

(05-019) - APPLICATION OF RECURRING NEURONAL NETWORKS IN THE IDENTIFICATION OF PHOTOVOLTAIC DISTRIBUTED GENERATION SYSTEMS

Batista Jorge , Rafael Omar ¹; Ramos Ciprián , Rubén Darío ²; Morales Del Carmen, Richy Carlos ²; Salavert Fernández, José Miguel ³; Guerrero Rodríguez, Nestor Francisco ⁴

¹ Instituto Tecnológico de Santo Domingo, ² Universidad Central del Este, ³ Universitat Politècnica de València, ⁴ Pontificia Universidad Católica Madre y Maestra

Modeling photovoltaic distributed generation systems presents important challenges due to the dynamic complexity that characterizes these systems. Both solar cells and interfaces based on power electronics present non-linear behaviors that hinder the theoretical modeling process as well as the implementation of system identification techniques. Classic system identification techniques may present limitations when applied. This work explores the use of recursive neural networks, specifically, nonlinear autoregressive neural networks for modeling a time series that relates the input irradiance in photovoltaic solar panels versus the power output of the inverter.

A process of capturing irradiance and power data from a 3KVA photovoltaic system was carried out for a period of five days, from this an input database was built for the training process of the chosen neural network. The use of cross validation was considered for measuring performance in the training process. The results show how the proposed approach generates a model with a percentage mean square error of 0.12%, validating the approach of this work.

Keywords: Neural Networks; Generation; Photovoltaic

APLICACIÓN DE REDES NEURONALES RECURRENTE EN LA IDENTIFICACIÓN DE SISTEMAS DE GENERACIÓN DISTRIBUIDA FOTOVOLTAICOS

El modelado de los sistemas de generación distribuida fotovoltaicos presenta retos importantes debido a la complejidad dinámica que caracteriza estos sistemas. Tanto las celdas solares como las interfases basadas en electrónica de potencia presentan comportamientos no lineales que dificultan el proceso de modelado teórico al igual que la implementación de técnicas de identificación de sistemas. Las técnicas clásicas de identificación de sistemas pueden presentar limitaciones al momento de ser aplicadas. Este trabajo explora el uso de redes neuronales recursivas, específicamente, redes neuronales autorregresivas no lineales para el modelado de una serie de tiempo que relaciona la irradiancia de entrada en los paneles solares fotovoltaicos versus la salida en potencia del inversor.

Se realizó un proceso de captura de datos de irradiancia y potencia de un sistema fotovoltaico de 3KVA por un periodo de cinco días, a partir de esto se construyó una base de datos de entrada para el proceso de entrenamiento de la red neuronal elegida. Se consideró el uso de validación cruzada para la medición del desempeño en el proceso de entrenamiento. Los resultados muestran como el acercamiento propuesto genera un modelo con un error medio cuadrático porcentual del 0.12%, validando esto el planteamiento de este trabajo.

Palabras clave: Redes Neuronales; Generación; Fotovoltaicos



©2024 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

Correspondencia: Ruben Dario Ramos Ciprian, rubenramos@uce.edu.do

Agradecimientos: Esta investigación fue financiada por el Fondo Nacional de Innovación y Desarrollo Científico y Tecnológico (FONDOCYT) del Ministerio de Educación Superior Ciencia y Tecnología de la República Dominicana (MESCYT) a través del proyecto FONDOCyT-2020-2021-3C1-148.

1. Introducción

La identificación de sistemas es una técnica útil para modelar la respuesta dinámica de dispositivos de potencia, los que cada vez han tenido mayor predominancia debido a la integración de generación distribuida (GD) a partir energía renovable variable (ERV) según muestra (Souza Junior & Freitas, 2022). Los inversores de potencia son componentes clave de los sistemas de energía renovable, que convierten la corriente continua (DC) generada por los paneles solares o las turbinas eólicas en corriente alterna (AC) que se puede utilizar en el hogar o la red eléctrica. Un inversor de potencia para cualquier tipo de sistema consta de componentes de conmutación de electrónica de potencia, sistemas de control completos y comportamientos no lineales. En el pasado, se han utilizado varios métodos para explorar los comportamientos de los inversores (Patcharaprakiti et al., 2010).

El modelado y la simulación de sistemas de inversores de potencia son herramientas esenciales para el análisis, el funcionamiento y el impacto de los inversores en los sistemas eléctricos. Se pueden utilizar enfoques analíticos y experimentales para obtener los modelos necesarios (Ebead et al., 2023). La aplicación de técnicas de identificación de sistemas para el modelado de la respuesta dinámica de los inversores de potencia permite entender su comportamiento y mejorar su rendimiento.

La aplicación de técnicas de identificación de sistemas para el modelado de la respuesta dinámica de los inversores de potencia es una herramienta esencial para el diseño y optimización de sistemas de energía renovable (Qiao et al., 2023). Esto permite mejorar la eficiencia, la estabilidad y la calidad de la energía generada por estos sistemas, contribuyendo así a la transición hacia un futuro energético más sostenible. Además, el modelado preciso de la respuesta dinámica del inversor de potencia puede ser utilizado para el diseño de sistemas de control avanzados que mejoran la eficiencia y la estabilidad del sistema.

Trabajos como el presentado por los autores de (Chakraborty et al., 2022) recalcan la importancia de considerar el modelado de sistemas no lineales para diversos tipos de aplicaciones de electrónica de potencia. Sin embargo, no existen metodologías definidas para este tipo de acercamiento y sigue siendo un área de investigación en proceso. Los autores comentan sobre el uso de modelos tipo “caja negra” basados en datos para aproximar las complejidades asociadas al comportamiento no lineal presentado por las interfases de electrónica de potencia.

