



TECNOLÓGICO
NACIONAL DE MÉXICO



ACADEMIA JOURNALS
UNUS PRO SCIENTIA ET STUDIO

MAYO 25 Y 26, 2023

LA INVESTIGACIÓN EN LAS INGENIERÍAS COMO HERRAMIENTA PARA IDENTIFICAR RETOS Y OPORTUNIDADES POSTERIORES A UNA CRISIS

TRABAJOS DE INVESTIGACIÓN DEL CONGRESO
INTERNACIONAL DE INVESTIGACIÓN ACADEMIA
JOURNALS CHETUMAL 2023

ELIBRO CON ISBN ONLINE 978-1-939982-86-5

CONGRESO
ACADEMIA JOURNALS
CHETUMAL 2023

Algoritmo Matemático para Dar Seguimiento al MPP Utilizando Redes Neuronales: Revisión de Literatura

Ing. David Angel González Barbosa¹, ²Dr. David Luviano Cruz, Dr. Iván Juan Carlos Pérez Olguín³

Resumen—En este trabajo se analiza el problema de la eficiencia de los paneles solares fotovoltaicos, dando seguimiento al Máximo Punto de Potencia (MPP) de los parques solares, con la finalidad de optimizar la eficiencia. Actualmente, se han diseñado dispositivos que logran dar seguimiento al MPP y aproximan la potencia de salida de los paneles solares a la potencia de entrada de las baterías de almacenamiento. Sin embargo, invertir en paneles solares a pesar de los beneficios medioambientales es muy costoso, por lo tanto, es importante diseñar dispositivos de seguimiento al MPP. Este trabajo realiza un análisis de la literatura para diseñar un modelo matemático predictivo basado en datos de entrada-salida, utilizando un proceso de aprendizaje por regresión y para entrenar una red neuronal que prediga el MPP cumpliendo con las especificaciones de los dispositivos Maximum Power Point Tracker (MPPT), aminorando los costos de inversión de los paneles solares fotovoltaicos.

Palabras claves— Eficiencia energética, seguimiento al MPP, redes neuronales, aprendizaje por regresión.

Introducción

Con la aparición de los paneles solares se han solucionado problemas de la presencia de combustibles fósiles en el ambiente, se ha reducido el consumo de recursos naturales agotables y se han sustituido por el aprovechamiento de recursos inagotables como es el caso de la energía solar (Hernández, 2022).

Sin embargo, estos sistemas han resultado ineficientes en el aprovechamiento de la energía, una de las soluciones para maximizar la eficiencia en la entrega de energía por parte de los parques solares fotovoltaicos, es darle seguimiento al Máximo Punto de Potencia (MPP), esto trata de garantizar que una derivada de la potencia fotovoltaica con respecto a la tensión fotovoltaica debe converger a cero (Alexakis y Alexandridis, 2022a). Debido a esto se han desarrollado y profundizado varios algoritmos, siendo el más utilizado el método de perturbación y observación (P&O), este método se centra en perturbar la tensión fotovoltaica y observar cómo varía el MPP (Cuestas y Lebus, 2018). Existen otros métodos de seguimiento del MPP como es el caso de inductancia incremental, modo deslizante, ... (Méndez et al., 2019). En el mercado existe un dispositivo llamado (MPPT) que es el encargado de darle seguimiento al MPP utilizando las técnicas antes mencionadas.

Este dispositivo encarece la inversión de las celdas solares, por este motivo es necesario enfocarse en dar seguimiento al MPP mediante adquisición de datos, es por ello que se considera importante desarrollar un modelo matemático que supervise los datos de entrada y prediga cual será la potencia de salida del panel solar para que la mayor parte de esta sea almacenada por las baterías, de esta manera se disminuye el costo de las inversiones y se mantiene el objetivo de darle seguimiento al MPP en todo momento del día.

En este contexto, el presente documento realiza un análisis de los modelos y métodos existentes para dar seguimiento al MPP mediante los dispositivos de adquisición de datos, la evolución de estos, las ventajas, así como su potencial aplicación futura.

Marco Teórico

Energía renovable: Es conocido que la energía renovable son las fuentes basadas energéticamente en la utilización del sol, el viento, el agua o la biomasa vegetal/animal, entre otras. A diferencia de las fuentes convencionales, estas no utilizan combustibles fósiles, sino recursos con la habilidad de renovarse, de ahí el nombre (Frew et al., 2021).

La utilización del sol para generar electricidad ha sido un logro extraordinario de la humanidad, sin embargo, la eficiencia en la transformación de energía luminosa a eléctrica es muy baja debido a que las baterías de almacenamiento no absorben toda la energía generada por los paneles solares, esto disminuye considerablemente la eficiencia de estos.

