

Impacto de la Inteligencia Artificial en los portadores energéticos de ETECSA

Impact of Artificial Intelligence on ETECSA's energy carriers

Yainiel Martínez Fresneda^{I*}, Miguel Castro Fernández^{II}

^IEmpresa de Telecomunicaciones de Cuba S.A, ETECSA. La Habana, Cuba

^{II}Universidad Tecnológica de La Habana José Antonio Echeverría, Cujae. Cuba

*Autor de correspondencia: yainimf@gmail.com

Recibido: 2 de marzo de 2025

Aprobado: 23 de mayo de 2025

Este documento posee una [licencia Creative Commons Reconocimiento-NoComercial 4.0 internacional](https://creativecommons.org/licenses/by-nc/4.0/)



RESUMEN/ABSTRACT

La interconexión de las instalaciones fotovoltaicas a los sistemas eléctricos, demanda disponer de herramientas para la predicción de la generación eléctrica. El conocimiento anticipado de la generación de potencia eléctrica permite una mejor planificación para los operadores de los parques fotovoltaicos y los del Sistema Electroenergético Nacional. Con el propósito de contribuir a la planificación de los portadores energéticos de la Empresa de Telecomunicaciones de Cuba S.A, el autor se trazó como objetivo general, el desarrollo de una herramienta basada en técnicas de inteligencia artificial en el programa Matlab, para predecir la generación eléctrica diaria del sistema fotovoltaico instalado en uno de sus Centros Telefónicos a partir de las variables meteorológicas: temperatura ambiente, humedad relativa, nubosidad, velocidad del viento e irradiancia solar. Los resultados de la red fueron validados mediante su comparación con datos experimentales, y la obtención de indicadores estadísticos considerados como buenos para este tipo de herramienta.

Palabras clave: inteligencia artificial, generación eléctrica, sistema fotovoltaico, herramienta, Matlab.

The interconnection of photovoltaic installations to electrical systems requires tools for predicting electricity generation. Advance knowledge of electrical power generation allows for better planning for photovoltaic park operators and those of the National Electric Power System. With the aim of contributing to the planning of energy carriers for the Cuban Telecommunications Company S.A., the author's general objective was to develop a tool based on artificial intelligence techniques in the Matlab program to predict daily electricity generation from the photovoltaic system installed in one of its Call Centers based on meteorological variables: ambient temperature, relative humidity, cloud cover, wind speed, and solar irradiance. The network results were validated by comparing them with experimental data, and obtaining statistical indicators considered satisfactory for this type of tool.

Keywords: artificial intelligence, electricity generation, photovoltaic system, tool, Matlab.

INTRODUCCIÓN

En el contexto de la transición hacia un modelo energético más sostenible, la energía solar fotovoltaica ha emergido como una alternativa destacada por su capacidad de transformar la radiación solar en electricidad sin emisiones contaminantes. No obstante, pese a sus múltiples beneficios, esta tecnología enfrenta desafíos importantes. Entre ellos, la intermitencia representa un obstáculo clave, ya que la disponibilidad de radiación solar varía a lo largo del día y según las condiciones meteorológicas, lo que repercute directamente en la estabilidad de la producción energética.

Cómo citar este artículo:

Yainiel Martínez Fresneda y Miguel Castro Fernández. Impacto de la Inteligencia Artificial en los portadores energéticos de ETECSA. Ingeniería Energética. Vol. 46(2025): publicación continua. ISSN 1815-5901.

Sitio de la revista: <https://rie.cujae.edu.cu/index.php/RIE/index>

En la última década, las redes neuronales han cobrado protagonismo como una herramienta eficaz para la predicción de la generación eléctrica, permitiendo mejorar la integración de los sistemas fotovoltaicos con los sistemas electroenergéticos. En el año 2022 S.-C. Lim [1], propuso un modelo híbrido basado en redes neuronales convolucionales (CNN) y redes de memoria a largo plazo (LSTM) para la predicción de la generación de energía. La CNN se utiliza para clasificar los días como soleados o nublados, y luego se entrena un modelo LSTM específico para cada tipo de día, utilizando únicamente datos históricos de producción de energía, sin incluir variables meteorológicas. El rendimiento del modelo se evaluó mediante la métrica MAPE (Mean Absolute Percent Error, por sus siglas en inglés), obteniendo un error de 4,58 % para días soleados y 7,06 % para días nublados, lo que demuestra buena precisión, especialmente en condiciones estables.

Sin embargo, el método presenta como desventaja fundamental que su dependencia exclusiva de datos históricos de generación puede limitar su capacidad de adaptación ante condiciones climáticas imprevistas. En el año 2023 N. Sharma [2], empleó un perceptrón multicapa (una capa oculta) entrenado con backpropagation usando gradiente descendente (GD) y Levenberg–Marquardt (LM). Usaron datos de un panel solar de 100 W en Peer Panjal (India), midiendo irradiancia, temperatura ambiente y humedad con una resolución temporal de milisegundos durante cuatro meses. Las métricas de error fueron RMSE (Root Mean Square Error, por sus siglas en inglés), MAE (Mean Absolute Error, por sus siglas en inglés) y coeficiente de determinación R (rango 0,98–0,99). El modelo con LM superó al realizado con GD clásico, logrando concordancias muy altas, evidenciando predicción fiable. Sin embargo, la dependencia de datos de alta resolución temporal puede limitar su aplicación en escenarios donde tales datos no estén disponibles.

