

Jornadas de Automática

Control neuronal híbrido ISC-DSC para la máxima extracción de energía en turbinas eólicas marinas

Eduardo Muñoz^a, J. Enrique Sierra-García^b, Matilde Santos^a

^b Instituto de Tecnología del Conocimiento, Universidad Complutense de Madrid, 28040-Madrid, España.

^a Departamento de Digitalización, Universidad de Burgos, Campus Río Vena, Avda. Cantabria, s/n, 09006 Burgos, España.

To cite this article: Muñoz, Eduardo, Sierra-García, Jesús Enrique, Santos, Matilde. 2025. Hybrid ISC-DSC neural control for maximum energy extraction in offshore wind turbines. *Jornadas de Automática*, 46. <https://doi.org/10.17979/ja-cea.2025.46.12141>

Resumen

En esta investigación se estudia la operación de control de un aerogenerador marino flotante (FOWT) de 1.5MW para el seguimiento del punto de máxima potencia (MPPT) mediante una estrategia de control neuronal híbrida ISC-DSC. El controlador propuesto aplica una red neuronal que se entrena con los datos de sistema de control indirecto de velocidad (ISC), y se integra como parte de un esquema de control directo de velocidad (DSC) para cerrar el lazo de control. Un modelo realista de turbina eólica marina, simulado con el software OpenFAST, es sometido a condiciones ambientales de viento y olas que alteran la dinámica del sistema, incrementando su complejidad. Aún frente a estas dificultades se demuestra que el controlador propuesto genera resultados satisfactorios en comparación con el sistema de control embebido de OpenFAST, utilizado como referencia. Se logra una mayor producción de energía sin causar impactos relevantes en el movimiento de la estructura.

Palabras clave: DSC, ISC, Redes neuronales, MPPT, Coeficiente de potencia, Turbina eólica marina.

Hybrid ISC-DSC neural control for maximum energy extraction in offshore wind turbines

Abstract

In this research, the control operation of a 1.5MW floating offshore wind turbine (FOWT) is studied for maximum power point tracking (MPPT) using a hybrid ISC-DSC neural control strategy. The proposed controller applies a neural network that is trained with indirect speed control (ISC) system data, and integrated as part of a direct speed control (DSC) scheme to close the control loop. A realistic offshore wind turbine model, simulated with OpenFAST software, is subjected to environmental conditions of wind and waves that alter the dynamics of the system, increasing its complexity. Even in the face of these difficulties, it is demonstrated that the proposed controller generates satisfactory results in comparison with the OpenFAST embedded control system used as a reference. Higher energy production is achieved without causing relevant impacts on the movement of the structure.

Keywords: DSC, ISC, neural networks, MPPT, Power coefficient, offshore wind turbine.

1. Introducción

Con la creciente demanda energética que se vive en el mundo, las fuentes renovables han ido adquiriendo una importancia notoria (Sierra-García, & Santos, 2020). Entre ellas, la energía eólica (Muñoz-Palomeque et al., 2024a) es

hoy en día una de las tecnologías más prometedoras. En cuanto a los aerogeneradores (WT), su alta capacidad energética, reducido impacto ambiental, bajo coste y facilidad de instalación han hecho que estos sistemas convertidores de energía eólica sean esenciales en la producción de energía. Teniendo en cuenta estos beneficios de los sistemas WT, y con

la intención de aprovechar la amplia zona libre en aguas profundas y sus condiciones favorables, las turbinas eólicas marinas se han convertido en alternativas rentables.

Por otra parte, siendo más complejo el estudio de estos dispositivos offshore debido a las rigurosas condiciones ambientales que experimentan, el diseño de un control eficiente es necesario para garantizar su correcto funcionamiento y la generación efectiva de energía. Por lo tanto, algunos de los aspectos de control de los WT como la maximización de la potencia extraída, la regulación del ángulo de las palas, la reducción del ruido y las vibraciones, entre otros (Sierra-García y Santos, 2021a; Sierra-García y Santos, 2021b) deben adaptarse a estas tecnologías de turbinas eólicas marinas.

