

Entrenamiento de un modelo ANFIS basado en un controlador neuronal en turbinas eólicas marinas

Muñoz-Palomeque, E.^a*, Santos, M.^b, Sierra-García, J.E.^c

^a *Departamento de Arquitectura de Computadores y Automática, Universidad Complutense de Madrid, Madrid, España.*

^b *Instituto de Tecnología del Conocimiento, Universidad Complutense de Madrid, Madrid, España.*

^c *Departamento de Digitalización, Universidad de Burgos, Burgos, España.*

To cite this article: Muñoz-Palomeque, E, Santos, M., Sierra-García, J.E. 2025. Training an ANFIS model based on a neural controller in offshore wind turbines. XX Simposio CEA de Control Inteligente, Huelva (Spain), 2025.

Resumen

Este estudio presenta la aplicación de un sistema de inferencia neuro-difuso adaptativo (ANFIS) para el aprendizaje de la respuesta de control de una turbina eólica marina flotante en la región de operación de Seguimiento del Punto de Máxima Potencia (MPPT). El modelo ANFIS se entrena utilizando datos generados por un controlador neuronal previamente desarrollado, con el objetivo de evaluar su capacidad para replicar el comportamiento del controlador neuronal y su viabilidad para implementarlo como alternativa de control. Los resultados muestran que ANFIS puede aproximar la estrategia de control neuronal ante diferentes cambios en las condiciones de viento, dentro de los límites de la región de carga parcial, aunque presenta limitaciones ante perturbaciones significativas, que requieren optimización. La respuesta del modelo se evalúa en términos de errores de variabilidad con datos de operación del sistema, así como señales de eficiencia en la generación de energía, con lo que se valida la línea de aplicación del modelo de soft computing y sus implicaciones para el diseño de sistemas de control en turbinas eólicas marinas flotantes.

Palabras clave: Energías renovables, Inteligencia artificial, Sistema de inferencia neuro-difuso adaptativo (ANFIS), Seguimiento del Punto de Máxima Potencia (MPPT), Control inteligente, Turbina eólica marina.

Training an ANFIS Model based on a Neural Controller in Offshore Wind Turbines

Abstract

This study presents the application of an adaptive neuro-fuzzy inference system (ANFIS) for learning the control response of a floating offshore wind turbine in the Maximum Power Point Tracking (MPPT) operating region. The ANFIS model is trained using data generated by a previously developed neural controller, with the objective of evaluating its ability to replicate the behavior of the neural controller and its feasibility to implement it as a control alternative. The results show that ANFIS can approximate the neural control strategy to different changes in wind conditions, within the limits of the partial load region, although it presents limitations in the face of significant disturbances, which require optimization. The response of the model is evaluated in terms of variability errors with system operation data, as well as power generation efficiency signals, with which the line of application of the soft computing model and its implications for the design of control systems in floating offshore wind turbines are validated.

Keywords: Renewable energy, Artificial intelligence, Adaptive Neural Fuzzy Inference System (ANFIS), Estimation, Maximum Power Point Tracking (MPPT), Intelligent, Offshore wind turbine.

1. Introducción

Las turbinas eólicas marinas flotantes (Floating Offshore Wind Turbines, FOWT, por sus siglas en inglés) representan

una solución prometedora como tecnologías para la generación de energía renovable en aguas profundas. Estas estructuras enfrentan desafíos significativos debido a las condiciones ambientales adversas, como vientos fuertes, oleaje y corrientes marinas, que pueden afectar la estabilidad del dispositivo y la

*Autor para correspondencia: edumun04@ucm.es

Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

eficiencia de la generación de energía (Zhou et al., 2024), (Asghar et al., 2024).

El control eficiente de estas turbinas, especialmente en la región de operación de carga parcial (Seguimiento del Punto de Máxima Potencia, MPPT), es crucial para maximizar la captación de energía. Tradicionalmente, se han utilizado controladores como el Proporcional-Integral-Derivativo (PID), tip speed ratio (TSR), perturb and observe, o tablas de búsqueda; sin embargo, estos pueden no ser adecuados para manejar las no linealidades y las incertidumbres inherentes a las FOWTs (Muñoz-Palomeque et al., 2024a).