En el año 2023 X. Xiang [3], propuso un modelo híbrido que combina redes neuronales convolucionales temporales (TCN), una red de atención eficiente por canal (ECANet) y unidades recurrentes con compuertas (GRU) para mejorar la precisión de las predicciones. Para validar el modelo, se utilizaron datos de una planta de energía fotovoltaica en Australia, recolectados entre diciembre de 2018 y noviembre de 2019. Las variables de entrada incluyeron velocidad del viento, temperatura, dirección del viento, radiación horizontal global, precipitación diaria, velocidad máxima del viento y presión atmosférica, todas registradas a intervalos de cinco minutos. Los resultados mostraron que el modelo TCN-ECANet-GRU superó a otros modelos de referencia en todas las estaciones del año. Sin embargo, la complejidad del modelo híbrido puede requerir recursos computacionales significativos para su entrenamiento e implementación.

En este año 2025, en el trabajo de L. Kahana [4], emplearon algoritmos genéticos (AG) para ajustar los hiperparámetros de una FF-ANN para predicción solar. El modelo GA-FFANN se entrenó con datos reales de una planta fotovoltaica y demostró gran precisión: obtuvo $RMSE \approx 20$ W y $R \approx 0,9985$ en un día de prueba, superando métodos de referencia. Estos resultados muestran que la optimización con AG mejora la exactitud de redes FF-ANN clásicas. Sin embargo, la complejidad computacional asociada con la optimización de hiperparámetros mediante AG puede ser significativa, especialmente para conjuntos de datos grandes o en aplicaciones en tiempo real. En este año 2025, U. Ahmed [5], ofrece una contribución significativa al campo de la predicción de la irradiancia solar, proponiendo un *Parallel Boosting Neural Network* que combina modelos de árbol (XGBoost, CatBoost, Random Forest) cuyas salidas entran a una FFNN logrando mejoras en la precisión de las predicciones.

Se entrenó con datos diarios meteorológicos de irradiancia de la NASA para Islamabad (2010–2021) y San Diego (2016–2021). Se evaluó con las métricas RMSE, MAE, MSE, MAPE y NRMSE. Sin embargo, las consideraciones sobre la complejidad computacional y la necesidad de datos extensos deben tenerse en cuenta al aplicar este enfoque en entornos prácticos. El uso de herramientas basadas en inteligencia artificial tiende hacia el uso de modelos complejos y computacionalmente intensivos para la predicción de generación de energía fotovoltaica. En este trabajo se demuestra que es posible obtener resultados competitivos en términos de precisión mediante una red neuronal de arquitectura más sencilla.

La propuesta se enfoca en reducir significativamente la exigencia de recursos computacionales sin comprometer el desempeño del modelo, logrando métricas de error comparables a otros trabajos reportados en la literatura. Esta simplicidad estructural no solo facilita la implementación del modelo en dispositivos con capacidad limitada, sino que también reduce los tiempos de entrenamiento e inferencia. A continuación, se esbozan los conceptos fundamentales que permitieron establecer y delimitar el modelo para la obtención de la red neuronal artificial que se propone en este trabajo.

Tipos de predicción de potencia

Varios enfoques se han tomado para desarrollar modelos de predicción de potencia fotovoltaica. La clasificación de modelos de predicción de potencia se puede hacer según la variable que se predice, según el horizonte de predicción, y según el método utilizado para predecir.

- Según su variable de predicción. Inicialmente, los modelos de predicción de potencia se hicieron tomando como variable para predecir la irradiancia, y a partir de distintas expresiones que relacionan la irradiancia con la potencia, llegar a un valor futuro de potencia. Este tipo de predicción se conoce como predicción indirecta. Cuando el algoritmo de predicción tiene como variable de salida la potencia, al modelo se le denomina de predicción directa. Por estudios previos se conoce que la predicción directa entrega modelos con errores menores [6]. La ventaja de la predicción indirecta se encuentra en los sistemas recién instalados, donde no se cuenta con datos de producción, pero sí con datos meteorológicos.
- Según su horizonte de predicción. El horizonte de predicción es esa ventana de tiempo entre el último dato medido y aquel que se desea predecir. Existen las mediciones de corto, mediano y largo plazo, y dependiendo del uso que se le vaya a dar al valor predicho, se recomiendan unos u otros plazos para la predicción. En la actualidad no existe una regla general que sirva para decir qué tipo de algoritmo entrega mejores resultados en cada uno de los tiempos de predicción [6].

Los tipos de horizonte de predicción son los siguientes:

- Corto plazo. Es el pronóstico de la potencia fotovoltaica que se realiza durante una hora, varias horas, un día o hasta siete días. La predicción a corto plazo de la energía fotovoltaica garantiza la programación, la planificación de cargas a abastecer y el envío de energía eléctrica. Este tipo de predicción es útil para diseñar un sistema integrado de gestión de energía fotovoltaica. El pronóstico a corto plazo también mejora la seguridad de la operación de la red.
- Mediano plazo. Esta predicción es de más de una semana a un mes. Este tipo de pronóstico ayuda a mejorar la planificación de mantenimientos y a predecir la disponibilidad de energía eléctrica en el futuro.
- Largo plazo. Los pronósticos de energía fotovoltaica de más de un mes a un año se consideran de largo plazo. La utilidad de tener este tipo de predicciones se encuentra en la mejora de la planificación de generación, transmisión y distribución de la electricidad generada, aparte de la licitación de energía y la operación de seguridad.
- Además de los plazos antes mencionados, existe otra categoría denominada predicción a muy corto plazo (nowcasting) que predice para horizontes temporales entre uno y varios minutos [7]. Este tipo de predicción a muy corto plazo sirve para suavizar el despacho de energía a tiempo real.
- Según su método de predicción. Las predicciones que utilizan datos históricos de variables ambientales y de energía generada por paneles solares, se pueden dividir según su método o algoritmo de predicción (ver figura 1).