Muchos métodos han sido reportados en la literatura para el proceso de identificación de interfases de potencia, sin embargo, mucho de estos asumen una aproximación lineal. Ejemplo de esto es el método de promediado presentado por (Patcharaprakiti et al., 2010). En este se promedian los estados para analizar inversores basado en el análisis de circuitos y las teorías de sistemas lineales. La derivación del conjunto de ecuaciones del espacio de estados para cada topología es el primer paso principal. A continuación, se calculan funciones de transferencia y se obtiene un modelo de funcionamiento en el dominio del tiempo continuo.

Sin embargo, este tipo de asunciones pierden aplicación al considerar la respuesta no lineal tanto de las interfases de potencia como la respuesta de los paneles solares fotovoltaicos. El presente trabajo busca explorar el uso de modelos de caja negra basados en redes neuronales artificiales para la identificación de la respuesta dinámica no lineal ofrecido por un sistema generador solar fotovoltaico junto a su interfaz de potencia. Se mostrarán los objetivos planteados, la metodología a desarrollar, resultados obtenidos y las conclusiones a las que se ha llegado luego de la implementación del modelo propuesto.

2. Objetivos

1. Implementar una metodología de medición para las señales de entrada y salida de un inversor monofásico para crear un modelo tipo caja negra a partir de los datos capturados.
2. Analizar arquitecturas de redes neuronales recurrentes que permitan crear modelos predictivos para datos estructurada como series de tiempo.
3. Aplicar estrategias de validación cruzada de modelos para evaluar el desempeño de la arquitectura de redes neuronales seleccionada considerando la característica de sesgo y varianza.
4. Validar con datos adicionales no considerados en el proceso de entrenamiento del modelo la respuesta obtenida para demostrar el correcto funcionamiento de la estrategia de identificación propuesta.

3. Metodología

3.1. Captura de datos para el proceso de identificación

En el proceso de medición llevado fueron utilizada una serie de herramientas y dispositivos especializados para obtener datos precisos sobre la respuesta dinámica exhibida por el inversor monofásico bajo estudio en el sistema solar propuesto. Este proceso tuvo las siguientes consideraciones:

- Configuración de la medición: Fue utilizado el analizador de calidad de energía FLUKE 434 para medir las variables de entrada y salida del inversor bajo estudio. Fue posible registrar la forma de onda de la tensión de entrada y salida, valores de corriente y potencia entregada por el inversor a las cargas. En la Figura 1 se muestra la conexión del analizador propuesto

Figura 1: Configuración de conexión del FLUKE 434 al inversor realizada por este trabajo



Fue posible realizar mediciones de la eficiencia de conversión de los inversores, evaluar la calidad de las ondas sinusoidales generadas y cuantificar de manera detallada la potencia entregada. El FLUKE 434 permite realizar un proceso de registro y descargar la captura de los datos. El software de captura permite exportar los datos obtenidos para el proceso de creación de los modelos basados en redes neuronales. En la Tabla 1 se observa las características de operación del dispositivo FLUKE 434 a partir de su hoja de datos (Fluke Corporation, 2024).

Tabla 1: Especificaciones Técnicas medidor FLUKE 434

Características eléctricas del FLUKE 434	
Voltaje Nominal Máximo	1000V
Resolución Voltaje	0.1V
Corriente Nominal Máxima	600A
Resolución Corriente	0.1A
Frecuencia Operación	51Hz-69Hz
Armónicos	Hasta el 50vo armónico
Capturas por minuto máxima	1 captura
Resolución Cálculo Potencia	±1%

Las características del sistema de generación solar fotovoltaico que se está identificando son las mostradas en la Tabla 2. En el caso de la prueba realizada, solamente se conectó una de las hileras de paneles fotovoltaicos al inversor, por lo que la potencia disponible es la mitad de la potencia nominal. El proceso de captura realizado abarcó un periodo de 5 días, con un total de 7,200 mediciones capturadas con diferentes características de irradiancia solar. El máximo periodo de muestreo que permite el FLUKE 434 en su función de captura es 1 muestra/minuto.

Tabla 2: Características del Sistema de Generación Solar Fotovoltaico

Características eléctricas del Panel solar PS315P-24/T	
Potencia nominal STC	315W
Imp	8.56A
Vmp	36.8V
ISC	8.88A
Voc	46.2V
Voltaje máximo del sistema	600V
Características del Inversor SUN2000-3KTL-L1	
Máxima potencia activa	0.100~3.300
Reducción de potencia activa fija (W)	3000
Nivel de voltaje (V)	230
Máxima potencia activa	3300

3.2. Simulación de respuesta dinámica y creación de un modelo híbrido

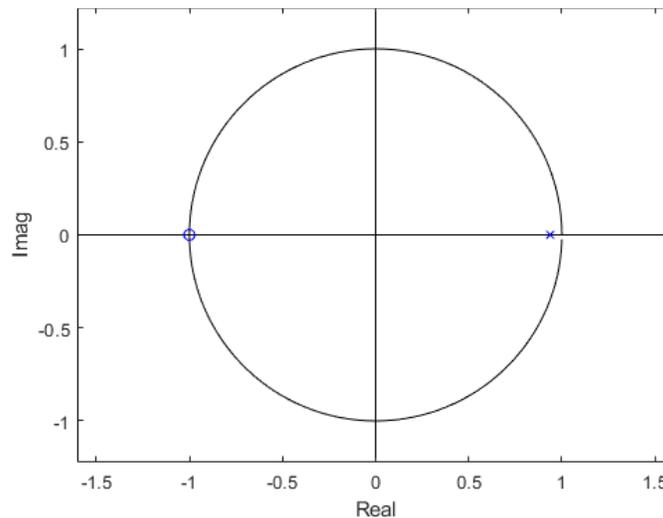
Debido a la resolución de muestreo ofrecida por el FLUKE 434 no es posible capturar la respuesta dinámica entre los cambios de respuesta que ofrece el inversor seleccionado entre la relación de su entrada con su salida. Por tal motivo, y para validar la efectividad del acercamiento de modelado propuesto, se propone la creación de un modelo híbrido, que utilice datos reales capturados junto a una simulación de una respuesta dinámica de un sistema de segundo orden. Este tipo de acercamiento ha sido abordado anteriormente en la literatura científica, como se evidencia en el trabajo presentado por (Haghi et al., 2024).