Por otra parte, los controladores basados en la inteligencia artificial han demostrado ser eficaces en este contexto debido a su capacidad para manejar las no linealidades, incertidumbre y aleatoriedad en sistemas complejos (Nasim et al., 2025), (Pham et al., 2025).

En este contexto, diferentes técnicas inteligentes han sido estudiadas para procesos de control y optimización (Pande, et al., 2021). Entre ellas, las redes neuronales (Nguelcheu et al., 2025), lógica difusa (Sayeh et al., 2024), aprendizaje por refuerzo (Sierra-García et al., 2022), algoritmos genéticos y algoritmos de enjambre. Además, la aplicación de enfoques híbridos se plantea como soluciones robustas. En este grupo, los sistemas de inferencia neuro-difusos adaptativos (ANFIS) han ganado atención como una alternativa viable, los cuales combinan las capacidades de aprendizaje e interpretación de las redes neuronales y la lógica difusa. Con esta funcionalidad, el ANFIS permite modelar sistemas complejos y no lineales de manera efectiva (Santos et al., 2006).

Estudios recientes han demostrado la eficacia del ANFIS en la predicción y optimización de variables relacionadas con las turbinas eólicas, para mejorar su rendimiento. Esto proporciona las bases para su implementación eficiente en la tarea de seguimiento de la máxima potencia.

Por ejemplo, en (Phan et al., 2022) se explica el uso de un sistema ANFIS para estimar la velocidad del viento en un esquema de control adaptativo para el seguimiento de la potencia óptima, obteniendo un buen rendimiento con bajos errores de velocidad. En (Griche et al., 2022) se ha desarrollado un controlador ANFIS para turbinas eólicas que mejoran la estabilidad de la red frente a fallos eléctricos, reduciendo oscilaciones de potencia y recuperando el voltaje con rapidez. De manera similar, en (Ouhssain et al., 2024) los autores proponen un controlador ANFIS para mejorar la respuesta de máxima extracción de energía, demostrando una respuesta más rápida, baja distorsión armónica y mejor estabilidad de la red en comparación con un controlador clásico PI.

En esta línea, el presente estudio explora el uso de un sistema ANFIS como alternativa para estimar la respuesta de operación de un aerogenerador en la región de control MPPT, replicando la ley de control de un sistema neuronal, es decir, evaluando su capacidad para imitar el comportamiento de un controlador neuronal y su desempeño.

Este artículo está estructurado en las siguientes secciones. La sección 2 describe los principios de un sistema de generación de energía eólico. La sección 3 expone el diseño del modelo ANFIS y su entrenamiento. La sección 4 muestra los resultados y evaluación de desempeño con el uso del

modelo neuro-difuso. Finalmente, la sección 5 presenta las conclusiones y trabajos futuros.

2. Fundamentos teóricos

La actividad de una turbina eólica confluye en el proceso de conversión de energía cinética del viento a energía eléctrica útil. Sin embargo, su comportamiento específico para este fin está conducido por la intensidad de viento que incide sobre el sistema. De acuerdo con esta velocidad, en un sistema eólico se distinguen regiones de funcionamiento, donde el sistema actúa de una manera específica en cada una de ellas.

En términos generales, se definen cuatro regiones de operación (Pao et al., 2024):

- Región I: Consiste en una zona donde el viento no alcanza la velocidad mínima para vencer la inercia del sistema y comenzar el proceso de conversión de energía. Por lo tanto, el aerogenerador se encuentra en un estado de inactividad.

- Región II: Conocido como región de seguimiento de la máxima potencia o MPPT. En esta región, el aerogenerador es controlado para regular su velocidad y lograr las condiciones dinámicas necesarias para lograr una generación de potencia óptima que sigue un comportamiento no lineal. Se limita entre la velocidad de viento mínima de funcionamiento y la velocidad nominal de viento.

