

Técnicas de control inteligente para el seguimiento del punto de máxima potencia en turbinas eólicas

Eduardo Muñoz-Palomeque^{a,*}, Jesús Enrique Sierra-García^a, Matilde Santos^b

^a Departamento de Digitalización, Universidad de Burgos, Burgos, España.

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

To cite this article: Muñoz-Palomeque, E., Sierra-García, J. E., Santos, M. 2024.: Intelligent control techniques for maximum power point tracking in wind turbines. Revista Iberoamericana de Automática e Informática Industrial 21, 193–204. <https://doi.org/10.4995/riai.2024.21097>

Resumen

El seguimiento del punto de máxima potencia (MPPT) es una etapa esencial en la operación de las turbinas eólicas para garantizar una generación de energía eficiente. En los últimos años se han diseñado y aplicado técnicas de control avanzadas e inteligentes para lograr este objetivo, solventando algunas de las limitaciones de los métodos clásicos. Este artículo proporciona una visión general de las estrategias existentes y describe con más detalle algunas configuraciones de control específicas, explicando su utilidad y proporcionando una base para futuros desarrollos. En concreto incluye técnicas de control basadas en la inteligencia artificial para el estudio del control MPPT en aerogeneradores. Se ejemplifican dos estrategias de control inteligente: una red neuronal y un controlador de lógica borrosa. Estos enfoques se enmarcan en la regulación del par electromagnético del generador y, en consecuencia, de la velocidad angular de la turbina eólica, mejorando la generación de energía. Los resultados evidencian los beneficios de estos controladores inteligentes para maximizar la potencia y mejorar el proceso de conversión de energía.

Palabras clave: Turbina eólica, seguimiento del punto de máxima potencia (MPPT), control inteligente, redes neuronales, control fuzzy.

Intelligent control techniques for maximum power point tracking in wind turbines

Abstract

Maximum power point tracking (MPPT) is an essential stage in the operation of wind turbines to ensure efficient power generation. In recent years, advanced control techniques have been designed and applied to achieve this objective, solving some of the limitations of classical methods. This article provides an overview of existing strategies and describes some specific control configurations in more detail, explaining their usefulness and providing a basis for future developments. Specifically, it includes control techniques based on artificial intelligence for the study of MPPT control in wind turbines. Two intelligent control strategies are exemplified: a neural network and a fuzzy logic controller. These approaches are framed in the regulation of the electromagnetic torque of the generator and, consequently, the angular velocity of the system, improving power generation. The results show the benefits of these intelligent controllers to maximize power and improve the energy conversion process.

Keywords: Wind turbine, maximum power point tracking (MPPT), intelligent control, neural networks, fuzzy control.

1. Introducción

Cada vez más el estudio de los sistemas de producción de energía se centra en la generación de energía limpia, buscando alcanzar niveles mayores de eficiencia desde su producción

hasta su transporte y almacenamiento (Ramos-Teodoro, and Rodríguez 2022).

En el caso de la energía eólica, el viento es el recurso primario que debe capturarse y aprovecharse al máximo para que las turbinas eólicas (*wind turbine*, *WT*) sean rentables.

*Autor para correspondencia: emp1016@alu.ubu.es

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

En un aerogenerador o WT se definen cuatro regiones de funcionamiento, dependiendo de la velocidad del viento que incide en la turbina, como se presenta en la Figura 1.

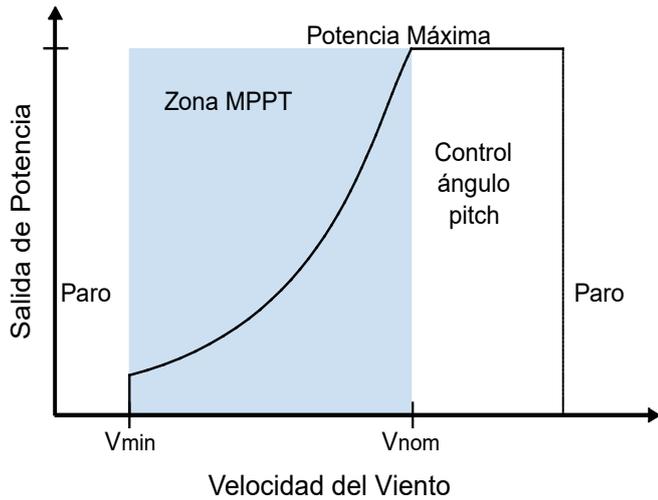


Figura 1. Regiones de operación de una turbina eólica

En la primera región el aerogenerador permanece parado debido a que la fuerza del viento no es lo suficientemente fuerte como para iniciar la rotación de la turbina y mantener el movimiento. Por lo tanto, no se produce energía.