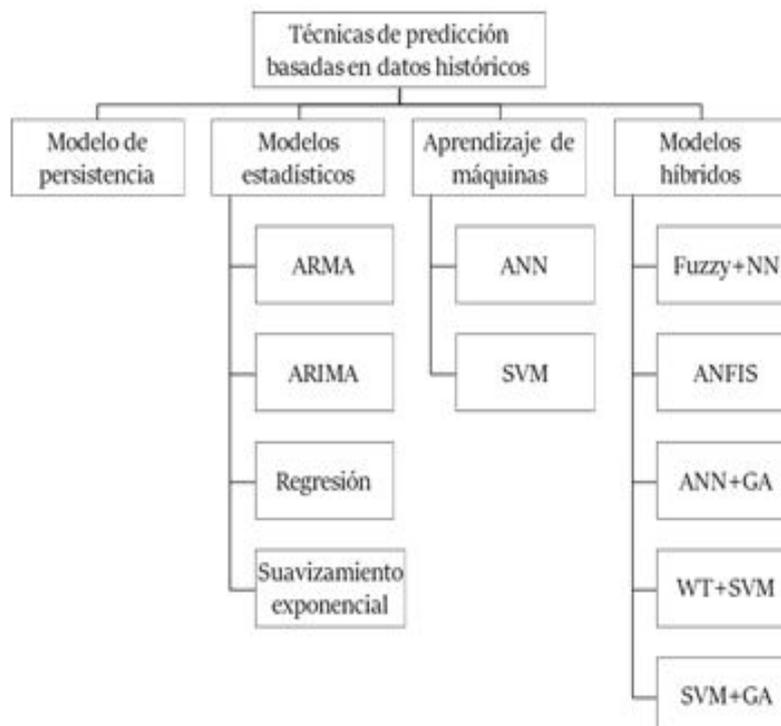


Fig. 1. Técnicas de predicción. Fuente [6]

- Modelo de Persistencia. El método más sencillo es el de persistencia. El método de persistencia es utilizado hoy en día como una base para comparar los modelos de predicción hechos con otros métodos más avanzados. El modelo de persistencia consiste en asumir que el siguiente valor de potencia, será igual al del día anterior a una hora similar. Evidentemente, no todos los días las condiciones climáticas son iguales, y esto lleva a un error, pero el método de persistencia tiene como ventaja su simplicidad matemática [6].

- Modelos Estadísticos. Los modelos estadísticos como ARIMA y SARIMA son herramientas ampliamente utilizadas para la predicción de series temporales debido a su capacidad para modelar patrones lineales y estacionales en datos históricos. Estos modelos proporcionan resultados interpretables y precisos cuando los datos son estacionarios y presentan comportamientos estables, lo que los hace especialmente útiles en aplicaciones como la planificación y gestión de recursos. Sin embargo, su desempeño puede verse limitado por la necesidad de transformaciones previas para lograr la estacionariedad, así como por su incapacidad para capturar relaciones no lineales o adaptarse a cambios estructurales repentinos en las series temporales. Además, la correcta selección de los parámetros del modelo es crítica y puede ser compleja, incrementando el riesgo de sobreajuste en conjuntos de datos pequeños o muy estacionales. Estas limitaciones han llevado a que se complementen o sustituyan por técnicas más flexibles como el aprendizaje automático en escenarios más complejos [8].
- Aprendizaje de máquinas. Dentro de los métodos de aprendizaje de máquinas los algoritmos más comunes son Redes Neuronales Artificiales (RNA), Máquinas de Soporte Vectorial (SVM), Árboles de Decisión (RF), Algoritmos Genéticos (GA), y algoritmos de agrupamiento. Sin embargo, para desarrollar modelos de regresión que luego sirven para hacer pronósticos de potencia se utilizan con más frecuencia las RNA y SVM [6]. La combinación de estos algoritmos brinda modelos con mayor precisión llamados modelos híbridos.
- Las redes neuronales artificiales consisten en un modelo matemático basado en el sistema nervioso biológico, formado por un gran número de elementos simples que procesan información mediante su estado dinámico como respuesta a entradas externas.

Redes Neuronales Artificiales

Las RNA consisten en una arquitectura multicapa conformada por una capa de entrada, varias capas ocultas y una capa de salida, donde cada neurona está interconectada mediante pesos ajustables que permiten el aprendizaje de patrones complejos en los datos. La modelación de una RNA incluye etapas fundamentales: la recopilación, preparación y limpieza de los datos para optimizar el entrenamiento; la selección de la arquitectura adecuada: que involucra la determinación del número de capas, neuronas y funciones de activación; el proceso de entrenamiento mediante algoritmos que ajustan los pesos para minimizar la función de error; y finalmente, la evaluación del modelo para verificar su capacidad de generalización con datos no vistos. Estas fases son críticas para asegurar que la red aprenda eficientemente y sea capaz de resolver problemas complejos en diversas áreas, como clasificación y predicción [9]. La desventaja fundamental de las RNA radica en la necesidad de disponer de gran cantidad de datos para el proceso de entrenamiento.

Redes neuronales MLP (Perceptrón Multicapa)

Las redes neuronales multicapa (MLP) son una clase de redes neuronales artificiales ampliamente utilizadas en tareas de regresión y clasificación debido a su capacidad para aproximar funciones no lineales complejas. Una MLP se compone de al menos tres capas: una capa de entrada, una o más capas ocultas, y una capa de salida. Cada capa está formada por nodos (neuronas) que están completamente conectados a las neuronas de la capa anterior y posterior. La información se transmite en una sola dirección, desde la entrada hasta la salida, sin ciclos, lo que caracteriza a estas redes como FeedForward (FF) [10]. Las neuronas en cada capa aplican una función de activación, como la ReLU o la Sigmoide, que introduce no linealidad en el modelo y permite aprender relaciones complejas.