- Región III: Denominada zona de control de ángulo pitch. En esta región el viento supera la velocidad nominal y el aerogenerador opera en su máxima capacidad. Para evitar daños en el sistema y mantener una generación eficiente de energía, se controla la posición de las palas para limitar el impacto del viento y estabilizar la potencia de generación en su capacidad máxima.

- Región IV: En esta zona, el aerogenerador se apaga, ya que la velocidad del viento llega a valores muy altos que pueden afectar el sistema. Entonces, no existe producción de energía.

Durante el proceso de generación de potencia, la aerodinámica del aerogenerador y sus características constructivas definen la cantidad de energía y relaciones óptimas de variables involucradas en la eficiencia de la turbina.

La potencia que el dispositivo captura del viento se expresa en (1).

$$P = \frac{1}{2} \rho \pi R^2 V_w^3 C_p(\lambda, \beta) \quad (1)$$

De esta ecuación, ρ es la densidad del aire, R es el radio de la turbina, V_w es la velocidad del viento, β es el ángulo de pitch, λ es el tip speed ratio (TSR), y C_p es el coeficiente de potencia.

El TSR se define como la relación entre dos velocidades: la velocidad tangencial de las palas, calculada en función de la velocidad angular del rotor (ω_r), y la velocidad del viento.

$$\lambda = \frac{R \omega_r}{V_w} \quad (2)$$

En términos de esta relación, para cada una de las posiciones angulares de las palas se establece un valor de coeficiente de potencia. Esta variedad de combinaciones da lugar a un conjunto de curvas que representan la eficiencia de la turbina eólica en el proceso de captura de potencia. Este

valor está limitado por la Ley de Betz, la cual establece que la máxima potencia que la turbina eólica puede extraer del viento es del 59.3%.

3. Construcción del modelo ANFIS

3.1. Contexto de aplicación

En el estudio de los aerogeneradores, y particularmente en la etapa de control, diversas variables y fenómenos influyen sobre la respuesta dinámica del sistema.

Enfatizando en la región de operación MPPT, donde se centra este trabajo, el aerogenerador se ve sometido a cambios de las condiciones ambientales (viento, olas, corrientes), así como alteraciones producidas en sus mecanismos y dinámica interna. Ante estos cambios, el aerogenerador debe ser capaz de regular la velocidad de rotación de manera rápida y precisa, logrando un balanceo con el par electromagnético que dará lugar a una máxima potencia generada.

Sin embargo, la relación entre estas variables que toma un comportamiento no lineal, así como la influencia de perturbaciones y dinámicas complejas en el funcionamiento del dispositivo eólico, hacen necesaria la aplicación de metodologías flexibles que se adapten a esta naturaleza.

En este sentido, la adecuación entre velocidades y pares durante la transmisión del movimiento a través del sistema mecánico implica una asertiva respuesta de control.

3.2. Controlador neuronal de referencia

Con el fin de establecer una base de datos referencial para el estudio del control inteligente, se midieron, a través de simulación, diferentes variables que interactúan durante la operación controlada de MPPT de la turbina eólica.

Se aplicó un controlador neuronal utilizando una arquitectura de red de base radial (RBFNN), expresada en (3), con una capa oculta compuesta por 81 neuronas, tal como se detalla en (Muñoz-Palomeque, et al., 2024b), y entrenada con datos simulados del sistema bajo diferentes patrones de viento y oleaje.

$$T_{em_{ref}} = \sum_{i=1}^{N_1} W_i \cdot e^{-\left(\frac{\|(e\omega_g, e\dot{\omega}_g, i)\|}{\delta}\right)} \quad (3)$$

$T_{em_{ref}}$ es el par de referencia para MPPT, W_i es el peso de la neurona i , N_1 es el número de neuronas, $e\omega_g$ y $e\dot{\omega}_g$ los errores de velocidad y aceleración del generador, y δ el radio de acción de las neuronas. La expresión $\|(e\omega_g, e\dot{\omega}_g, i)\|$ denota la distancia Euclídea entre las entradas de velocidad y su derivada, y los centros de cada una de las neuronas de la red.