El control del seguimiento del punto de máxima potencia (maximum power point tracking, MPPT) en los aerogeneradores, cuando la velocidad del viento está por debajo de su valor nominal, es una de las principales áreas de interés en el control del dispositivo. En los convertidores de energía eólica marina, el control también debe hacer frente a los efectos de las cargas ambientales que influyen directamente en el funcionamiento y la eficiencia del aerogenerador. En particular, en el caso de los aerogeneradores marinos flotantes (floating offshore wind turbine, FOWT), el impacto del viento y las olas en el movimiento de la estructura aumenta la complejidad de la tarea de control. Además, el estrés mecánico y las fluctuaciones de potencia son algunos de los efectos negativos que muestran estos dispositivos flotantes (Pustina et al, 2020).

Teniendo en cuenta todos estos factores y la naturaleza incierta de las perturbaciones del FOWT, la necesidad de controladores más eficaces y robustos es imprescindible. En este contexto, las redes neuronales han demostrado su capacidad para adaptarse a diferentes condiciones de funcionamiento, impulsando el avance en el ámbito de la energía eólica (Muñoz-Palomeque et al, 2023; Buestán-Andrade, et al., 2023).

Entre las distintas regiones de funcionamiento de un aerogenerador, en función de la velocidad del viento, el seguimiento del punto de máxima potencia (MPPT) busca seguir la mejor curva de coeficiente de potencia C_p , con la que se relaciona la potencia de salida, para alcanzar la mayor producción de energía. Para ello se puede utilizar un controlador como el Direct Speed Control (DSC), en el que se genera una consigna de velocidad para regular la velocidad del generador de la turbina, o la estrategia Indirect Speed Control (ISC), que genera directamente una consigna de par a partir de los parámetros característicos de la turbina. En este proceso, el ángulo de las palas se mantiene en una posición específica correspondiente al valor más bajo con el que se capta el máximo flujo de viento.

El problema del MPPT se ha abordado con métodos de control convencionales e inteligentes, tanto aplicados por separado como en configuración híbrida. Podemos mencionar algunas estrategias convencionales, como la técnica de hill-climb searching (HCS), power signal feedback (PSF), tip-speed ratio (TSR) o el control indirecto de velocidad (ISC) (Pozo et al, 2021; Ayala y Simani, 2019; Pande et al, 2021). Por otro lado, en la literatura se han propuesto controladores fundamentados en inteligencia artificial con diferentes

enfoques. En (Malobe et al, 2020), se aplica un controlador de lógica difusa (Fuzzy Logic Controller, FLC) para mejorar el control en modo deslizante de un WT. En (Muñoz et al, 2021) se afronta el problema MPPT implementando un control difuso bajo el esquema DSC. También se han utilizado redes neuronales (NN), como en (El Aissaoui et al, 2021), donde se aplican NN y FLC para la estimación de la tensión máxima y el control del convertidor DC-DC boost en un aerogenerador. En (Pathak et al, 2016), se aplica una NN de retropropagación (BPNN) para el control indirecto de la corriente en una microrred eólica. En (Chandrasekaran et al, 2020), se presenta un enfoque de NN en cascada para el control de potencia máxima.

En este trabajo se utiliza una técnica de control artificial, concretamente redes neuronales, para el control MPPT de un aerogenerador offshore flotante de 1,5MW. Se propone una estrategia de control híbrida ISC-DSC. La parte DSC obtiene una velocidad de referencia del generador y, a continuación, el controlador neuronal proporciona el par electromagnético adecuado y ajusta la velocidad del generador, siguiendo el óptimo C_p . Los pesos del controlador neuronal han sido previamente entrenados con datos del funcionamiento de un controlador ISC, de esta forma se combinan las técnicas DSC e ISC de forma satisfactoria.

El resto del documento se estructura como sigue. En la Sección 2 se describe el modelo de aerogenerador flotante. La arquitectura de control se explica en la Sección 3. En la Sección 4 se discuten los resultados. El documento finaliza con las conclusiones y futuras líneas de investigación.

2. Modelo de turbina eólica

2.1 Variables de decisión del problema.

El modelo de aerogenerador utilizado en este trabajo corresponde a una representación de turbina eólica semisumergible de 3 palas, simulado mediante el software OpenFAST. En este sistema, la altura de la torre es de 92,39 m, y la distancia medida desde el nivel del mar hasta el centro de masa de la plataforma es de 8,6 m. La plataforma está anclada al fondo marino con un sistema de amarre compuesto por 3 líneas. La WT incorpora un generador de inducción doblemente alimentado (DFIG) de 1,5 MW con una velocidad nominal de 1200 rpm que está conectado a la red.