Durante el entrenamiento, el modelo ajusta los pesos de las conexiones utilizando algoritmos como el descenso por gradiente, con la ayuda del método de retropropagación (backpropagation), que calcula el error cometido en la salida y lo propaga hacia atrás para actualizar los pesos [11]. Las MLP son valoradas por su simplicidad y eficacia en múltiples aplicaciones, desde el reconocimiento de patrones hasta la predicción de series temporales. Sin embargo, su rendimiento depende de varios factores clave, como la cantidad de capas ocultas, el número de neuronas por capa, la calidad del preprocesamiento de los datos y la elección de hiperparámetros. Aunque no son tan profundas como las redes convolucionales o recurrentes modernas, siguen siendo una herramienta versátil y eficiente cuando se usan correctamente [12].

Tipos de Aprendizaje de las Redes Neuronales Artificiales

El método de aprendizaje se refiere a la etapa en la que la red neuronal adquiere la capacidad de ejecutar y mostrar los resultados según el propósito con el que esté siendo diseñada. Existen dos tipos de aprendizaje.

- Aprendizaje supervisado. El aprendizaje supervisado es un enfoque en el cual un modelo de red neuronal se entrena utilizando un conjunto de datos etiquetados, donde cada entrada está asociada a una salida deseada. El objetivo es que la red aprenda la relación entre las entradas y las salidas para poder predecir resultados en datos no vistos [13].

- Aprendizaje no supervisado. El aprendizaje no supervisado se caracteriza por el uso de datos no etiquetados, donde el modelo busca identificar patrones y estructuras subyacentes sin supervisión explícita. Este enfoque es útil para tareas como agrupamiento (clustering), reducción de dimensionalidad y detección de anomalías. Los modelos de redes neuronales en este contexto, como los mapas autoorganizados (SOM) y los autoencoders, aprenden representaciones de los datos sin necesidad de etiquetas, permitiendo descubrir relaciones y estructuras en los datos de entrada [14].

Para este trabajo se definió que el modelo realice una predicción directa (potencia), con un horizonte de predicción corto (24 horas de antelación), basado en redes neuronales artificiales del tipo MLP, a través de un aprendizaje supervisado.

MATERIALES Y MÉTODOS

En la Empresa de Telecomunicaciones de Cuba SA (ETECSA), la instalación de sistemas fotovoltaicos en cubiertas de Centros de Telecomunicaciones ha ido en aumento en los últimos años. El uso de la Inteligencia Artificial como una herramienta de predicción de potencia eléctrica generada por sistemas fotovoltaicos y su aplicación en Centros Telefónicos u otros edificios de la Empresa, contribuirá con una mejor gestión de los planes energéticos diarios y mensuales. Con la inserción y desarrollo de esta herramienta se puede incidir directamente en un mejor aprovechamiento de las jornadas laborales, en el aumento de los niveles de producción y en un mejor uso de los equipos de climatización.

En este trabajo, se utiliza el programa informático Matlab para el entrenamiento de una RNA, a partir de los datos experimentales obtenidos con el Sistema Fotovoltaico Conectado a Red (SFCR) del Centro Telefónico (CT) de Minas, en complemento con los datos de archivo del Instituto de Meteorología (INSMET). El sistema está compuesto por 16 paneles de 295 Wp, un inversor de 5 kW y el sistema de protecciones (ver figura 2). Con el entrenamiento de esta RNA se obtiene como variable de salida un valor de generación eléctrica diaria que podrá ser considerado por los Portadores Energéticos del CT Minas para la toma de decisiones. Los datos con los que se realiza el entrenamiento pertenecen al periodo de tiempo comprendido entre los meses de mayo y septiembre, por lo que la herramienta solo será válida en igual espacio de tiempo.



Fig. 2. Sistema Fotovoltaico instalado en la cubierta del CT Minas

Modelación del Modelo Matemático

1. Variables de entrada y tratamiento de datos: Durante el proceso de recopilación y análisis de datos se valoraron hasta ocho variables meteorológicas de entrada. A cada una de estas variables, se les realizó un análisis de correlación respecto a la variable de salida para determinar su impacto en el desempeño del sistema fotovoltaico. Finalmente, se definieron como variables meteorológicas de entrada: la temperatura media ambiente, la humedad relativa media, la nubosidad media, la velocidad del viento y la irradiancia solar. Como parte del tratamiento y limpieza de datos se eliminaron los pertenecientes a los días en que hubo fallo del suministro eléctrico, pues por la configuración propia del sistema, ante la ausencia del suministro de la red comercial el sistema fotovoltaico se desconecta, disminuyendo el aporte de potencia del sistema debido a las horas de fallo. Es indispensable este paso en el entrenamiento de la red, pues de esta manera, se consiguió trabajar con datos que reflejaran el verdadero comportamiento del sistema.
2. Selección y configuración de la red: El modelo matemático se desarrolló en MATLAB R2020a, a través del Toolbox nntool. Mediante los distintos cuadros de diálogo del Toolbox se determina la configuración de la RNA: matrices de datos (entradas y salidas) de los cuales la red neuronal aprenderá (ver figura 3); tipo de red neuronal, método de aprendizaje y funciones de transferencia (ver figura 4); y los parámetros que definen el entrenamiento y convergencia de la red (cantidad de iteraciones máximas, factores para hallar el error mínimo, entre otros). Ver figura 5.

