general el modelo LSTM presenta un mejor comportamiento que el modelo CNN. Puede decirse que las predicciones realizadas para días con diferente comportamiento (soleado, nublado, parcialmente nublado) y para distintas épocas del año (invierno y verano) resultan adecuadas en ambos casos analizados, lo que demuestra la efectividad de los modelos de predicción utilizados.

## Conclusiones

A partir de los resultados obtenidos en este trabajo se comprueba la factibilidad de determinar una estructura de modelo dinámico para la predicción de la generación eléctrica en una planta fotovoltaica, partiendo directamente de los datos de generación reales obtenidos en la planta bajo estudio. El estudio realizado demuestra la necesidad de realizar primero una correcta descripción tecnológica de la planta fotovoltaica para la cual se desarrollará el modelo predictivo, así como una caracterización temporal y frecuencial de los datos disponibles. Se demuestra que diferentes estructuras de modelos predictivos basados en técnicas de inteligencia artificial, específicamente con aprendizaje profundo (en este caso modelo LSTM y modelo CNN) cumplen con el objetivo de obtener predicciones con un buen cumplimiento del criterio de exactitud, implicando con ello que las predicciones en diferentes períodos de tiempo y épocas del año resultan adecuadas con valores pequeños del error de predicción (MSE) en cada uno de los casos analizados.

La principal contribución del trabajo radica en el desarrollo de un modelo de predicción que resulta aplicable en cualquier planta fotovoltaica que disponga de las mediciones necesarias, considerando importante que los datos tomados experimentalmente, para el entrenamiento de los modelos que se desarrollen tengan una buena calidad.

## Referencias

- Agoua, Xwegnon Ghislain, Girard, Robin Y Kariniotakis, George, 2018. Short-Term Spatio-Temporal Forecasting Of Photovoltaic Power Production. *Ieee Transactions On Sustainable Energy* [En Línea]. Abril 2018. Vol. 9, No. 2, P. 538-546. Doi 10.1109/Tste.2017.2747765.
- Ahmed, R., Sreeram, V., Mishra, Y. Y Arif, M.D., 2020. A Review And Evaluation Of The State-Of-The-Art In Pv Solar Power Forecasting: Techniques And Optimization. *Renewable And Sustainable Energy Reviews* [En Línea]. Mayo 2020. Vol. 124, P. 109792. Doi 10.1016/J.Rser.2020.109792.
- Beristáin Jimenez, J A, 2021. *Propuesta Del Inversor Bidireccional Multinivel Con Aislamiento En Alta Frecuencia Utilizando Las Topologías De Puente Completo/Medio Puente* [En Línea]. 17 Diciembre 2021. <https://www.tdx.cat/bitstream/handle/10803/6336/06jabj06de10.pdf;sequence=6>inversores
- Jiménez, A M, 2014. *Modelos De Predicción A Corto Plazo De La Generación Eléctrica En Instalaciones Fotovoltaicas*. Doctoral. Universidad De La Rioja.
- Lima, Francisco J.L., Martins, Fernando R., Pereira, Enio B., Lorenz, Elke Y Heinemann, Detlev, 2016. Forecast For Surface Solar Irradiance At The Brazilian Northeastern Region Using Nwp Model And Artificial Neural Networks. *Renewable Energy* [En Línea]. Marzo 2016. Vol. 87, P. 807-818.. Doi 10.1016/J.Renene.2015.11.005.
- Massidda, Luca Y Marrocu, Marino, 2017. Use Of Multilinear Adaptive Regression Splines And Numerical Weather Prediction To Forecast The Power Output Of A Pv Plant In Borkum, Germany. *Solar Energy* [En Línea]. Abril 2017. Vol. 146, P. 141-149. Doi 10.1016/J.Solener.2017.02.007.
- Paulescu, Marius, Paulescu, Eugenia, Gravila, Paul Y Badescu, Viorel, 2013. *Weather Modeling And Forecasting Of Pv Systems Operation*. London: Springer London. Green Energy And Technology. Isbn 978-1-4471-4648-3.
- Qing, Xiangyun Y Niu, Yugang, 2018. Hourly Day-Ahead Solar Irradiance Prediction Using Weather Forecasts By Lstm. *Energy* [En Línea]. Abril 2018. Vol. 148, P. 461-468. [Accedido 17 Diciembre 2021]. Doi 10.1016/J.Energy.2018.01.177.
- Raza, Muhammad Qamar, Mithulananthan, Nadarajah, Li, Jiaming, Lee, Kwang Y. Y Gooi, Hoay Beng, 2019. An Ensemble Framework For Day-Ahead Forecast Of Pv Output Power In Smart Grids. *Ieee*