2.2 Modelo aerodinámico

El sistema de turbina eólica captura la energía del viento de entrada a través de las palas cuando éstas son golpeadas por el viento. Este suceso genera el movimiento de la turbina y la energía se convierte en energía mecánica para mover el generador.

En esta primera etapa, la potencia mecánica que se extrae durante el funcionamiento del aerogenerador se puede expresar matemáticamente de la siguiente manera (Muñoz et al, 2020; Magdi et al, 2019):

$$P = \frac{1}{2} C_p A \rho V_w^3 \quad (1)$$

donde V_w es la velocidad del viento (m/s), ρ es la densidad del aire (kg/m^3), A es el área de barrido que cubren las palas (m^2), y C_p es el coeficiente de potencia.

El coeficiente de potencia se describe en función de dos elementos: el tip speed ratio (TSR), λ , y el ángulo de las palas, β . El coeficiente de potencia C_p denota la eficiencia en la extracción de potencia por la turbina eólica y puede ser aproximado por la expresión (2) (Yang et al, 2017). Como resultado, el C_p forma diferentes curvas de acuerdo con las características del sistema reflejadas en los coeficientes c_1 a c_6 y los valores de TSR y β .

$$C_p = c_1 \left(\frac{c_2}{\lambda_i} - c_3 \beta - c_4 \right) e^{-\frac{c_5}{\lambda_i}} + c_6 \lambda \quad (2)$$

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^3 + 1}$$

El TSR relaciona la velocidad de la punta de las palas con la velocidad del viento, como se expresa en (3).

$$\lambda = \frac{\omega_r R}{V_w} \quad (3)$$

donde ω_r es la velocidad del rotor de la turbina (rad/s) y R es la longitud de las palas (m).

Para el modelo de turbina eólica usado en este trabajo, el C_p máximo es 0.48 y el TSR óptimo es 7.1. El ángulo de las palas se fija en 2° .

2.3 Modelo mecánico

La relación mecánica de los elementos rotatorios en el sistema eólico puede definirse mediante las conexiones con la caja de engranajes. Este mecanismo funciona con dos zonas de transmisión de la velocidad del generador y el par, el eje de baja velocidad, y después de la caja de engranajes, el eje de alta velocidad. La expresión (4) (Muñoz-Palomeque, et al., 2024b) presenta la relación matemática del modelo mecánico.

$$T_r = \dot{\omega}_r (N^2 J_g + J_r) + N T_{em} \quad (4)$$

donde $\dot{\omega}_r$ es la aceleración angular del rotor (rad/s²), N es la relación de la caja de engranes, J_g y J_r son los momentos de inercia del generador y del rotor (Kg m²), y T_r es el par aerodinámico (Nm). La aceleración del rotor puede también ser descrita en términos de la aceleración del generador $\dot{\omega}_g$, como: $\dot{\omega}_r = \dot{\omega}_g/N$.

2.4 Modelo eléctrico del generador

El tipo de generador del modelo de turbina eólica de este estudio corresponde a una máquina DFIG. Su representación se puede obtener con los voltajes y flujos utilizando la transformada de Park, y las expresiones son definidas en el marco d-q (Sahri et al, 2018; Ospina, 2022). Las ecuaciones (5) y (6) presentan este modelo matemático. Cada término se expresa en el lado del estator (s) o del rotor (r).

$$V_{ds} = R_s i_{ds} + \frac{d\psi_{ds}}{dt} - \omega_e \psi_{qs} \quad (5)$$

$$\begin{aligned} V_{qs} &= R_s i_{qs} + \frac{d\psi_{qs}}{dt} + \omega_e \psi_{ds} \\ V_{dr} &= R_r i_{dr} + \frac{d\psi_{dr}}{dt} - \omega_{sl} \psi_{qr} \\ V_{qr} &= R_r i_{qr} + \frac{d\psi_{qr}}{dt} + \omega_{sl} \psi_{dr} \\ \psi_{ds} &= L_s i_{ds} + M \cdot i_{dr} \\ \psi_{qs} &= L_s i_{qs} + M \cdot i_{qr} \\ \psi_{dr} &= L_r i_{dr} + M \cdot i_{ds} \\ \psi_{qr} &= L_r i_{qr} + M \cdot i_{qs} \end{aligned} \quad (6)$$