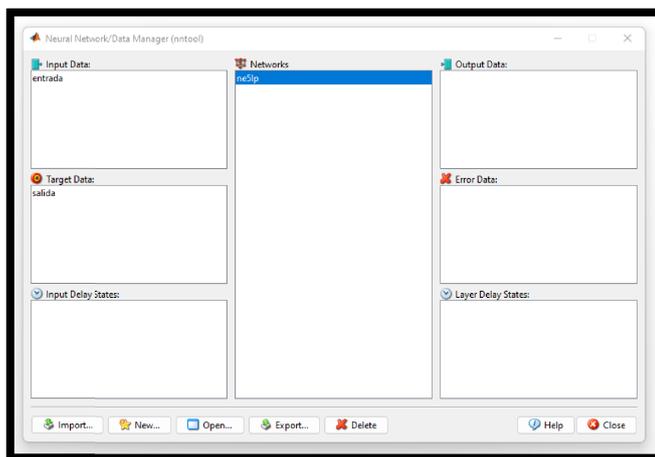


Fig. 3. Ventana de creación de la red y asignación de los vectores de entrada y salida

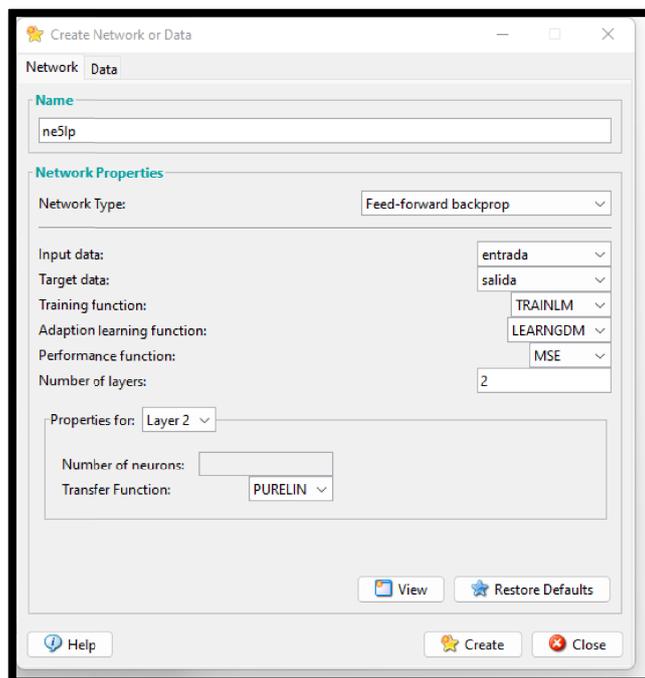


Fig. 4. Configuración del método de aprendizaje, cantidad de neuronas por capa y funciones de transferencia

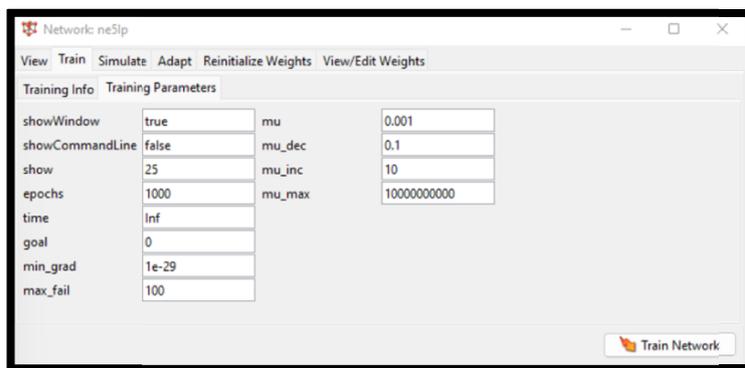


Fig. 5. Parámetros de convergencia del modelo matemático

La red neuronal contará con cinco neuronas en su capa de entrada (cantidad correspondiente a las variables de entrada), cinco neuronas en la capa oculta, y una neurona en la capa de salida (correspondiente a la variable de salida) (ver figura 6). La cantidad de neuronas en la capa oculta se determinó por el método de prueba y error, después de realizar diversas iteraciones aumentando el número de neuronas desde dos hasta diez, obteniéndose los mejores resultados con cinco neuronas en la capa oculta. Las funciones de transferencia que mejor se ajustaron a la red fueron logsig / purelin.

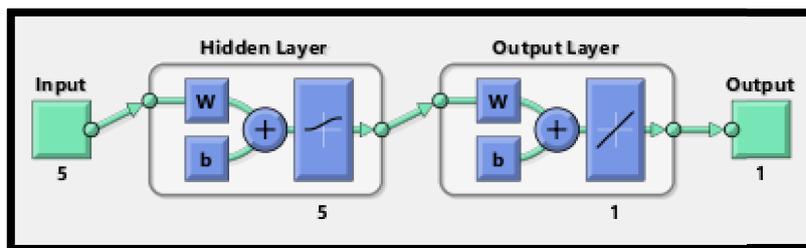


Fig. 6. Cantidad de neuronas en las capas de entrada, oculta y salida

Métodos y parámetros matemáticos empleados en la solución

- Levenberg-Marquardt. Es una técnica de optimización iterativa que ajusta los parámetros de un modelo no lineal para minimizar la suma de los cuadrados de los errores entre los valores observados y los predichos. Combina las características del método de Gauss–Newton y del descenso por gradiente, adaptando dinámicamente su comportamiento para mejorar la convergencia y la estabilidad del proceso de optimización [15].
- BackPropagation. Es un método de optimización utilizado en el entrenamiento de redes neuronales artificiales que consiste en calcular el gradiente de la función de pérdida respecto a los pesos de la red mediante la regla de la cadena, permitiendo ajustar dichos pesos a través de técnicas como el descenso por gradiente[16].
- Coeficiente de correlación lineal de Pearson. Es una medida estadística que cuantifica la fuerza y dirección de la relación lineal entre dos variables continuas. Su valor oscila entre -1 y +1, donde +1 indica una correlación positiva perfecta, -1 una correlación negativa perfecta y 0 ausencia de correlación lineal [17].
- MAPE (Mean Absolute Percent Error, por sus siglas en inglés). Es una métrica estadística que cuantifica la precisión de los modelos de predicción al calcular el promedio del valor absoluto del porcentaje de error entre los valores reales y los predichos. Su valor se expresa como un porcentaje, lo que facilita la interpretación de la precisión del modelo en términos relativos [18].
- RMSE (Root Mean Square Error, por sus siglas en inglés). Es una métrica ampliamente usada para evaluar el rendimiento de modelos de predicción. Representa la raíz cuadrada del promedio de los errores al cuadrado entre los valores predichos y los valores reales. Es especialmente útil en contextos de predicción de generación eléctrica, ya que penaliza fuertemente los errores grandes y sus unidades coinciden con la variable de salida [19].
- NRMSE (Normalized Root Mean Square Error, por sus siglas en inglés). Normaliza el valor del RMSE para hacerlo comparable entre distintos conjuntos de datos o modelos. Esta normalización se puede hacer dividiendo el RMSE por el rango, la media o el valor máximo de la variable real. El NRMSE se expresa como una fracción o porcentaje, proporcionando una perspectiva del error relativo [20].