Para este propósito, se procede a crear una simulación en ambiente MATLAB/SIMULINK que tome como entrada los datos capturados y lo aplique a un sistema de segundo orden con las características mostradas en la Tabla 3. El sistema es diseñado en el dominio del tiempo continuo, para luego ser discretizado mediante la correspondencia polo-cero entre el Plano S y el Plano Z. En la Figura 2, se grafican en el Plano Z los polos y ceros resultantes de la función de transferencia del sistema discreto diseñado, se observa que los polos quedan dentro del círculo unitario, por lo que el sistema diseñado presenta una respuesta dinámica estable.

Tabla 3: Características dinámicas para la creación del modelo híbrido

Descripción	Valor
Ganancia	30
Frecuencia Natural	10 Hz
Frecuencia de Muestreo	1000 Hz
Número de ceros	2
Número de polos	2

Figura 2: Gráfica generada en MATLAB con la ubicación de polos y ceros en el Plano Z

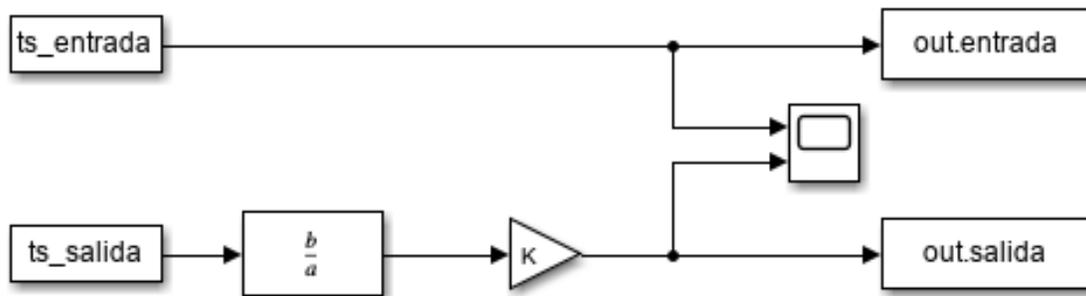


A partir de esto se obtuvo la siguiente expresión matemática para la función transferencia discreta que describe la dinámica propuesta para la respuesta del sistema híbrido. La ecuación (1) muestra la función transferencia obtenida.

$$G(z) = \frac{1 + 2z^{-1} + z^{-2}}{1 - 1.878z^{-1} + 0.8819z^{-2}} \quad (1)$$

Con esta ecuación en transferencia fue construido un modelo utilizando SIMULINK y tomando como vector de entrada los datos medidos en la fase experimental descrita en la metodología de este trabajo. Para la configuración de SIMULINK el modelo fue ejecutado en el tiempo discreto con un paso de computación máximo de $1 \times 10^{-4}s$. El modelo en bloques desarrollado se muestra en la Figura 3.

Figura 3: Modelo en bloques desarrollado en MATLAB/SIMULINK para la respuesta dinámica del sistema fotovoltaico en estudio.



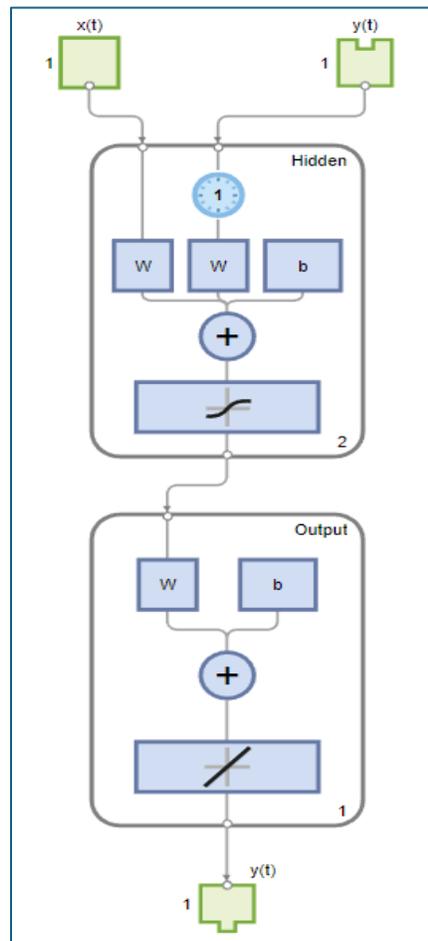
3.3. Estructura de Red Neuronal del tipo NARX para análisis de serie temporal

Finalmente fue implementado mediante el TOOLBOX de Aprendizaje de Máquina de MATLAB una red neuronal recurrente. Las redes neuronales autorregresivas no lineales con entrada externa (NARX) son un tipo de red neuronal artificial que se utiliza para modelar y predecir series temporales (Munoz & Acuna, 2021). Estas redes son capaces de captar dinámicas complejas y no lineales en los datos, lo que las hace especialmente útiles en diversas aplicaciones prácticas (Cheng & Low, 2023).