Esta red se incorpora en un esquema de control que, a partir de una referencia de velocidad (4), controla el correspondiente par electromagnético para lograr una efectiva conversión de energía.

$$\omega_{g.ref} = G \cdot \sqrt{\frac{T_{em} \cdot G + \frac{\dot{\omega}_g (J_r + G^2 J_g)}{G}}{K_{opt}}} \quad (4)$$

En esta expresión, G corresponde a la relación de la caja de engranes, T_{em} es el par electromagnético, J_r y J_g son los momentos de inercia del rotor y del generador, respectivamente, $\dot{\omega}_g$ es la aceleración angular del generador, y K_{opt} es la constante óptima para MPPT, misma que se escribe como:

$$K_{opt} = \frac{1}{2} \rho \pi R^5 \frac{C_{p_{opt}}}{\lambda_{opt}^3}, \quad (5)$$

donde $C_{p_{opt}}$ es el coeficiente de potencia óptimo para la máxima extracción de potencia, y λ_{opt} el correspondiente TSR óptimo que se vincula a la consecución de esa eficiencia.

3.3. Diseño y entrenamiento del modelo ANFIS

La arquitectura del modelo neuro-difuso se estructura como la integración de una red neuronal con la definición de las reglas de interpretabilidad del esquema fuzzy.

El modelo ANFIS que se diseña en este estudio se corresponde con una estructura estándar ANFIS basada en un sistema de inferencia difuso de Takagi-Sugeno con dos entradas y una salida.

Este sistema busca replicar el comportamiento de un control neuronal ejecutado en la región MPPT. Para ello, las entradas incluyen las mediciones directas de la velocidad del generador y la velocidad del viento. La salida es el par del generador que se vincula con la potencia de salida del sistema eólico de potencia. La Figura 1 ilustra este modelo ANFIS.

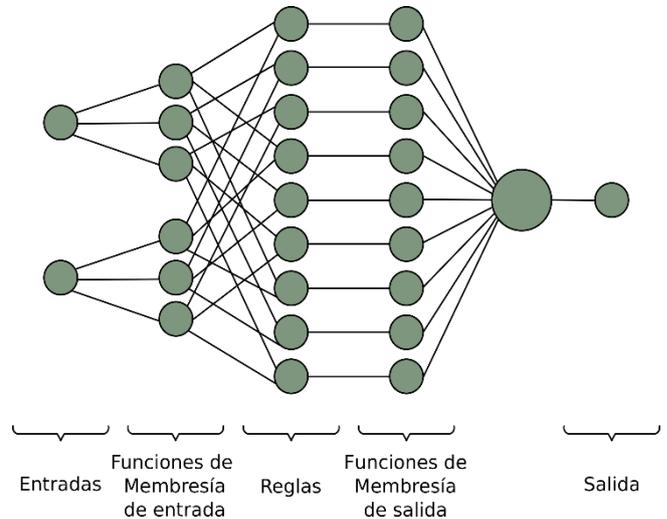


Figura 1: Estructura del modelo neuro-difuso.

El sistema neuro-difuso está compuesto por dos grupos de funciones de pertenencia, uno para cada variable, donde se definen siete funciones del tipo Gaussianas. Estas características se establecen conforme a la literatura, siendo un punto de partida que ha demostrado un adecuado rendimiento en sistemas similares.

Este conjunto de funciones conduce a la creación de 49 reglas difusas, con una configuración mediante partición de malla, que establecen los criterios de funcionamiento del modelo ANFIS para relacionar las entradas y salida del proceso.

Como técnica de entrenamiento se utiliza un algoritmo híbrido, conformado por los criterios de mínimos cuadrados y gradiente descendente, ejecutado con un número total de 100 iteraciones. En esta etapa se emplean las señales de entrenamiento obtenidas de la aplicación del controlador neuronal.