Seguimiento al MPP: Para obtener una mejor eficiencia en los paneles solares, es aconsejable dar seguimiento al máximo punto de potencia para ocuparse de mantener este punto en todo momento del día. Con esto se logra que las

¹ David Angel González Barbosa es estudiante de la Maestría en Tecnología de la Universidad Autónoma de Ciudad Juárez, Ciudad Juárez, Chihuahua. al216577@alumnos.uacj.mx (autor corresponsal)

²David Luviano Cruz es profesor de la Universidad Autónoma de Ciudad Juárez, Ciudad Juárez, Chihuahua. david.luviano@uacj.mx

³Iván Juan Carlos Pérez Olguín es profesor de la Universidad Autónoma de Ciudad Juárez, Ciudad Juárez, Chihuahua. ivan.perez@uacj.mx

baterías de almacenamiento de energía absorban la mayor cantidad de potencia generada por los paneles fotovoltaicos (Seyedmahmoudian et al., 2018).

Dispositivos de adquisición de datos: Los sistemas de adquisición de datos (DAQ, por sus siglas en inglés): son sistemas especializados que permiten adquirir datos en tiempo real de múltiples sensores y/o instrumentos. Estos sistemas pueden ser de hardware o software y pueden ser configurados para adaptarse a diversas necesidades de adquisición de datos (Lakshmana et al., 2022; Zhang et al., 2018).

La adquisición de datos ha evolucionado significativamente a través de los años, desde las técnicas de adquisición analógicas y manuales utilizados inicialmente, hasta las tecnologías digitales y automatizadas que se utilizan hoy en día (Corbacho, 2021). Uno de los métodos utilizados para aprendizaje autónomo es mediante redes neuronales, este entrenamiento debe cumplir varios requisitos para evitar el sobre entrenamiento (over fitting) y con esto una mala predicción de los valores.

Over fitting: También conocido como sobre-entrenamiento, en una red neuronal implica una incertidumbre que resulta difícil de detectar y corregir. Para esto es importante utilizar técnicas de regularización y validación para evitar este problema y mejorar el rendimiento de la red en el cumplimiento de su función (Salman & Liu, 2019). Resolviendo este problema se puede obtener un buen análisis y predicción de datos con un objetivo predeterminado, como es el caso de adquirir datos para dar seguimiento al MPP en un parque solar fotovoltaico.

Análisis del MPPT: En las figuras 1 y 2, se muestran el MPP para diferentes condiciones de temperaturas de las celdas solares y para distintas condiciones climatológicas utilizando la técnica de P&O.




Figura 1: Características del módulo fotovoltaico para tres niveles de irradiación S y la temperatura de dos paneles diferentes: (a) potencia de salida frente a voltaje y (b) corriente frente a voltaje (Femia et al., 2005).




Figura 2: Ruta del punto de funcionamiento del MPPT utilizando P&O. Representación del MPP para diferentes niveles de irradiancia: (a) cambio lento en las condiciones atmosféricas y (b) cambio rápido en las condiciones atmosféricas (Femia et al., 2005).

Estas figuras representan aproximaciones de datos centradas en diversos valores de entrada, una de las problemáticas comunes, cuando se requiere realizar análisis de contraste de las observaciones de diversos autores, radica en la no disponibilidad de los datos, sin embargo, es posible utilizar técnicas de extracción de estos para la generación de tablas

que puedan ser utilizadas para investigaciones. En el caso de la presente investigación los datos fueron extraídos utilizando la herramienta WebPlotDigitizer, desarrollada por Rohatgi (2022).

Metodología

Aprendizaje autónomo por regresión: De los datos extraídos, se procedió a realizar un análisis de aprendizaje autónomo por regresión, para determinar un modelo matemático que permitiera el ajuste de los datos y que ofreciera la oportunidad de utilizarlos como método de inferencia. Estos datos fueron ingresados a Matlab, presentando la Figura 3 los resultados de algunos de los modelos utilizados para entrenamiento.