La región 2, también conocida como de seguimiento del punto de máxima potencia (*Maximum Power Point Tracking, MPPT*), está situada entre la velocidad mínima para que el aerogenerador arranque y la velocidad nominal del viento. En ella debe garantizarse la máxima producción de potencia, para lo que se mantiene el ángulo de las palas (*pitch*) fijo y se controla la velocidad del generador a través de la regulación del par de la turbina. En esta región el aerogenerador debe seguir la curva de potencia que caracteriza su comportamiento mediante un algoritmo de control para alcanzar un funcionamiento óptimo (algoritmo MPPT). Cuando se sigue adecuadamente esta curva de potencia, específica para cada turbina, se garantiza la eficiencia aerodinámica óptima del aerogenerador (Mansouri et al. 2023) y se captura la mayor cantidad de energía del viento posible (Sitharthan et al. 2020).

Cuando la velocidad del viento supera la velocidad nominal, el sistema eólico se ve sometido a empujes y velocidades de rotación elevados (región 3 o zona de control de pitch). En esta zona de operación el ángulo de las palas debe ser controlado para cambiar el ángulo de incidencia del viento con respecto a las palas y reducir el impacto del viento. Esta acción asegura que el dispositivo se mantenga en su máxima capacidad de potencia o potencia nominal, reduciendo la velocidad de funcionamiento y el par.

Finalmente en la región 4, debido a las limitaciones estructurales del sistema eólico, éste no puede soportar velocidades de viento por encima de un valor crítico, dado por la velocidad del viento de desconexión. Para evitar daños estructurales en el sistema el aerogenerador se detiene y no hay producción de energía.

Debido a que la turbina eólica es un sistema no lineal y complejo, el algoritmo de control que procesa la velocidad del

viento, el par y otras variables relacionadas, debe estar bien diseñado para además ajustarse a las cambiantes condiciones externas y a la dinámica interna de la turbina. Como se menciona en (Zhou et al. 2023), los sistemas de energía eólica, y particularmente los aerogeneradores flotantes que son instalados en el mar (*offshore*), lejos de la costa, representan sistemas complejos que están sometidos a condiciones adversas, lo que requiere tecnologías avanzadas para su estabilidad, generación y transmisión de energía. El estudio de control MPPT es un campo de investigación abierto para la mejora de esta tecnología.

El resto del artículo se estructura de la siguiente manera. En la sección 2 se describe la curva de potencia de una turbina eólica. La sección 3 detalla las configuraciones clásicas de control MPPT. La sección 4 describe el uso del control inteligente como alternativa de aplicación para el MPPT del aerogenerador. En este apartado se destacan las redes neuronales, lógica borrosa, enfoques de control híbrido, así como aplicaciones de estrategias de optimización. Se presentan ejemplos de aplicación en la sección 5, donde se enfatiza la forma en la que son incorporadas las técnicas de *soft computing* y su viabilidad en el control de aerogeneradores. El estudio finaliza en la sección 6 con las conclusiones.

2. Curva de potencia de una turbina eólica

Un aerogenerador es un sistema integrado por diferentes etapas mecánicas y eléctricas que convierte secuencialmente la energía eólica de su entorno en energía eléctrica. La potencia mecánica que es capaz de extraer este dispositivo eólico se puede expresar mediante (1) (Sitharthan et al. 2019):

$$P_{ext} = \frac{1}{2} C_p(\lambda, \beta) A \rho V_w^3 \quad (1)$$

donde P_{ext} (W) es la potencia extraída del viento, ρ (Kg/m^3) es la densidad del aire, V_w (m/s) es la velocidad del viento, A (m^2) es el área que barren las palas, y C_p es el coeficiente de potencia.