Los datos utilizados para el entrenamiento del sistema ANFIS se obtuvieron mediante simulaciones del aerogenerador operando bajo diferentes condiciones de viento dentro de la región MPPT, considerando cambios bruscos, así como suaves de este fenómeno ambiental que influye directamente sobre el dispositivo eólico.

La superficie irregular que establece la relación entre las variables involucradas en el procesamiento del modelo ANFIS, se muestra en la Figura 2.

Para las pruebas, tanto en la obtención de la base de datos como en la verificación de los resultados, se utilizó un modelo de turbina eólica marina flotante semi-sumergible basado en la referencia de 5 MW de NREL.

La simulación se realizó mediante el uso de la herramienta OpenFAST de NREL, integrada con MATLAB/Simulink para la implementación del controlador.

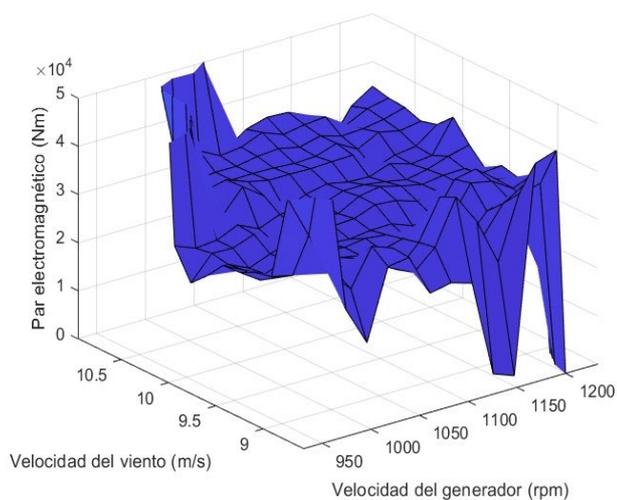


Figura 2: Superficie de procesamiento del sistema neuro-difuso.

Las pruebas se realizan con el uso de un perfil de olas (Figura 3), y un perfil de viento aleatorio (Figura 4) que replica patrones cambiantes del viento en diferentes magnitudes.

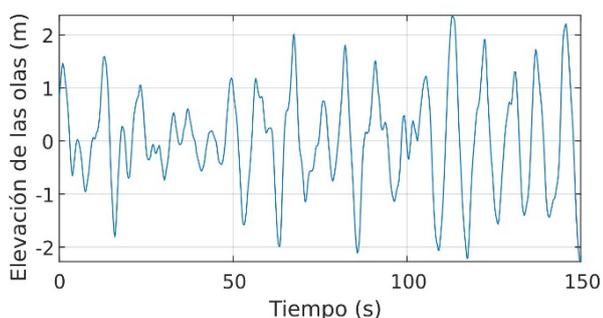


Figura 3: Perfil de olas que alteran la estabilidad del sistema eólico.

Las pruebas se realizaron en un tiempo de 150 segundos de simulación, donde los sistemas actúan sobre el aerogenerador con un periodo de control de 50ms. Este periodo es adecuado para aplicaciones de control de aerogeneradores a pequeña y mediana escala, permitiendo una operación que puede ser ejecutada en entornos en tiempo real.

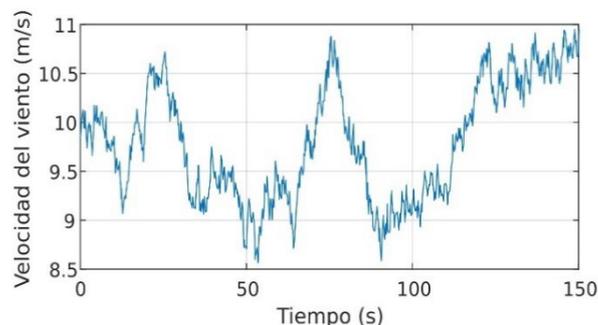


Figura 4: Perfil de viento aleatorio incidente sobre el rotor.

4. Resultados

La implementación de sistema de estimación ANFIS se analiza a continuación, destacando los resultados en su objetivo por reproducir el comportamiento de un controlador neuronal.