RESULTADOS

Durante el entrenamiento de la RNA, los datos utilizados a su vez, se separan en datos de entrenamiento, validación y datos de prueba, determinando la correlación existente en cada grupo de datos. Los valores obtenidos en cada grupo (ver figura 7), y en la totalidad de los datos, supera el 90% de aciertos, por lo que se considera que la red tiene un alto nivel de ajuste en la predicción de potencia.

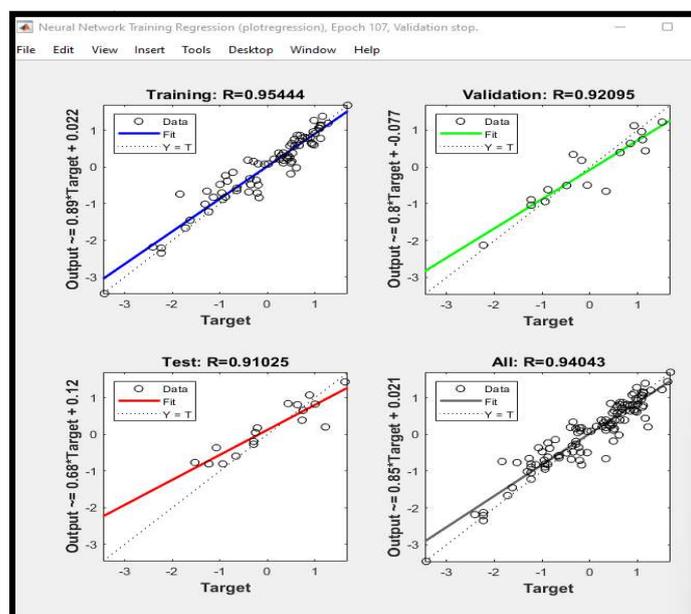


Fig. 7. Resultados del ajuste de la RNA

Después del entrenamiento de la RNA, se debe pasar a la etapa de validación, para ello se utilizaron el 20% de los datos de la muestra total. Su selección se realiza de forma aleatoria con el objetivo de comprobar el correcto funcionamiento de la RNA para predecir la potencia cualquier día comprendido entre los meses de mayo y septiembre. Debe destacarse que los datos de validación son diferentes a los que se utilizó para el entrenamiento de la red. Los resultados obtenidos en la validación de la RNA se comparan con los valores experimentales (registros de potencia real entregada) del funcionamiento del sistema fotovoltaico (ver figura 8).

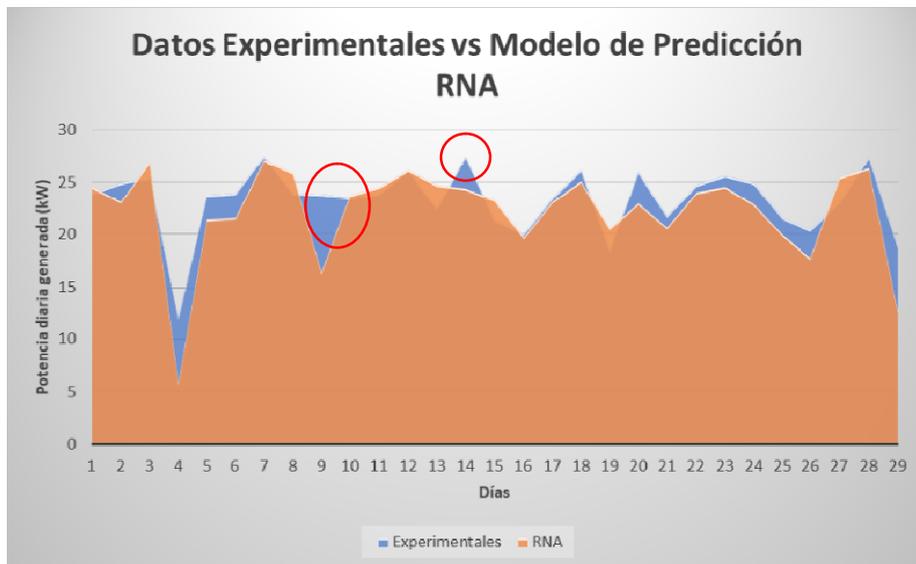


Fig. 8. Comparación de datos experimentales y los obtenidos en la validación de la RNA

De los 29 valores utilizados en la validación se denotan dos que se ajustan poco a su correspondiente valor experimental, al compararlo con los resultados totales, se observa que la mayoría de los valores tienen un mejor seguimiento de la potencia generada, coincidiendo con los valores de correlación que se muestran en la figura 6. En la figura 9, se muestra la comparación de los valores de validación y experimentales, eliminando los dos valores atípicos.