El valor del coeficiente de potencia es un indicador de la eficiencia en la conversión eólica. Esta métrica depende del valor del *tip speed ratio*, TSR o λ , y del ángulo de paso de las palas o ángulo de pitch, β . El TSR da una medida de la relación entre el viento y la velocidad del extremo de la pala. El valor más alto del coeficiente de potencia está limitado teóricamente a 0.59, conocido como límite de Betz, que indica que el aerogenerador sólo puede convertir hasta el 59 % de la energía cinética del viento en energía mecánica. Sin embargo, los aerogeneradores suelen trabajar con valores de C_p máximos más bajos debido a pérdidas aerodinámicas (Zouheyr et al. 2021). La relación no lineal $C_p - \lambda$ se muestra en la Figura 2, donde el valor máximo corresponde al punto de seguimiento de máxima potencia.

El TSR o λ es una relación algebraica entre velocidades, en la que intervienen la velocidad de la punta de la pala y la velocidad del viento V_w (2).

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

En esta relación, ω_r (rad/s) es la velocidad del rotor de la turbina eólica y el radio R (m) es la distancia del eje central de la turbina hasta la punta de las palas.

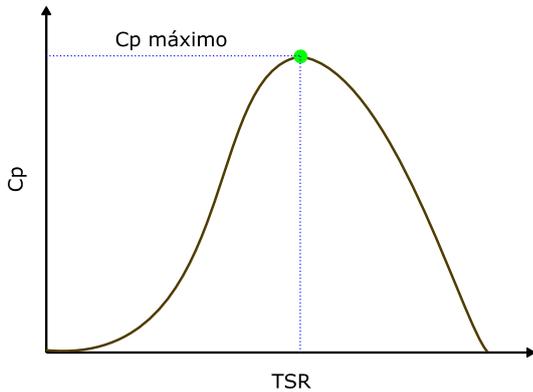


Figura 2. Curva $C_p - \lambda$ de una turbina eólica

A partir de la potencia capturada y la velocidad de la turbina ω_r se puede calcular el par aerodinámico como (Aissaoui et al. 2021):

$$T_a = \frac{P_{ext}}{\omega_r} = \frac{C_p \pi R^2 \rho V_w^3}{2 \omega_r} \quad (3)$$

3. Técnicas MPPT clásicas

3.1. Control TSR

Se han usado diferentes técnicas clásicas de control para los aerogeneradores en la región del control MPPT. Por ejemplo, el control *tip speed ratio* (TSR) se ha utilizado en algunos trabajos por ser una solución sencilla. El control TSR busca la extracción máxima de energía en función del cálculo de una velocidad de referencia (4) que utiliza la relación TSR óptima y mediciones del viento (Dida and Benattous 2015). Sin embargo, la necesidad de instrumentos de medición genera costes y afecta la eficiencia de esta técnica (Pande et al. 2021).

En la Figura 3 se muestran las variables con las que trabaja este enfoque clásico de control MPPT.

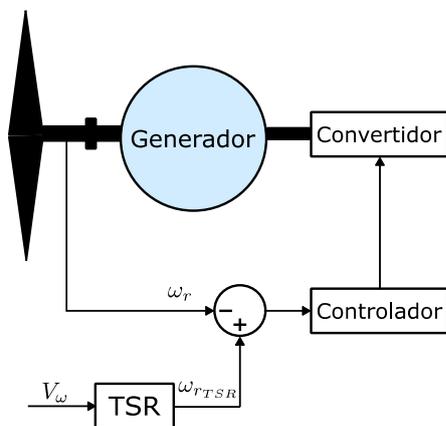


Figura 3. Técnica de control TSR

La velocidad de viento es su medición en tiempo real, de la cual depende la efectividad del control. Conociendo el factor óptimo TSR (λ^*) se puede calcular la referencia ω_{rTSR} según la ecuación (4), siendo ω_{rTSR} un indicador de la velocidad a la que debe rotar la turbina para alcanzar el máximo coeficiente de potencia y maximizar la conversión de energía.

$$\omega_{rTSR} = \frac{\lambda^* \cdot V_w}{R} \quad (4)$$

3.2. Control PSF

Otro método clásico de control MPPT es el *Power Signal Flow* (PSF), que aplica una tabla de búsqueda con la relación potencia-velocidad para obtener la referencia de potencia ideal que el sistema debe seguir (Tiwari et al. 2018). Como se ilustra en la Figura 4, la medición de la velocidad actual de la turbina es el único elemento necesario para el funcionamiento de la técnica. Esta velocidad ingresa a una base de datos preestablecida para definir la correspondiente potencia referencial, P_{ref} , a la que está relacionada y que constituye la potencia ideal de operación en la región MPPT para la velocidad medida. Este esquema de control favorece el seguimiento de la señal óptima de potencia si los datos almacenados en la tabla son fiables.