Entre las variables más importantes para analizar el desempeño del modelo, la Figura 5 muestra la señal potencia generada.

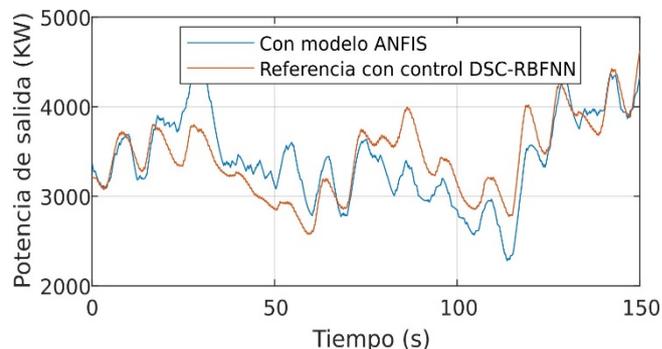


Figura 5: Comparación de la respuesta de potencia producida en el sistema eólico.

Se observa que la energía capturada por el sistema con la implementación del modelo ANFIS (línea azul), sigue la tendencia de la señal de referencia (línea roja), con mayores variaciones durante los periodos de incremento brusco de la velocidad del viento. No obstante, el sistema ANFIS desempeña una tarea satisfactoria en replicar el comportamiento de producción de potencia.

El coeficiente de potencia se ilustra también en la Figura 6, donde se verifica el buen rendimiento del sistema neuro-difuso, alcanzando altos niveles de este índice de eficiencia en la conversión de energía, próximos a los valores referenciales de los datos de entrenamiento.

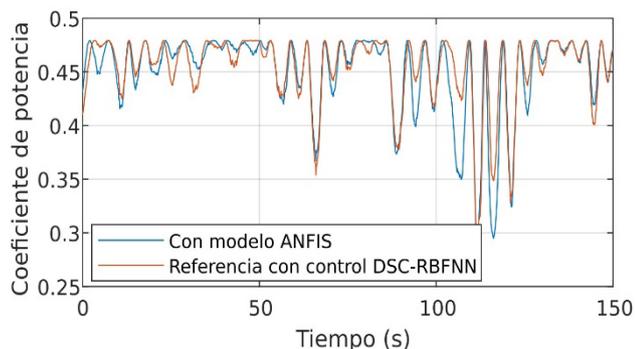


Figura 6: Comparación de la respuesta del coeficiente potencia producida en el sistema eólico.

La Figura 7 presenta la respuesta del par electromagnético que se produce con el control inteligente (línea azul). El par se proyecta con variaciones en magnitud con respecto a la señal del controlador neuronal (línea roja), dado que el modelo no se ajusta con total precisión a la complejidad de los datos y cambia la respuesta del sistema en el tiempo.

Sin embargo, la capacidad de respuesta del torque para ajustarse a los nuevos cambios de velocidad que se generan en la turbina eólica es satisfactoria. Esto hace posible que la adecuación de las variables mecánicas se ajuste al seguimiento de la potencia máxima.

Para evaluar la capacidad de aprendizaje en la réplica del control neuronal, se analizan los errores de potencia de salida.

La Figura 8 muestra el correspondiente diagrama de distribución de errores. En esta gráfica se observa que la mayor cantidad de variaciones se producen con magnitudes bajas, lo que proporciona un buen indicador de la capacidad del modelo para reproducir los datos.

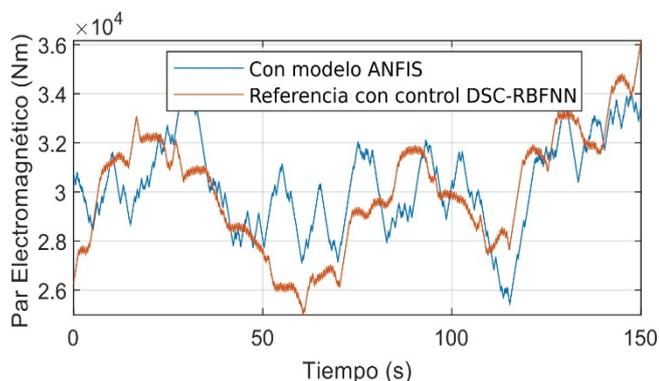


Figura 7: Comparación de la respuesta de par electromagnético de salida producida en el sistema eólico.