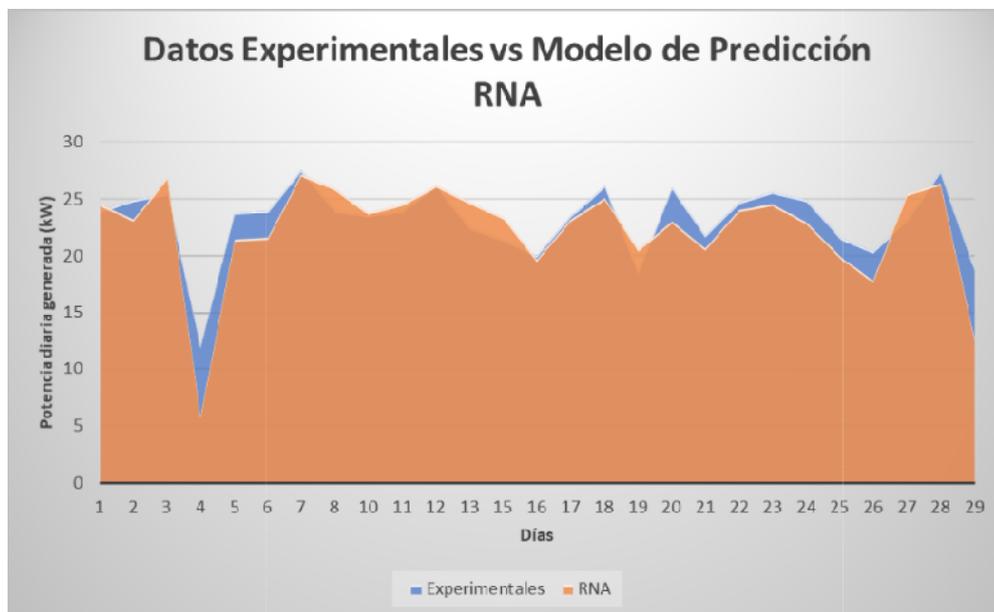


Fig. 9. Comparación de datos experimentales y los obtenidos en la validación de la RNA, eliminando los dos valores atípicos

Para tener referencia de cuan bueno puede ser el modelo se calculan las métricas del Modelo de Persistencia. También se compararon los resultados obtenidos con las métricas de otros modelos similares de la bibliografía consultada, concluyéndose que los valores de los distintos parámetros de validación son buenos para este tipo de herramienta. Ver tabla 1.

Tabla 1. Comparación de la RNA obtenida con otros modelos similares

Métrica	RNA obtenida en este trabajo	Modelo Persistencia	(Haque, Nehrir, & Mandal, 2013)	(De Giorgi et al., 2014)	(Leva, Dolara, Grimaccia, Mussetta, & Ogliari, 2017)	(Zhu et al., 2016)
MAPE (%)	9,60	23,29	3,38-11,83	-	-	-
RMSE (kW)	2,68	5,09	-	-	-	-
nRMSE (%)	12,03	21,88	12,11-13,13	10,91-23,99	12,5-36,9	7,193-19,663

DISCUSIÓN

De los resultados alcanzados en la validación del modelo, se puede concluir que la RNA obtenida presenta un buen ajuste con los datos experimentales, ofreciendo pronósticos con más de un 90% de aciertos y un margen de error de 2,68 kW en cada pronóstico, que al compararse con otros modelos similares de la literatura consultada pueden considerarse como resultados positivos. Debe destacarse que es un modelo de bajas exigencias computacionales, cuyo objetivo es el pronóstico anticipado de generación para la planificación energética diaria del Centro Telefónico. La herramienta desarrollada en este trabajo, solo será válida en los meses comprendidos entre mayo y septiembre, por lo que se recomienda extender el estudio para poder realizar predicciones en un año calendario.

CONCLUSIONES

La aplicación de herramientas de pronóstico de generación eléctrica, basadas en inteligencia artificial, también es posible con una menor exigencia computacional, modelos matemáticos de menor complejidad y con menores tiempos de entrenamiento, lo que permite su implementación en ámbitos de recursos limitados y la optimización de los recursos disponibles. El impacto positivo de esta herramienta en este Centro Telefónico en cuanto a la mejora de la eficiencia energética, un mejor aprovechamiento de la jornada laboral y mejores condiciones de trabajo, puede hacerse extensible a otras edificaciones de la empresa que disponen de la instalación de sistemas fotovoltaicos.