Las NARX se utilizan para modelar series temporales en las que la predicción de un valor en un momento dado depende no sólo de entradas externas, sino también de valores anteriores de la serie. Esto permite a la red aprender patrones y dependencias a largo plazo, lo que resulta crítico en campos como la meteorología, la economía y la ingeniería de control. Uno de los rasgos distintivos de NARX es su capacidad para hacer predicciones en varios pasos. Esto significa que la red puede predecir una secuencia de valores futuros, lo que resulta esencial para la planificación y la toma de decisiones en ámbitos como la gestión de inventarios y la planificación energética (H. Gao et al., 2023).

Para las previsiones a largo plazo, NARX puede funcionar en modo de realimentación. En este modo, la red utiliza su propia salida como parte de la entrada para la siguiente previsión, lo que le permite generar previsiones continuas incluso en ausencia de nuevas entradas externas. NARX es muy flexible y puede adaptarse a diferentes estructuras de datos y requisitos de modelización. Esto lo hace adecuado para aplicaciones en las que los patrones de datos pueden cambiar con el tiempo o en las que se requiere una gran precisión de predicción. De esta forma procedemos a realizar el entrenamiento de una arquitectura NARX con dos capas ocultas, un retraso de la salida y sin retrasos de la entrada. La Figura 4 muestra la arquitectura realizada.

Figura 4: Diagrama del modelo de arquitectura seleccionada para Red Neuronal del tipo NARX generado por MATLAB



4. Resultados

4.1. Resultados proceso captura de datos

El proceso de captura de los datos llevado a cabo fue realizado en un total de cuatro días con una frecuencia de una muestra por minuto para un total de 5,757 registros. En la Figura 5 se observa la forma de onda obtenida al medir la potencia entregada por el sistema solar fotovoltaico para uno de los días capturados (tercer día). Estas corresponden con el comportamiento esperado para el suministro de potencia del generador solar fotovoltaico según una curva de irradiancia típica en una región caribeña (Euán et al., 2022). Esta gráfica se complementa con la entrada de voltaje de los paneles solares, que se muestra en la Figura 6. Estos datos sirven como entrada para la creación del modelo del sistema solar fotovoltaico.

Figura 5: Gráfico generado en EXCEL de la potencia salida para un día haciendo uso de los datos capturados por el FLUKE 434

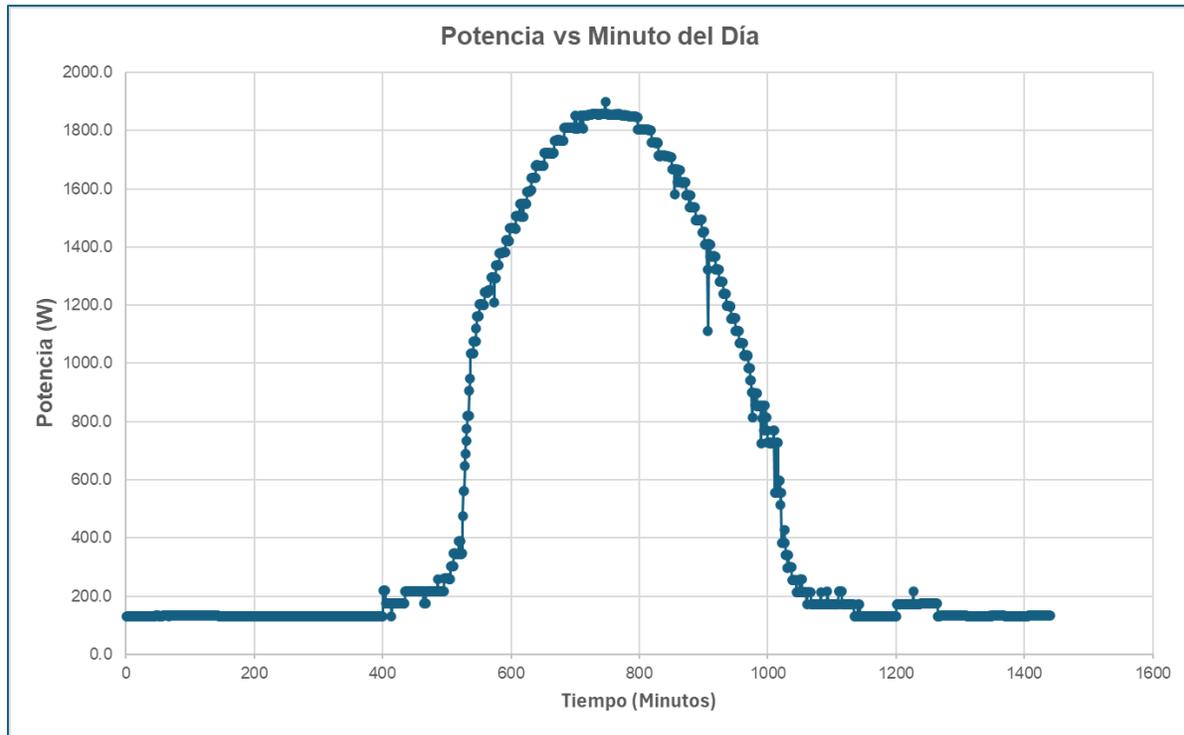
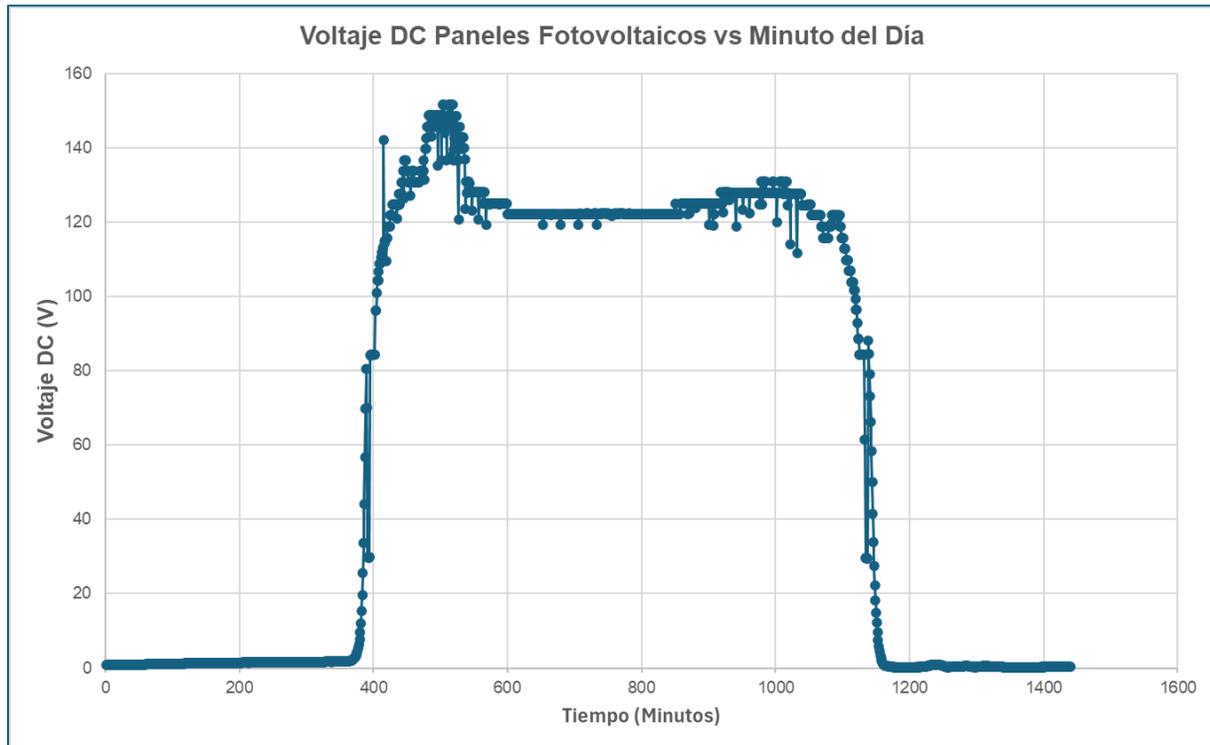