*Transactions On Industrial Informatics*, Agosto 2019. Vol. 15, No. 8, P. 4624-4634.  
Doi 10.1109/Tii.2018.2882598.

Sivaneasan, B., Yu, C.Y. Y Goh, K.P., 2017. Solar Forecasting Using Ann With Fuzzy Logic Pre-Processing. *Energy Procedia*. Diciembre 2017. Vol. 143, P. 727-732. Doi 10.1016/J.Egypro.2017.12.753.

Wen, Lulu, Zhou, Kaile, Yang, Shanlin Y Lu, Xinhui, 2019. Optimal Load Dispatch Of Community Microgrid With Deep Learning Based Solar Power And Load Forecasting. *Energy*, Marzo 2019. Vol. 171, P. 1053-1065. Doi 10.1016/J.Energy.2019.01.075.

Wolff, Björn, Kühnert, Jan, Lorenz, Elke, Kramer, Oliver Y Heinemann, Detlev, 2016. Comparing Support Vector Regression For Pv Power Forecasting To A Physical Modeling Approach Using Measurement, Numerical Weather Prediction, And Cloud Motion Data. *Solar Energy*. Octubre 2016. Vol. 135, P. 197-208. Doi 10.1016/J.Solener.2016.05.051.

Zhang, Jinsong, Verschae, Rodrigo, Nobuhara, Shohei Y Lalonde, Jean-François, 2018. Deep Photovoltaic Nowcasting. *Solar Energy*, Diciembre 2018. Vol. 176, P. 267-276. Doi 10.1016/J.Solener.2018.10.024.

Zhang, Rui, Feng, Minwei, Zhang, Wei, Lu, Siyuan Y Wang, Fei, 2018. Forecast Of Solar Energy Production - A Deep Learning Approach. En: *2018 Ieee International Conference On Big Knowledge (Icbk)*. Singapore: Ieee. Noviembre 2018. P. 73-82. Isbn 978-1-5386-9125-0.

### **Conflicto de interés**

Los autores autorizan la distribución y uso de su artículo.

### **Contribuciones de los autores**

1. Conceptualización: Reinier Herrera Casanova.
2. Curación de datos: Reinier Herrera Casanova, Jesús Gabriel García Tamayo
3. Análisis formal: Francisco B. Herrera Fernández.
4. Adquisición de fondos: Francisco B. Herrera Fernández.
5. Investigación: Reinier Herrera Casanova, Beatriz Bello García.

6. Metodología: Reinier Herrera Casanova
7. Administración del proyecto: Francisco B. Herrera Fernández.
8. Recursos: Lesyani León Viltres
9. Software: Beatriz Bello García
10. Supervisión: Lesyani León Viltres
11. Validación: Reinier Herrera Casanova
12. Visualización: Jesús Gabriel García Tamayo

### **Financiación**

Este artículo ha estado soportado por el proyecto nacional “Perfeccionamiento de los sistemas de pronósticos energéticos para plantas eólicas y fotovoltaicas conectadas al Sistema Electroenergético Nacional (SEN)”. Proyecto asociado al Programa Nacional Desarrollo Energético Integral y Sostenible