REFERENCIAS

- [1]. Lim, S. "Solar power forecasting using CNN-LSTM hybrid model," *Energies*. 2022, vol. 15, n.21. ISSN 1996-1073. Disponible en: <https://www.mdpi.com/1996-1073/15/21/8233>
- [2]. Sharma, N. "Solar power forecasting beneath diverse weather conditions using GD and LM-ANN," *Scientific Reports*. 2023, vol. 13, n. 3635. ISSN 2045-2322. Disponible en: <https://www.nature.com/articles/s41598-023-35457-1>
- [3]. Xiang, X. "A short-term forecasting method for photovoltaic power generation based on the TCN-ECANet-GRU hybrid model," *Scientific Reports*. 2024, vol. 14, n. 6744. ISSN 2045-2322. Disponible en: <https://www.nature.com/articles/s41598-024-56751-6>
- [4]. Kahana, L. "Predicción de energía fotovoltaica basada en algoritmos genéticos y una red neuronal dinámica," *pv-magazine*. 2025. ISSN 1865-3138. Disponible en: <https://www.pv-magazine-mexico.com/2025/02/03/prediccion-de-energia-fotovoltaica-basada-en-algoritmos-geneticos-y-una-red-neuronal-dinamica/>
- [5]. Ahmed, U. "Parallel boosting neural network with mutual information for day-ahead solar irradiance forecasting," *Scientific Reports*. 2025, vol. 15, n. 11642. ISSN 2045-2322. Disponible en: <https://www.nature.com/articles/s41598-025-95891-1>
- [6]. Rodríguez, J. "Modelo para predicción de potencia de paneles fotovoltaicos utilizando técnicas de clasificación no supervisada y redes neuronales artificiales". Tesis de maestría. Universidad del Norte, Colombia. 2020. Disponible en: <https://manglar.uninorte.edu.co/handle/10584/9049#page=1>
- [7]. Baeza, G. "Prediction techniques adapted to the estimation of energy production of photovoltaic installations integrated in virtual power plants". Tesis de doctorado. Universidad de Alcalá, España. 2022, p. 143. Disponible en: <https://ebuah.uah.es/dspace/handle/10017/53830?locale-attribute=en>
- [8]. Adineh, A. "Importance of data preprocessing in time series prediction using SARIMA: A case study," *Journal of Intelligent & Fuzzy Systems*. 2020, vol. 38, n.3, p. 1-10. ISSN 1875-8967. Disponible en: <https://dl.acm.org/doi/abs/10.3233/KES-200065>
- [9]. Zhang, M. "A survey on deep neural networks: architectures, applications, and future trends," *IEEE Transactions on Neural Networks and Learning Systems*. 2022, vol. 33, n. 2. ISSN 2162-2388. Disponible en: <https://bura.brunel.ac.uk/bitstream/2438/14221/1/FullText.pdf>
- [10]. Basset, A. "A novel intelligent medical decision support model based on soft computing and IoT for heart disease diagnosis," *IEEE Access*. 2020, vol. 8, p. 107580–107590. ISSN 2169-3536. Disponible en: https://www.researchgate.net/publication/334999037_A_Novel_Intelligent_Medical_Decision_Support_Model_Based_on_Soft_Computing_and_IoT
- [11]. Khan, M. "Deep neural networks for time series forecasting: A review," *IEEE Access*. 2020, vol. 8, p. 145685–145703. ISSN 2169-3536. Disponible en: <https://ieeexplore.ieee.org/document/10583885>

- [12]. Li, Y. "A review of MLP-based deep learning methods for short-term traffic flow prediction,". IEEE Transactions on Intelligent Transportation Systems. 2022, vol. 23, n. 5, p. 3744–3756. Disponible en: https://www.researchgate.net/publication/366460896_Traffic_flow_prediction_models_-_A_review_of_deep_learning_techniques
- [13]. Messaoud, S. "A survey on machine learning in Internet of Things: Algorithms, strategies, and applications,". Internet of Things. 2020, vol. 12, p. 53. ISSN 2542-6605. Disponible en: https://www.academia.edu/97681946/A_survey_on_machine_learning_in_Internet_of_Things_Algorithms_strategies_and_applications
- [14]. Yazici, I. "Unsupervised learning,". Engineering Science and Technology, an International Journal,". Engineering Science and Technology, an International Journal. 2023, vol. 39, p. 1-12. ISSN 2215-0986. Disponible en: <https://www.sciencedirect.com/topics/computer-science/unsupervised-learning>
- [15]. Huang, X. "Optimization of Levenberg–Marquardt Algorithm Applied to Nonlinear Systems,". Processes. 2023, vol. 11, n. 6. ISSN 2227-9717. Disponible en: <https://www.mdpi.com/2227-9717/11/6/1794>
- [16]. Li, M. "Comprehensive Review of Backpropagation Neural Networks,". Academic Journal of Science and Technology. 2024, vol. 9, n. 1, p. 150–154. ISSN 2771-3032. Disponible en: https://www.researchgate.net/publication/378359601_Comprehensive_Review_of_Backpropagation_Neural_Networks
- [17]. Lalinde, J., *et al.* "Sobre el uso adecuado del coeficiente de correlación de Pearson: verificación de supuestos mediante un ejemplo aplicado a las ciencias de la salud,". Revista Colombiana de Estadística. 2018, vol. 41, n. 2, p. 345–356. Disponible en: <https://www.redalyc.org/journal/559/55963207020/html/>
- [18]. Kim, S. "A new metric of absolute percentage error for intermittent demand forecasts,". International Journal of Forecasting. 2016, vol. 32, n. 3, p. 669–679. ISSN 1872-8200. Disponible en: <https://www.sciencedirect.com/science/article/pii/S016920711630012>
- [19]. Smith, A. "Comparative analysis of deep neural network architectures for renewable energy forecasting: enhancing accuracy with meteorological and time-based features,". Discover Sustainability. 2024, vol. 5, n. 533. ISSN 2662-9984. Disponible en: <https://link.springer.com/article/10.1007/s43621-024-00783-5>
- [20]. Johnson, B. "A Hybrid Deep Learning Model to Estimate the Future Electricity Demand of Sustainable Cities,". Sustainability. 2024, vol. 16, n. 15. ISSN 2071-1050. Disponible en: <https://www.mdpi.com/2071-1050/16/15/6503>

CONFLICTO DE INTERESES

Los autores declaran que no existen conflictos de intereses.

CONTRIBUCIÓN DE LOS AUTORES

Yainiel Martínez Fresneda: <https://orcid.org/0009-0004-2049-0649>

Participó en la búsqueda de información y diseño de la investigación, en la recolección, análisis y tratamiento de los datos, en el ajuste y obtención de la red neuronal. Participó en el análisis de los resultados y establecimiento de conclusiones, además de la revisión crítica del contenido, redacción y aprobación del informe final.

Miguel Castro Fernández: <https://orcid.org/0000-0002-3983-469X>

Participó en el aporte de ideas y establecimiento de conclusiones, la revisión del borrador del artículo, la revisión crítica de su contenido y en la aprobación final del informe.