Figura 6: Gráfico generado en EXCEL del Voltaje DC de los paneles solares fotovoltaicos para un día haciendo uso de los datos capturados por el FLUKE 434

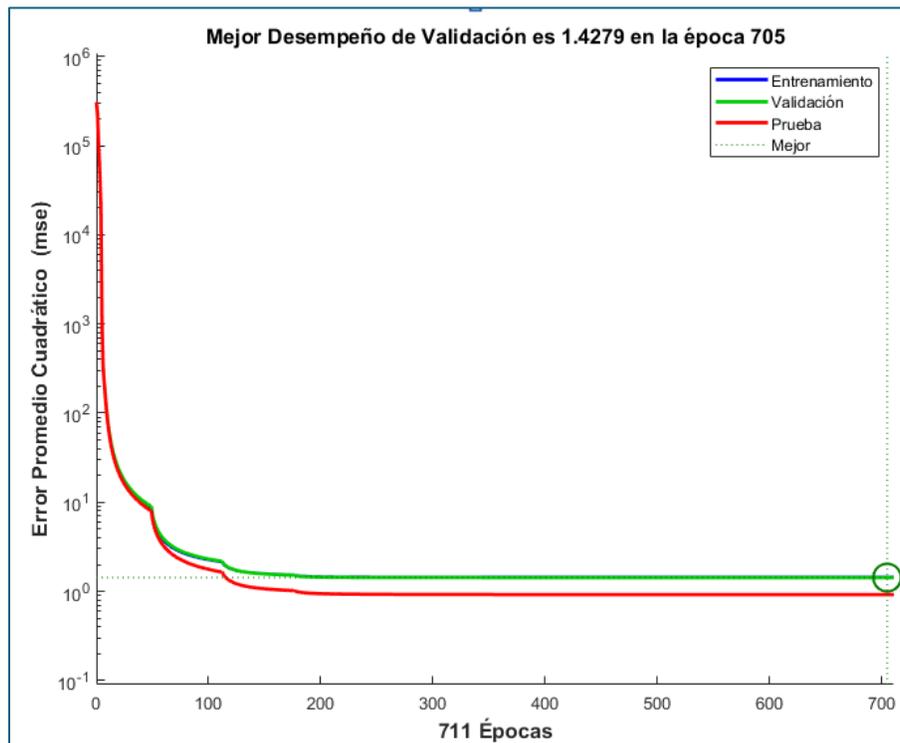


Es importante recalcar que el cuarto día de captura fue un día con bastante presencia nubosa, por lo que no fue utilizado para el proceso de validación. Al observar la cantidad de datos y validar el proceso de entrenamiento del modelo, se decidió hacer un modelo predictivo para una programación del día siguiente. Por lo que se entrenará a partir del día uno, y se verá la capacidad del modelo de capturar la dinámica para predecir la potencia generada en el día dos a partir de las variaciones en el voltaje entregado por la hilera de paneles solares fotovoltaicos.

4.2. Proceso de Entrenamiento del modelo NARX

A continuación se detalla el proceso de entrenamiento a partir de los datos del día uno del modelo NARX seleccionado utilizando el TOOLBOX de MATLAB/SIMULINK. La arquitectura entrenada fue la mostrada en la metodología del presente trabajo. La Figura 7 muestra el desempeño en función del error cuadrático medio (MSE). Es importante destacar que la implementación del TOOLBOX seleccionado utiliza una validación cruzada en la selección del modelo con mejor desempeño, por lo que se espera que el mismo tome en consideración la relación sesgo/variancia para evitar el sobreajuste del modelo.