Model 2.24: Neural Network Status: Trained Training Results RMSE (Validation) 0.20832 R-Squared (Validation) 1.00 MSE (Validation) 0.043397 MAE (Validation) 0.13352 Prediction speed ~14000 obs/sec Training time 36.995 sec	Model 2.23: Neural Network Status: Trained Training Results RMSE (Validation) 0.19727 R-Squared (Validation) 1.00 MSE (Validation) 0.038917 MAE (Validation) 0.13768 Prediction speed ~24000 obs/sec Training time 33.869 sec	Model 2.22: Neural Network Status: Trained Training Results RMSE (Validation) 0.15384 R-Squared (Validation) 1.00 MSE (Validation) 0.023666 MAE (Validation) 0.08881 Prediction speed ~35000 obs/sec Training time 34.534 sec
Model 2.21: Neural Network Status: Trained Training Results RMSE (Validation) 0.3492 R-Squared (Validation) 1.00 MSE (Validation) 0.12194 MAE (Validation) 0.24618 Prediction speed ~10000 obs/sec Training time 35.106 sec	Model 2.20: Neural Network Status: Trained Training Results RMSE (Validation) 0.84207 R-Squared (Validation) 1.00 MSE (Validation) 0.70909 MAE (Validation) 0.57331 Prediction speed ~34000 obs/sec Training time 35.775 sec	Model 2.19: Gaussian Process Regression Status: Trained Training Results RMSE (Validation) 0.14746 R-Squared (Validation) 1.00 MSE (Validation) 0.021743 MAE (Validation) 0.084632 Prediction speed ~5700 obs/sec Training time 36.306 sec
Model 2.18: Gaussian Process Regression Status: Trained Training Results RMSE (Validation) 0.0083293 R-Squared (Validation) 1.00 MSE (Validation) 6.9377e-05 MAE (Validation) 0.0041511 Prediction speed ~16000 obs/sec Training time 36.635 sec	Model 2.17: Gaussian Process Regression Status: Trained Training Results RMSE (Validation) 0.12403 R-Squared (Validation) 1.00 MSE (Validation) 0.015383 MAE (Validation) 0.066857 Prediction speed ~16000 obs/sec Training time 37.091 sec	Model 2.16: Gaussian Process Regression Status: Trained Training Results RMSE (Validation) 0.14843 R-Squared (Validation) 1.00 MSE (Validation) 0.022031 MAE (Validation) 0.089147 Prediction speed ~20000 obs/sec Training time 29.294 sec

Figura 3: Resultados más significativos en el entrenamiento por regresión.

De dicha Figura 3, es posible identificar el modelo con menor Error Cuadrático Medio (MSE, por sus siglas en inglés), siendo el Proceso de Regresión Gaussiano (PRG) Exponencial el de mejor ajuste, la Figura 4, presenta la gráfica de datos verdaderos (color azul) y en predicción (color amarillo) por este modelo, que al ser sobrepuestas muestran los mismos valores.




Figura 4: Gráfica del PRG Exponencial.

Lamentablemente, a pesar de que el modelo resultante del proceso de entrenamiento es el de menor RMSE, se tiene el problema de sobre ajuste (over fitting), por lo que el modelo puede resultar en predicciones inadecuadas, especialmente cuando se extrapolan los resultados, es por ello que para realizar un análisis que atienda esta problemática, se procede a entrenar los datos mediante Redes Neuronales, utilizando Matlab.

Aprendizaje por redes neuronales: Para el entrenamiento de la red neuronal, se consideraron los siguientes métodos de entrenamientos: train with Levenberg-Marquardt, train with Bayesian Regularization y train with Scaled Conjugate Gradient. En la Figura 5 se muestran los pasos a seguir para comenzar el entrenamiento en Matlab.

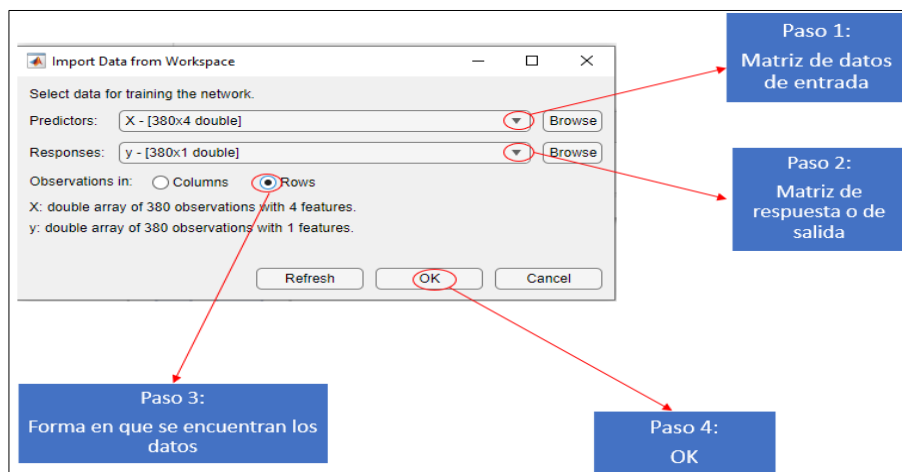


Figura 5: Como comenzar el entrenamiento de una red neuronal.