Una de las ventajas de esta estrategia es que no requiere de la medición de la velocidad del viento ya que la referencia de potencia se ajusta midiendo la velocidad de la turbina (Cheng and Zhu 2014). La información para definir la tabla de seguimiento de potencia-velocidad se puede obtener a partir de la expresión matemática de la potencia de la turbina o mediante experimentación, a través de un conjunto de datos previamente medidos (Sachan et al. 2017).

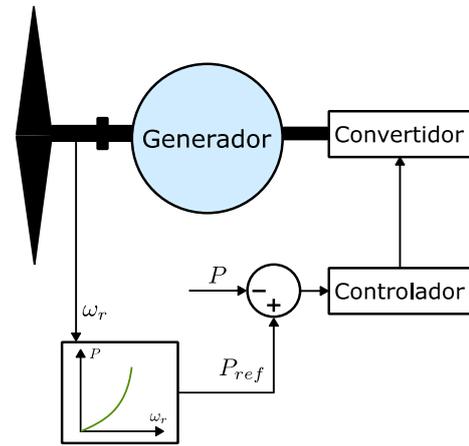


Figura 4. Esquema de control *Power Signal Flow*

3.3. Control DSC

Otra de las técnicas utilizadas es el control directo de velocidad (*Direct Speed Control, DSC*) (Muñoz et al. 2021), con el cual se regula la velocidad del generador mediante el ajuste del par electromagnético, considerando el modelo mecánico y los parámetros óptimos del aerogenerador.

La técnica DSC se ilustra en la Figura 5, donde ω_g es la velocidad del generador.

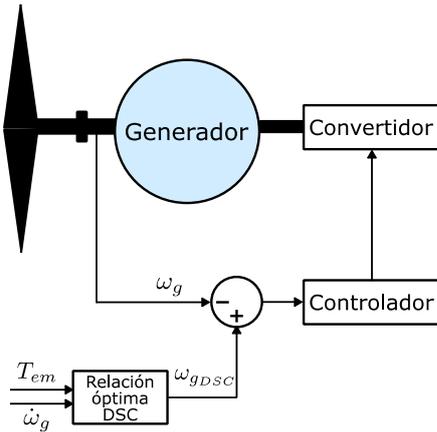


Figura 5. Control MPPT con DSC

En esta configuración de control se estima el par del rotor T_t a partir del modelo mecánico, la medida del par electromagnético T_{em} , y la aceleración del generador $\dot{\omega}_g$, mediante la siguiente relación:

$$T_t = \left(G \cdot J_g + \frac{J_t}{G} \right) \dot{\omega}_g + G \cdot T_{em} \quad (5)$$

donde G es la relación de la caja de engranajes del modelo mecánico, y J_t y J_g son los momentos de inercia de la turbina y del generador, respectivamente.

Posteriormente se calcula una referencia de velocidad ω_{gDSC} a partir del par de la turbina T_t estimado (6).

$$\omega_{gDSC} = G \sqrt{\frac{T_t}{\frac{\pi \rho R^5 C_p^*}{2 \lambda^{*3}}}} \quad (6)$$

En esta expresión, C_p^* es el coeficiente de potencia óptimo del aerogenerador, y λ^* es el correspondiente TSR óptimo.

Como se ha indicado, en el control DSC la velocidad de referencia ω_{gDSC} se calcula a partir de los parámetros óptimos de la turbina, por lo que esta señal contribuye a que el coeficiente de potencia permanezca en torno a su valor máximo de operación. Para que esta condición se cumpla y se alcance el valor de referencia, se debe implementar un controlador de velocidad. La señal de salida del controlador es el par electromagnético de referencia $T_{em,ref}$. Esta señal de par permite que la velocidad de rotación del aerogenerador siga el valor referencia, y de esta manera se logre el seguimiento de la curva óptima de operación.

Para implementar el controlador de velocidad se puede emplear un controlador convencional, como un regulador proporcional integral derivativo (PID), u otro control más avanzado. Esta etapa puede ser reemplazada por técnicas inteligentes, como las redes neuronales, lógica fuzzy, o cualquier otra alternativa que mejore el proceso de producción de energía.