donde V es el voltaje (V); ψ es el flujo (Wb); i es la corriente (A); R es la resistencia (Ω); L es la inductancia y M es la inductancia mutua, ambos en (H); ω_e es la velocidad angular (rad/s) y ω_{sl} es la velocidad angular de deslizamiento (rad/s). Haciendo uso de la misma transformada Park, y con p como el par de polos, el par electromagnético, T_{em} , puede ser expresado como:

$$T_{em} = p \frac{3M}{2L_s} (\psi_{qs} i_{dr} - \psi_{ds} i_{qr}) \quad (7)$$

3. Control neuronal híbrido MPPT DSC-ISC

La Fig. 1 ilustra la estrategia de control que se detalla en esta sección.

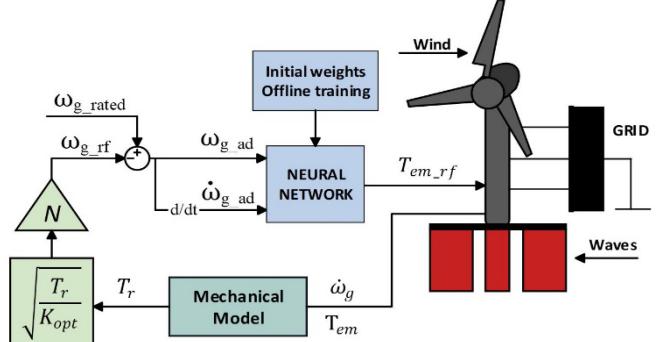


Figura 1: Esquema de control neuronal híbrido DSC-ISC.

Mediante el esquema de control DSC se obtiene una velocidad de generador de referencia ω_{g_rf} , con el fin de alcanzar la velocidad óptima del generador que garantice la máxima extracción de potencia.

La referencia de velocidad para DSC se puede expresar con (9), basada en la conexión entre la relación de la caja de engranajes N , el par del rotor T_r obtenido de (4), y un valor constante K_{opt} (8) calculado en términos del C_p óptimo y el TSR.

$$K_{opt} = \frac{\rho \pi}{2} C_{p_opt} \frac{R^5}{\lambda_{opt}^3} \quad (8)$$

$$\omega_{g_rf} = N \sqrt{\frac{T_r}{K_{opt}}} \quad (9)$$

La velocidad de referencia ajustada ω_{g_ad} , resultante de la diferencia entre ω_{g_rf} y la velocidad nominal, así como la derivada correspondiente $\dot{\omega}_{g_ad}$, se calculan para la estimación del par electromagnético, donde los efectos dinámicos están incluidos. La relación entre estas referencias y el T_{em} apropiado se determinan con la incorporación de una técnica de control.

En este caso, se aplican redes neuronales. El par electromagnético que se obtiene actúa como la referencia de par T_{em_rf} que el sistema eléctrico usa para regular el dispositivo eólico.

Esta red neuronal que determina la referencia de par T_{em_rf} cierra el lazo de control. Esta red ha sido implementada como una arquitectura de red perceptrón multicapa (MLP). Después de algunas simulaciones, la configuración de la red neuronal que ofrece el mejor resultado en la tarea de control tiene dos entradas: ω_{g_ad} y $\dot{\omega}_{g_ad}$; una capa oculta con 36 neuronas, y una variable de salida, .