Figura 7: Desempeño del proceso de entrenamiento del modelo seleccionado



En la Figura 8 se tiene el resumen del proceso de entrenamiento llevado a cabo en MATLAB. Como se puede ver el proceso terminó antes de las 1000 épocas configuradas para llegar a un nivel de error mínimo. Según definen en (Corzo et al., 2023) la época es un parámetro del proceso de entrenamiento de la red neuronal que indica la cantidad de iteraciones completas realizadas sobre todo el conjunto de entrenamiento. Es importante notar que la métrica de desempeño es la misma que en la Figura 7, el error cuadrático medio, obteniendo un valor de 0.168 al momento de realizar el entrenamiento al llegar a la condición de parada.

Figura 8: Captura de pantalla con el resumen de los indicadores del proceso de entrenamiento llevado a cabo en MATLAB, resaltando la métrica de desempeño.

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	1000	1000
Elapsed Time	-	00:07:45	-
Performance	1.18e+06	0.168	0
Gradient	2.42e+06	2.53	1e-07
Mu	0.001	0.01	1e+10
Validation Checks	0	0	6

4.3. Validación del modelo creado

Para validar el proceso de identificación de sistema propuesto se valida el modelo con datos de entrenamientos y datos de validación. Como se argumentó en la metodología, se propone un modelo con una ventana temporal de 24 horas. Las Figuras 9 y 10 muestran el comportamiento para ambos casos planteados. Se agrega el gráfico de los residuos del modelo en la parte inferior para poder evaluar el valor del error en instantes de tiempos específicos. En ambas gráficas es posible notar como los procesos de transición abrupta (ocurrencia de picos) presentan el principal reto para el modelo. Sin embargo, el error absoluto en los peores casos se mantuvo por debajo de 50W.

Figura 9: Graficando en MATLAB el desempeño del modelo con entrada de datos de entrenamiento y calculando los residuos del modelo

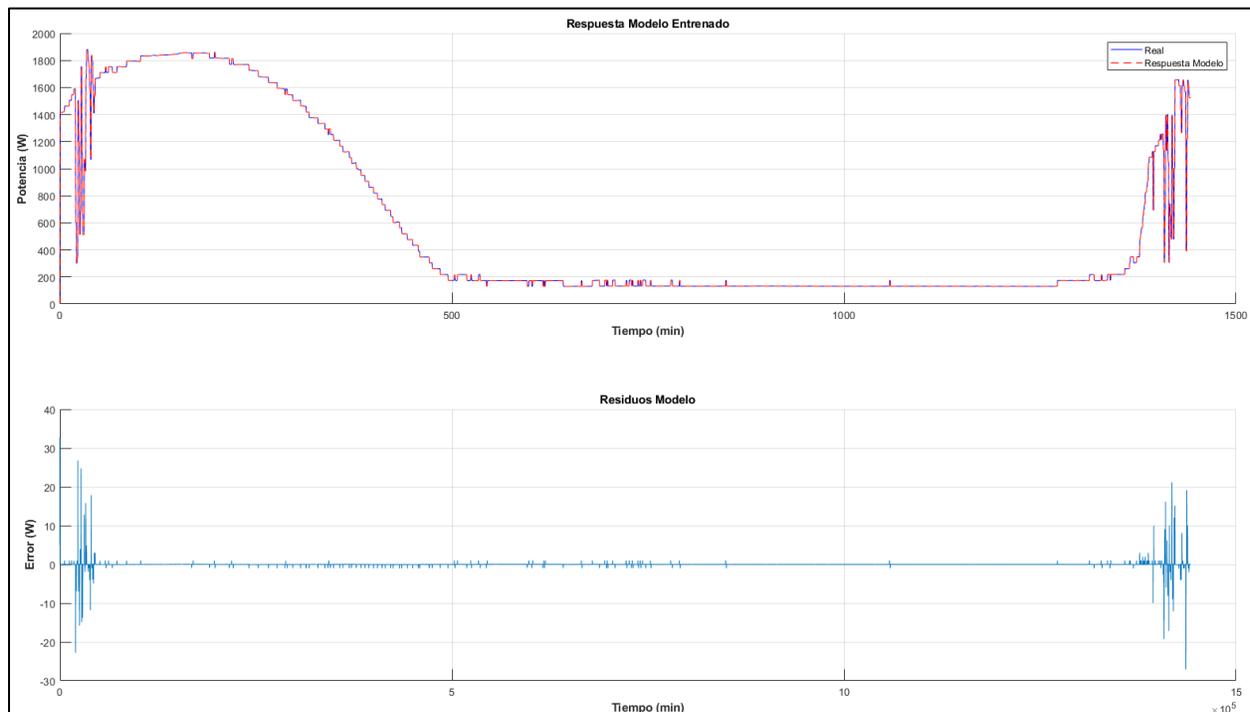
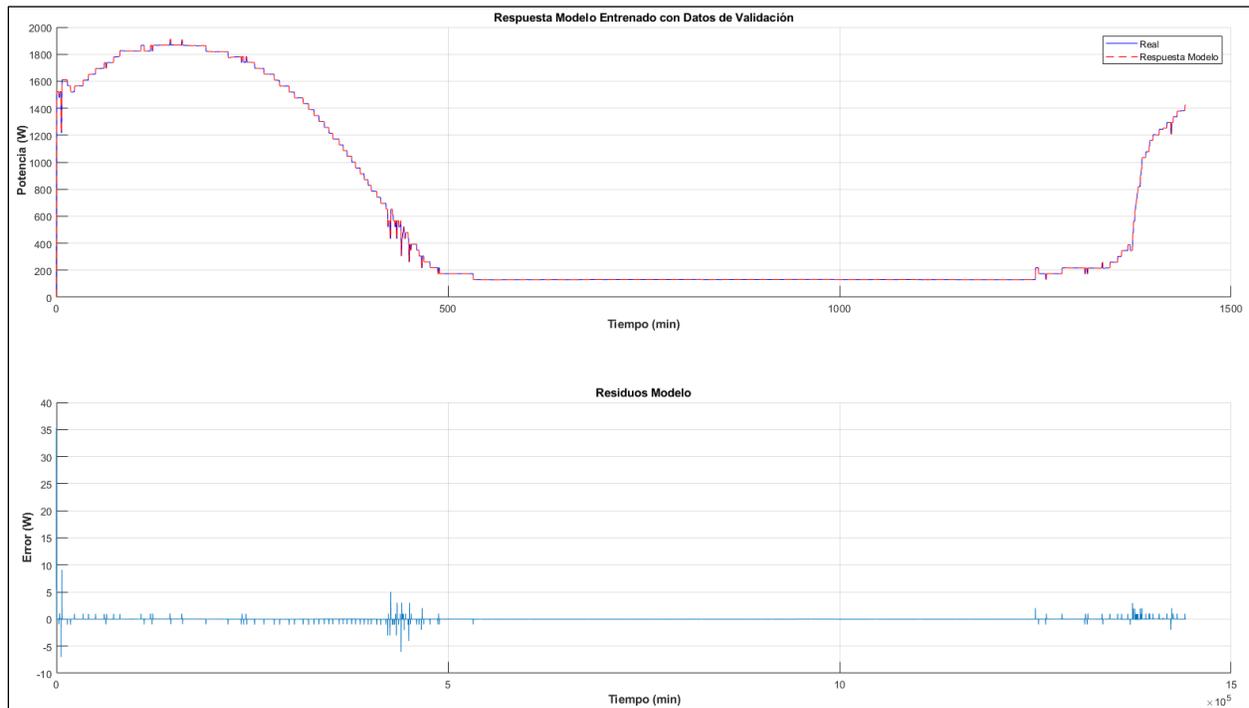