La potencia promedio obtenida con el sistema neuronal es de 3.42MW, mientras que la respuesta media de la réplica obtenida con el modelo ANFIS alcanza los 3.41MW, siendo una diferencia muy pequeña.

Las métricas de Error Porcentual Medio Absoluto, y del Error Relativo Promedio para las señales de potencia, corresponden respectivamente a un 8% y 9.6%, siendo una referencia de baja variabilidad en este complejo escenario.

De igual manera, el Error Cuadrático Medio y el Error Absoluto Medio, se calculan con valores de 0.11MW^2 y 0.26MW , respectivamente, reflejando buena precisión en el objetivo último de seguimiento de potencia.

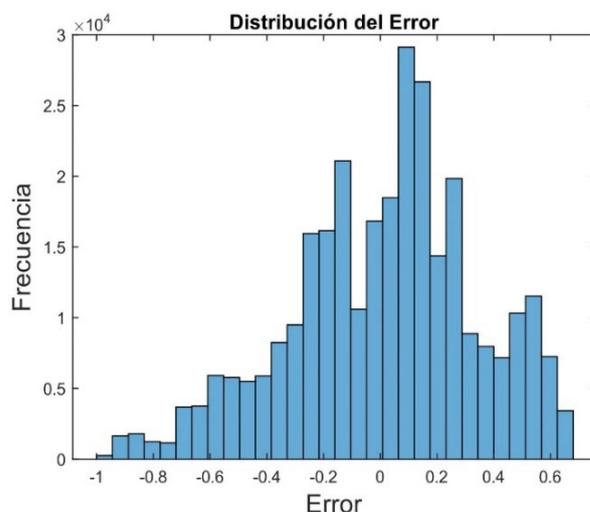


Figura 8: Distribución de la señal de error de potencia.

Los resultados indican que el ANFIS puede replicar en gran medida la estrategia de control neuronal en condiciones conocidas, ofreciendo ventajas para mejorar la flexibilidad del control en la región MPPT de una turbina eólica. Sin embargo, su capacidad de generalización es limitada, lo que sugiere la necesidad de mejorar su robustez con nuevos patrones de comportamiento del sistema y condiciones no previstas.

5. Conclusiones y trabajos futuros

El estudio demuestra que un sistema de inferencia neurodifuso adaptativo, entrenado con datos de un controlador neuronal, puede reproducir y funcionar de manera efectiva como controlador en la región MPPT de una turbina eólica marina flotante. Aunque presenta limitaciones en su capacidad de generalización, su simplicidad y eficiencia lo hacen una opción viable, la cual puede ser mejorada a través del aprendizaje de una mayor cantidad de patrones obtenidos de respuestas eficientes de otros procesos de control, o bien mediante técnicas de optimización.

Los resultados prueban la eficacia de este control inteligente para tareas en sistemas complejos que relacionan variables no lineales y de dinámicas cambiantes.

En esta línea, se busca avanzar con la integración del modelo ANFIS como un control en MPPT, incorporando mecanismos de aprendizaje online para mejorar su adaptabilidad. Asimismo, se evaluará el desempeño del ANFIS en otras regiones de operación de la turbina, junto con la optimización de su configuración en cuanto al número de funciones de pertenencia o reglas.

Además, se pretende mejorar la objetividad y generalidad en la evaluación de los resultados al utilizar como referencia directa la potencia teórica máxima extraíble por el aerogenerador, basada en la ley de Betz o en simulaciones ideales.

Agradecimientos

Este trabajo fue parcialmente financiado por el Ministerio de Ciencia e Innovación de España, como parte del proyecto MCI/AEI/FEDER PID2021-123543OB-C21.