Para entrenar la red neuronal, se genera un conjunto de datos utilizando el algoritmo del control indirecto de velocidad (ISC). Este esquema de control también trabaja con la constante óptima K_{opt} y la velocidad angular del rotor, como se expresa en (10). Aplicando esta técnica de control, la señal T_{em} se extrae para ser usada como la salida para el entrenamiento de la red. T_r también se mide, y la ecuación (9) se utiliza para generar la referencia de velocidad, que da lugar a las entradas de la red neuronal para el entrenamiento. De esta forma se obtiene una estrategia de control híbrida DSC-ISC.

$$T_{em_rfISC} = \omega_r^2 \cdot K_{opt} \quad (10)$$

4. Resultados y discusión

Una vez diseñado el controlador, se implementa en Matlab/Simulink, vinculado a un modelo de WT offshore que se ejecuta en OpenFAST. La simulación se realiza con entradas aleatorias de velocidad del viento y oleaje que reproducen un FOWT real. La velocidad del viento toma valores por debajo de la velocidad nominal de 11,5 m/s para operar en la región MPPT. El tiempo de simulación es de 350 s. La estrategia de control propuesta se evalúa en términos de potencia de salida, coeficiente de potencia, desplazamiento estructural y comparación con el control de par OpenFAST.

Las variables del sistema que forman parte del proceso MPPT se muestran en las siguientes figuras. En la Fig. 2 y Fig. 3 se presentan, respectivamente, el par electromagnético, T_{em} , que alcanza el dispositivo eléctrico, y la potencia de salida generada. En la Fig. 2 se puede observar cómo el T_{em} se ajusta rápidamente a las condiciones de entrada.

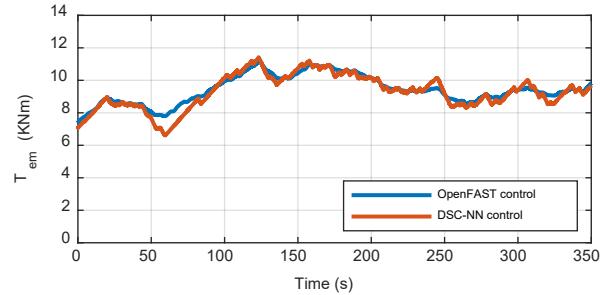


Figura 2: Par electromagnético en la operación MPPT de la WT.

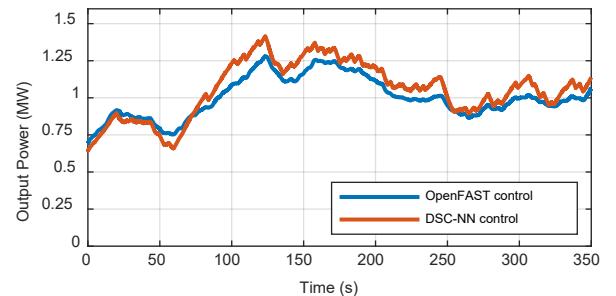


Figura 3: Salida de potencia en la operación MPPT de la WT.

Del mismo modo, la potencia de salida es bastante similar a la de OpenFast. También presenta una respuesta rápida al par aplicado, haciendo frente a la dinámica no lineal existente. El nivel de potencia con el neurocontrolador alcanza valores superiores, más cercanos al valor nominal (1,5MW), con una media de 1,056MW frente a la media de 1,003 MW con el controlador OpenFAST. Esto supone 53 kW más de potencia media. Con la regulación del par, se controla la velocidad del generador (Fig. 4). Esta variable oscila para mantener una relación velocidad-par adecuada, necesaria para el mejor funcionamiento del sistema. Se puede observar que la velocidad toma valores alrededor de la velocidad nominal del generador (1200 rpm) durante la máxima conversión de energía.

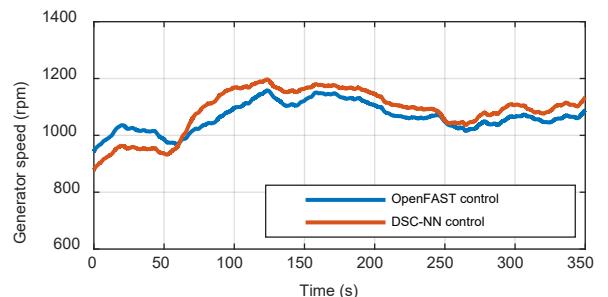


Figura 4: Velocidad del generador en la operación MPPT de la WT.

Como indicador de la eficiencia del funcionamiento del control inteligente MPPT, se mide el coeficiente de potencia (Fig. 5). Este factor ilustra cómo se obtiene la máxima generación de potencia con el controlador inteligente, ya que su respuesta se aproxima más al Cp óptimo. Por ello, se consigue con éxito el seguimiento de la curva de potencia máxima y, en consecuencia, del punto de potencia óptimo.