Train with Levenberg-Marquardt

El algoritmo de Levenberg-Marquardt (LMA) es un algoritmo de región de confianza que utiliza un mínimo de una (ya sea lineal o no lineal) en un ámbito de parámetros. Una zona segura de la función objetivo se modela internamente con alguna función como una cuadrática, cuando encuentra un ajuste adecuado, la zona de confianza se expande. Al igual que con muchas técnicas numéricas, el método de Levenberg-Marquardt puede ser sensible a los parámetros iniciales de partida (Bafitlhile et al., 2018).

La Tabla 1, despliega los resultados para este entrenamiento, se realizaron varios entrenamientos para lograr el menor error cuadrático medio (MSE) y la menor diferencia entre la validación y prueba, que son las variables para tener en cuenta para definir un buen entrenamiento de la red. En este caso la mejor opción se obtuvo con 9 neuronas.

Train with Bayesian Regularization

La regularización bayesiana es un proceso matemático que convierte una regresión no lineal en un problema estadístico "bien planteado" a la manera de una regresión de cresta. Estas redes brindan soluciones a una serie de problemas que surgen en el modelado QSAR (algoritmo de modelado complejo), como la elección del modelo, la solidez del modelo, la elección del conjunto de validación, el tamaño del esfuerzo de validación y la optimización de la arquitectura de la red. Son difíciles de sobreentrenar, ya que los procedimientos de evidencia proporcionan un criterio bayesiano objetivo para detener el entrenamiento. También son difíciles de sobreajustar, porque BRANN calcula y entrena en una serie de parámetros o pesos de red efectivos, desactivando efectivamente aquellos que no son relevantes (Burden & Winkler, 2008).

En este caso, la Tabla 1 despliega que se necesitaron 8 neuronas para el entrenamiento de la red neuronal, obteniendo el menor MSE en las variables antes mencionadas.

Train with Scaled Conjugate Gradient

El algoritmo de gradiente conjugado escalado (SCG), está basado en direcciones conjugadas, pero éste no realiza una búsqueda de línea en cada iteración a diferencia de otros algoritmos de gradiente conjugado. SCG fue diseñado para evitar la búsqueda de línea que consume mucho tiempo. Se utiliza para entrenar una red que actualiza peso y valores del sesgo. Es capaz de entrenar cualquier red siempre que su peso, entrada neta y funciones de transferencia tengan funciones derivada. En el algoritmo SCG, el tamaño del paso es una función de aproximación cuadrática de la función de error, lo que lo hace más robusto e independiente del usuario (Babani et al., 2016).

En este último método, la Tabla 1 indica que se necesitaron 14 neuronas para obtener el mejor MSE.

Tabla 1: Datos de entrenamiento de la red neuronal para cada método.

	Levenberg-Marquardt			Bayesian Regularization			Scaled Conjugate Gradient		
	Observations	MSE	R	Observations	MSE	R	Observations	MSE	R
Training	266	0,0460	0,9999	266	0,0332	1,0000	266	0,0253	1,0000
Validation	57	0,0326	1,0000	57	0,0405	0,9999	57	0,0232	1,0000
Test	57	0,0386	1,0000	57	0,0478	0,9999	57	0,0241	1,0000

Resultados

Para validar el modelo de entrenamiento, los datos obtenidos se dividen en tres partes, entrenamiento 70% del total de los datos, validación 15% y prueba el otro 15% de los datos, en algunas literaturas se utiliza el 60 % para entrenamiento, en este caso se utilizó la cantidad que viene por defecto en Matlab.

La Tabla 1, muestra los resultados arrojados por Matlab, donde en la columna de observaciones se tienen los datos numéricos que utilizó la red neuronal para su entrenamiento, la segunda columna muestra el MSE que existe entre estos datos y la última columna (representada por la letra R) señala la relación que existe entre los datos, es importante conocer que, para una buena relación y validación de los datos, los valores de R deben estar cercanos a la unidad.

Para este estudio, el mejor método resultó el de SCG, que con 14 neuronas logra el MSE más bajo en comparación a los otros dos modelos. El paso que le sigue a este resultado es simular el modelo en simulink y tener un acercamiento más ajustado a la realidad. No se debe descartar los resultados del estudio en regresión lineal, éste convenció la utilización de redes neuronales para la solución absoluta de este problema.

Conclusiones

En este trabajo de investigación se obtuvieron datos de gráficas de investigaciones anteriores para realizar una comparación de diferentes métodos de obtención de resultados bajo las mismas condiciones. Los resultados obtenidos pueden resultar de interés para futuros investigadores, ya que se muestra la opción de adquirir datos desde gráficas, cuando las tablas que originan la información no están disponibles, lo que es práctica común en múltiples artículos de investigación, lo que dificulta el proceso de transferencia tecnológica entre la sociedad académica.