Referencias

- Asghar, A.B. et al., 2024. Recurrent neural network for pitch control of variable-speed wind turbine. *Science Progress*, 107(2). doi:10.1177/00368504241243160.
- Griche, I. et al., 2022. A new adaptive neuro-fuzzy inference system (ANFIS) controller to control the power system equipped by wind turbine. *ITM Web of Conferences*, 42, p. 01011. doi:10.1051/itmconf/20224201011.
- Muñoz-Palomeque, E., Sierra-García, Jesús Enrique and Santos, M., 2024a. Técnicas de Control Inteligente para el seguimiento del punto de máxima potencia en Turbinas Eólicas. *Revista Iberoamericana de Automática e Informática industrial*, 21(3), pp. 193–204. doi:10.4995/riai.2024.21097.
- Muñoz-Palomeque, E., Sierra-García, J Enrique and Santos, M., 2024b. Enhancing offshore wind turbines performance with hybrid control strategies using neural networks and conventional controllers. *Journal of Computational Design and Engineering*, 12(3), pp. 80–97. doi:10.1093/jcde/qwae103.
- Nasim, F., Khatoon, S., Ibraheem, Urooj, S., Shahid, M., Ali, A., & Nasser, N. 2025. Hybrid ANFIS-PI-Based Optimization for Improved Power Conversion in DFIG Wind Turbine. *Sustainability*, 17(6), 2454. <https://doi.org/10.3390/su17062454>.
- Nguelcheu, U.N. et al., 2025. Harnessing artificial neural networks for improved control of wind turbines based on brushless doubly fed induction generator. *Engineering Applications of Artificial Intelligence*, 154, p. 110925. doi:10.1016/j.engappai.2025.110925.
- Ouhssain, S. et al., 2024. Enhancing the performance of a wind turbine based DFIG generation system using an effective ANFIS control technique. *International Journal of Robotics and Control Systems*, 4(4), pp. 1617–1640. doi:10.31763/ijrcs.v4i4.1451.
- Pande, J. et al. 2021. A review of maximum power point tracking algorithms for Wind Energy Conversion Systems. *Journal of Marine Science and Engineering*, 9(11), p. 1187. doi:10.3390/jmse9111187.
- Pao, L. Y., Pusch, M., & Zalkind, D. S. 2024. Control co-design of wind turbines. *Annual Review of Control, Robotics, and Autonomous Systems*, 7:201-226. doi.org/10.1146/annurev-control-061423-101708.
- Pham, Q.D., Nguyen, H.A. & Vu, N.TT. 2025. Adaptive dynamic programming based MPPT control for doubly-fed induction generator-wind turbine. *Neural Comput & Applic*. doi.org/10.1007/s00521-025-11247-w.
- Phan, N.M.-L. et al., 2022. ANFIS wind speed estimator-based output feedback near-optimal MPPT control for PMSG wind turbine. *Journal of Control, Automation and Electrical Systems*, 34(3), pp. 588–598. doi:10.1007/s40313-022-00980-5.
- Santos, M., López, R., & de la Cruz, J. M. 2006. A neuro-fuzzy approach to fast ferry vertical motion modelling. *Engineering Applications of Artificial Intelligence*, 19(3), 313–321. <https://doi.org/10.1016/j.engappai.2005.09.002>.
- Sayeh, K.F. et al., 2024. Fuzzy logic-enhanced direct power control for wind turbines with doubly fed induction generators. *Results in Engineering*, 24, p. 103557. doi:10.1016/j.rineng.2024.103557.
- Sierra-García, J.E., Santos, M. and Pandit, R., 2022. Wind Turbine Pitch Reinforcement Learning Control improved by PID regulator and Learning Observer. *Engineering Applications of Artificial Intelligence*, 111, p. 104769. doi:10.1016/j.engappai.2022.104769.
- Zhou, Y. et al., 2024. A model reference adaptive control framework for floating offshore wind turbines with collective and individual blade pitch strategy. *Ocean Engineering*, 291, p. 116054. doi:10.1016/j.oceaneng.2023.116054.