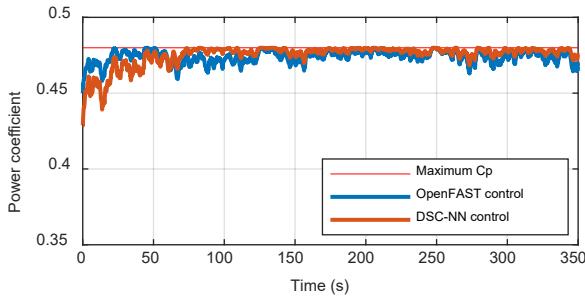


Figura 5: Coeficiente de potencia en la operación MPPT de la WT.

Por otro lado, es importante tener en cuenta la estabilidad estructural del dispositivo eólico. Las vibraciones de la estructura del aerogenerador se miden mediante el desplazamiento de la parte superior de la torre (m) en la dirección fore-aft. Este movimiento se presenta en la Fig. 6. Aquí, se puede observar que la técnica de control propuesta produce un desplazamiento ligeramente mayor en comparación con el control de par integrado en OpenFAST. En promedio, este desplazamiento es 0.2272 m con el controlador neuronal y 0.2213 m con el control OpenFAST. La diferencia es de 0,0059 m.

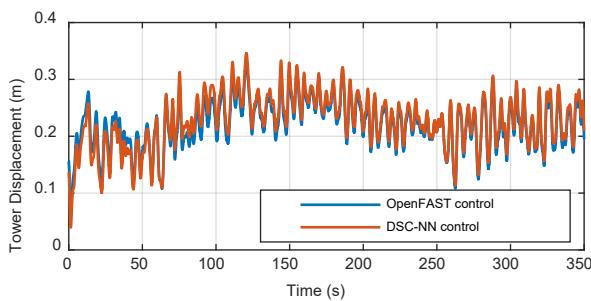


Figura 6: Desplazamiento de la torre en la operación MPPT de la WT.

Esto puede ser debido a la mayor velocidad del generador producida por el control neuronal, lo que significa un mayor efecto de las masas en el sistema, inercia, y variaciones más rápidas en las variables para un mejor y más rápido seguimiento del Cp. No obstante, las variaciones son muy pequeñas y se justifican con el aumento de la potencia extraída.

5. Conclusiones y trabajos futuros

En este trabajo se ha desarrollado una estrategia de control inteligente para la región MPPT de un aerogenerador flotante. Se propone una estrategia para combinar el control DSC y el ISC mediante el uso de redes neuronales. El controlador ha sido capaz de hacer frente a la dinámica no lineal del sistema y a las perturbaciones externas que se presentan en los aerogeneradores marinos.

La propuesta se ha comparado con el sistema de control integrado en el software OpenFast con resultados satisfactorios en términos de producción de energía. Sin embargo, a costa de producir vibraciones ligeramente mayores en la torre, aunque la diferencia puede considerarse despreciable.

Como trabajos futuros, siguiendo esta línea de investigación, proponemos la aplicación de estrategias de

aprendizaje que permitan al control adaptarse mejor a las perturbaciones del entorno. También se podría analizar cómo suavizar las vibraciones.

Agradecimientos

Este trabajo de investigación ha sido parcialmente financiado por el Proyecto MCI AEI/FEDER PDI2021-123543OB-C21, del Ministerio de Ciencia, Innovación y Universidades de España.