Figura 10: Graficando en MATLAB el desempeño del modelo con entrada de datos de validación y calculando los residuos del modelo



Si se comparan los resultados obtenidos con revisiones recientes de la literatura científica con referencia al uso de modelos de aprendizaje de máquina para el pronóstico de la generación solar fotovoltaica (Gaboitaolelwe et al., 2023) encontramos que el desempeño obtenido supera a técnicas que no se basan en estructura de redes neuronales recurrentes. De los trabajos revisados el presentado por los autores (M. Gao et al., 2019) es el que utiliza una estructura parecida a la red tipo NARX y obtiene el mejor desempeño con un error porcentual cuadrático medio del 1.68%. Si calculamos este error para nuestro trabajo, el mismo es 0.12%, por lo que estructuras de redes neuronales recurrentes que toman en cuenta no linealidades como la propuesta pueden ofrecer mejoras importantes en la creación de estos modelos predictivos.

Otro punto para mencionar es que estos trabajos típicamente se enfocan en capturar solo la respuesta dinámica de los paneles solares fotovoltaicos (Lafta et al., 2021). En el presente trabajo se busca un modelo para el sistema incluyendo las no linealidades presentes en el convertidor de potencia DC-AC. Como se puede ver en las Figuras 5 y 6 existen no linealidades importantes en la relación del voltaje de entrada provisto por los paneles y la potencia de salida en el inversor. Los autores de (Dai & Fu, 2024) también argumentan sobre esta capacidad de las redes del tipo NARX para modelar sistemas con altas no linealidades.

Al explicar la alta precisión del modelo creado se debe notar que el mismo parte de la relación existente entre el voltaje de los paneles solares fotovoltaicos y el valor de irradiancia (El Achouby et al., 2018). Otros trabajos en la literatura toman la irradiancia como un predictor no conocido (Amer et al., 2023) agregando un importante factor de aleatoriedad. En el caso del modelo desarrollado, debido a que lo que interesa es poder capturar las no linealidades del sistema para fines de obtener un modelo tipo caja negra de todo el sistema de generación a partir de energía solar, se asume como una variable conocida el voltaje de los paneles solares fotovoltaicos.

5. Conclusión

El diseño y la optimización de sistemas de potencia pueden mejorarse mediante la simulación de un sistema que identifica automáticamente los parámetros de un inversor monofásico de bucle abierto. Este enfoque permite evaluar los diseños y las estrategias de control antes de su implementación, con el consiguiente ahorro potencial de tiempo y costes. La simulación detallada proporciona una perspectiva completa del comportamiento dinámico del inversor, identificando su respuesta y sus parámetros funcionales.

Las señales de entrada y salida se capturaron utilizando una arquitectura de inversor en MATLAB/SIMULINK. Se analizaron los algoritmos de identificación para seleccionar la estrategia más adecuada y se identificó con éxito la respuesta del inversor. Su correcto funcionamiento y adaptabilidad se confirmaron mediante la validación bajo distintas condiciones operativas. Se implementaron capturas de señales físicas en condiciones reales para soportar y validar el modelo matemático obtenido.

Se ha comprobado que las redes neuronales recurrentes son eficaces para modelar sistemas no lineales de forma flexible y adaptativa. Tienen el potencial de superar los retos asociados a la no linealidad de los sistemas y se consideran una forma muy eficaz de identificar sistemas de inversores monofásicos bajo estas condiciones.