Se realizaron entrenamientos mediante técnicas de aprendizaje por regresión y redes neuronales, donde se encontró que la técnica de aprendizaje autónomo que mejor enfrenta el sobre-entrenamiento es precisamente las redes neuronales, es por ello que se analizaron tres métodos de entrenamiento, el algoritmo de Levenberg-Marquardt, la regularización bayesiana y el algoritmo de gradiente conjugado escalado, resultando que la metodología del algoritmo de gradiente conjugado, con 14 neuronas, logró el MSE más bajo en comparación a los otros dos modelos.

Referencias

- Alexakis, Z. A., & Alexandridis, A. T. (2022). Optimization of MPP tracking algorithms for PVs with the impact of losses minimized. *IEEE International Conference on Control and Automation, ICCA, 2022-June*, 103–108. <https://doi.org/10.1109/ICCA54724.2022.9831863>
- Babani, L., Jadhav, S., & Chaudhari, B. (2016). Scaled Conjugate Gradient Based Adaptive ANN Control for SVM-DTC Induction Motor Drive. In *IFIP Advances in Information and Communication Technology* (Vol. 475, pp. 384–395). https://doi.org/10.1007/978-3-319-44944-9_33
- Bafithile, T. M., Li, Z., & Li, Q. (2018). Comparison of Levenberg Marquardt and Conjugate Gradient Descent Optimization Methods for Simulation of Streamflow Using Artificial Neural Network. *Advances in Ecology and Environmental Research*, 3(2517–9454), 217–237. <http://www.ss-pub.org/journals/aecer/vol-3/vol-3-issue-11-november-2018/>
- Burden, F., & Winkler, D. (2008). Bayesian Regularization of Neural Networks. In *Methods in Molecular Biology* (Vol. 458, pp. 23–42). https://doi.org/10.1007/978-1-60327-101-1_3
- Corbacho, R. M. (2021). *Técnicas de Inteligencia Artificial y Big Data en la Gestión Óptima de Parques Fotovoltaicos: Estado del Arte*. 1–86.
- Cuestas, S., & Lebus, L. (2018). Diseño De Un Seguidor De Punto Máximo De Potencia. *Universidad Tecnológica Nacional Facultad Regional Paraná*, 64–69.
- Femia, N., Petrone, G., Spagnuolo, G., & Vitelli, M. (2005). Optimization of perturb and observe maximum power point tracking method. *IEEE Transactions on Power Electronics*, 20(4), 963–973. <https://doi.org/10.1109/TPEL.2005.850975>
- Frew, B., Brinkman, G., Denholm, P., Narwade, V., Stephen, G., Bloom, A., & Lau, J. (2021). Impact of operating reserve rules on electricity prices with high penetrations of renewable energy. *Energy Policy*, 156(Stoft 2002), 112443. <https://doi.org/10.1016/j.enpol.2021.112443>
- Hernández, V. (2022). *Impacto de la conexión de sistemas fotovoltaicos a Sistemas Industriales considerando aspectos de calidad de la potencia*. 1–47.
- Lakshmana, K., Kaluri, R., Gundluru, N., Alzamil, Z. S., Rajput, D. S., Khan, A. A., Haq, M. A., & Alhussen, A. (2022). A Review on Deep

Learning Techniques for IoT Data. *Electronics*, 11(10), 1604. <https://doi.org/10.3390/electronics11101604>

Méndez, E. F., Mafla, G. M., & Reyes, F. J. (2019). Implementación de un algoritmo para el seguimiento del punto de potencia máxima en un panel solar mediante un control predictivo por modelo. *Espacios*, 40, 7.

Salman, S., & Liu, X. (2019). *Overfitting Mechanism and Avoidance in Deep Neural Networks*.
<https://doi.org/https://doi.org/10.48550/arXiv.1901.06566>

Seyedmahmoudian, M., Kok Soon, T., Jamei, E., Thirunavukkarasu, G., Horan, B., Mekhilef, S., & Stojcevski, A. (2018). Maximum Power Point Tracking for Photovoltaic Systems under Partial Shading Conditions Using Bat Algorithm. *Sustainability*, 10(5), 1347.
<https://doi.org/10.3390/su10051347>

Zhang, Y., Huang, T., & Bompard, E. F. (2018). Big data analytics in smart grids: a review. *Energy Informatics*, 1(1), 8.
<https://doi.org/10.1186/s42162-018-0007-5>