Referencias

- Ayala E., and Simani, S. (2019). Perturb and observe maximum power point tracking algorithm for permanent magnet synchronous generator wind turbine systems. In: Conte G (ed) Proceedings of 15th European workshop on advanced control and diagnosis – ACD. Lecture notes in control and information sciences. Alma Mater Studiorum, University of Bologna. Springer, Bologna, pp 1–11.
- Bustam-Andrade, P. A., Santos, M., Sierra-García, J. E., & Pazmiño-Piedra, J. P. (2023, August). Comparison of LSTM, GRU and transformer neural network architecture for prediction of wind turbine variables. In International conference on soft computing models in industrial and environmental applications (pp. 334-343). Cham: Springer Nature Switzerland.
- Chandrasekaran, K., Mohanty, M., Golla, M., Venkadesan, A., and Simon, S. P. (2020). Dynamic MPPT Controller Using Cascade Neural Network for a Wind Power Conversion System with Energy Management. IETE Journal of Research, 1–15.
- El Aissaoui, H., El Ougli, A., and Tidhaf, B. (2021). Neural networks and fuzzy logic based maximum power point tracking control for wind energy conversion system. Advances in Science, Technology and Engineering Systems Journal, 6(2):586–592
- Magdi M., and Mojeed, O. (2019). Adaptive and predictive control strategies for wind turbine systems: a survey. IEEE Journal Autom SINICA 6:364–378
- Malobe, P., Djondine, P., Eloundou, P. and Ndongo, H. (2020). A Novel Hybrid MPPT for Wind Energy Conversion Systems Operating under Low Variations in Wind Speed. Energy and Power Engineering, 12(12), pp.716-728.
- Muñoz, E., Ayala, E., Pozo, N., and Simani, S. (2020). Fuzzy PID Control System Analysis for a Wind Turbine Maximum Power Point Tracking Using FAST and Matlab Simulink. In Brazilian Technology Symposium (pp. 905-917). Springer, Cham.
- Muñoz, E., Ayala, E., and Pozo, N. (2021). Estrategia de Control Fuzzy PI en una Turbina Eólica con Generador de Inducción Dblemente Alimentado para Maximizar la Extracción de Potencia en Presencia de Perturbaciones. Revista Técnica "energía", 18(1), 1-10.
- Muñoz-Palomeque, E., Sierra-García, J.E., and Santos.M. (2023). Wind turbine maximum power point tracking control based on unsupervised neural networks. Journal of Computational Design and Engineering 10.1: 108-121.
- Muñoz-Palomeque, E., Sierra-García, J. E., & 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), 193-204.
- Muñoz-Palomeque, E., Sierra-García, J. E., & Santos, M. (2024b). Enhancing Offshore Wind Turbines Performance with Hybrid Control Strategies Using Neural Networks and Conventional Controllers. Journal of Computational Design and Engineering, qwae103.
- Ospina Álvarez, A. F., and Santos, M. (2022). Mechanical stability analysis of a DFIG floating offshore wind turbine using an oriented-control model. IEEE Latin America Transactions, 100.
- Pande, J., Nasikkar, P., Kotecha, K. and Varadarajan, V. (2021). A Review of Maximum Power Point Tracking Algorithms for Wind Energy Conversion Systems. Journal of Marine Science and Engineering, 9(11), p.1187.
- Pathak, G., Singh, B., and Panigrahi, B. K. (2016). Back-Propagation Algorithm-Based Controller for Autonomous Wind-DG Microgrid. IEEE Transactions on Industry Applications, 52(5), 4408–4415.

- Pozo, A., Ayala, E., Simani, S., and Muñoz, E. (2021). Indirect Speed Control Strategy for Maximum Power Point Tracking of the DFIG Wind Turbine System. Revista Técnica "energía", 17(2), 92-101.
- Pustina, L., Lugni, C., Bernardini, G., Serafini, J., and Gennaretti, M. (2020). Control of power generated by a floating offshore wind turbine perturbed by sea waves. Renew. Sustain. Energy Rev., vol. 132, p. 109984.
- Sahri, Y., Tamalouzt, S., and Belaid, S. L. (2018). Direct torque control of DFIG driven by wind turbine system connected to the grid. In 2018 International Conference on Wind Energy and Applications in Algeria (ICWEAA) (pp. 1-6). IEEE.
- Sierra-García, J. E., & Santos, M. (2020). Exploring reward strategies for wind turbine pitch control by reinforcement learning. Applied Sciences, 10(21), 7462.
- Sierra-García, J. E., and Santos, M. (2021a). Deep learning and fuzzy logic to implement a hybrid wind turbine pitch control. Neural Computing and Applications, 1-15
- Sierra-García, J. E., and Santos, M. (2021b). Neural networks and reinforcement learning in wind turbine control. Revista Iberoamericana de Automática e Informática industrial, 18(4), 327-335
- Yang, B., Zhang, X., Yu, T., Shu, H., and Fang, Z. (2017). Grouped grey wolf optimizer for maximum power point tracking of doubly-fed induction generator based wind turbine. Energy conversion and management, 133, 427-443.
- .