En trabajos futuros será explorado el expandir el horizonte de predicción del modelo diseñado y agregar datos multivariados para el proceso de entrenamiento del modelo. Buscando mejorar su capacidad predictiva en un esquema temporal de mayor duración que las 24 horas que fueron validadas en este trabajo.

Bibliografía

- Amer, H. N., Dahlan, N. Y., Azmi, A. M., Latip, M. F. A., Onn, M. S., & Tumian, A. (2023). Solar power prediction based on Artificial Neural Network guided by feature selection for Large-scale Solar Photovoltaic Plant. *Energy Reports*, 9(S12), 262–266. <https://doi.org/10.1016/j.egy.2023.09.141>
- Chakraborty, R., Jain, H., & Seo, G. S. (2022). A review of active probing-based system identification techniques with applications in power systems. *International Journal of Electrical Power and Energy Systems*, 140(September 2021). <https://doi.org/10.1016/j.ijepes.2022.108008>
- Cheng, A., & Low, Y. M. (2023). Improved generalization of NARX neural networks for enhanced metamodeling of nonlinear dynamic systems under stochastic excitations. *Mechanical Systems and Signal Processing*, 200, 110543. <https://doi.org/10.1016/j.ymsp.2023.110543>
- Corzo, H., Electrónica, M. P.-D.-..., Y, A., & 2023, U. (2023). Potencial de YOLOv5 para detectar nódulos pulmonares en rayos x de tórax. *Rielac*, 44(1), e2303. <https://rielac.cujae.edu.cu/index.php/riec/article/view/916>
- Dai, J., & Fu, L. (2024). A wind speed forecasting model using nonlinear auto-regressive model optimized by the hybrid chaos-cloud salp swarm algorithm. *Energy*, 298, 131332. <https://doi.org/10.1016/j.energy.2024.131332>
- Ebead, R., Abo-Zalam, B., & Nabil, E. (2023). System identification of photovoltaic system based on fractional-order model. *Journal of Computational Electronics*, 22(1), 471–484. <https://doi.org/10.1007/s10825-022-01996-5>

- El Achouby, H., Zaimi, M., Ibral, A., & Assaid, E. M. (2018). New analytical approach for modelling effects of temperature and irradiance on physical parameters of photovoltaic solar module. *Energy Conversion and Management*, 177(August), 258–271. <https://doi.org/10.1016/j.enconman.2018.09.054>
- Euán, C., Sun, Y., & Reich, B. J. (2022). Statistical analysis of multi-day solar irradiance using a threshold time series model. *Environmetrics*, 33(3), 1–21. <https://doi.org/10.1002/env.2716>
- Fluke Corporation. (2024). *Analizadores de calidad eléctrica y energía 434-II y 435-II de Fluke*. <https://www.fluke.com/es-do/product/electrical-testing/power-quality/434-435/ds>
- Gaboitaolelwe, J., Zungeru, A. M., Yahya, A., Lebekwe, C. K., Vinod, D. N., & Salau, A. O. (2023). Machine Learning Based Solar Photovoltaic Power Forecasting: A Review and Comparison. *IEEE Access*, 11(April), 40820–40845. <https://doi.org/10.1109/ACCESS.2023.3270041>
- Gao, H., Qiu, S., Fang, J., Ma, N., Wang, J., Cheng, K., Wang, H., Zhu, Y., Hu, D., Liu, H., & Wang, J. (2023). Short-Term Prediction of PV Power Based on Combined Modal Decomposition and NARX-LSTM-LightGBM. *Sustainability*, 15(10), 8266. <https://doi.org/10.3390/su15108266>
- Gao, M., Li, J., Hong, F., & Long, D. (2019). Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LSTM. *Energy*, 187. <https://doi.org/10.1016/j.energy.2019.07.168>
- Haghi, R., Stagg, C., & Crawford, C. (2024). Wind Turbine Damage Equivalent Load Assessment Using Gaussian Process Regression Combining Measurement and Synthetic Data. *Energies*, 17(2). <https://doi.org/10.3390/en17020346>
- Lafta, F. A., Hasan, I. A., & Mohammed, M. J. (2021). Pid-pso controller for pv panel system identification models on anfis and nn-narx system. *Journal of Engineering Science and Technology*, 16(6), 4505–4517.
- Munoz, F., & Acuna, G. (2021). Time Series Forecasting using NARX and NARMAX models with shallow and deep neural networks. *2021 IEEE Latin American Conference on Computational Intelligence, LA-CCI 2021*, 1–6. <https://doi.org/10.1109/LA-CCI48322.2021.9769832>
- Patcharaprakiti, N., Kirtikara, K., Chenvidhya, D., Monyakul, V., & Muenpinij, B. (2010). Modeling of single phase inverter of photovoltaic system using system identification. *2nd International Conference on Computer and Network Technology, ICCNT 2010*, 462–466. <https://doi.org/10.1109/ICCNT.2010.120>
- Qiao, L., Xue, Y., Gui, Y., Du, W., & Wang, F. F. (2023). Comparative Study of Nonlinear Black-Box Modeling for Power Electronics Converters. *2023 IEEE Energy Conversion Congress and Exposition, ECCE 2023*, 1446–1452. <https://doi.org/10.1109/ECCE53617.2023.10362794>
- Souza Junior, M. E. T., & Freitas, L. C. G. (2022). Power Electronics for Modern Sustainable Power Systems: Distributed Generation, Microgrids and Smart Grids—A Review. *Sustainability (Switzerland)*, 14(6). <https://doi.org/10.3390/su14063597>

Comunicación alineada con los Objetivos de Desarrollo Sostenible