3.4. Control P&O

Por otra parte, la estrategia de control *Perturb and Observe* (P&O) es otra opción popular de control MPPT que relaciona las variaciones de potencia y velocidad para estimar el punto óptimo de seguimiento de la curva de potencia. Sobresale por su facilidad de aplicación y no dependencia de instrumentos externos de medición. Mediante la incorporación de una perturbación de velocidad en forma de una señal escalón, que puede variar de amplitud, permite el ajuste de la potencia en cada iteración, apuntando al estado de pendiente cero en la curva de potencia (Ramadan et al. 2019). La Figura 6 ilustra este procedimiento para diferentes velocidades de viento, alcanzando una potencia máxima distinta en cada caso y, por tanto, observando también la relación entre velocidades y potencia. Un estado de variación positiva de potencia antes del punto de máxima potencia requiere aplicar un incremento de velocidad; mientras que un cambio negativo después del punto máximo necesita una reducción de velocidad (Mousa et al. 2021). El uso de un tamaño de paso erróneo da lugar a efectos negativos, como incrementos de oscilaciones en la respuesta a baja velocidad de operación.

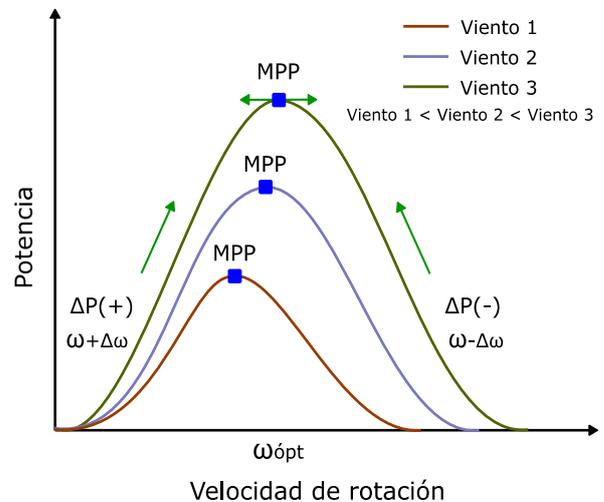


Figura 6. Principio de operación de la técnica *Perturb and Observe*

Sin embargo, a pesar de ofrecer soluciones al problema MPPT, las técnicas de control tradicionales presentan algunas desventajas. Estas limitaciones están relacionadas con una velocidad de respuesta lenta, precisión baja, falta de adaptabilidad y requerimientos de información pre-calculada o de mediciones en tiempo real que a veces son difíciles de obtener. Por ello, en la búsqueda de nuevas alternativas, se han explorado estrategias de control basadas en el uso de técnicas de inteligencia artificial. Estas técnicas inteligentes, como las redes neuronales, aprendizaje por refuerzo, o la lógica fuzzy, ofrecen mayor versatilidad y robustez para la regulación de las variables involucradas en la conversión y producción energética. Haciendo uso de estas herramientas, la no-linealidad intrínseca del sistema, las perturbaciones eléctricas y mecánicas y, en general, los efectos negativos producidos por fenómenos ambientales, estructurales y de operación, son manejados con mayor efectividad. En (Sierra-García, and Santos 2021) se exponen estrategias de control basadas en

redes neuronales y aprendizaje por refuerzo en el control del ángulo de pala en aerogeneradores, demostrando el gran potencial y utilidad de estas metodologías.

4. Estrategias de control inteligente para la máxima generación de potencia en turbinas eólicas

Dada la importancia y eficiencia de estas estrategias inteligentes, en este trabajo se presenta el uso de métodos de control inteligente en la región MPPT de turbinas eólicas, particularmente redes neuronales y control borroso. Además de recoger trabajos de la literatura, se refuerza el contenido mostrando ejemplos de aplicación con algunas técnicas. Es decir, se expone una revisión general de la integración de técnicas de control inteligente en dispositivos eólicos para el seguimiento óptimo de potencia, donde se resume cómo son utilizadas, qué variables son consideradas, con qué enfoques son aplicadas, y qué variaciones o tipos derivados de estas metodologías han sido estudiados.

La búsqueda del punto de máxima potencia (MPPT), así como la regulación simultánea de la dinámica de la turbina y del generador, es una tarea esencial en la operación del aerogenerador. Como se ha mencionado, se han aplicado diversas estrategias de control con este objetivo, utilizando diferentes relaciones entre variables, soluciones matemáticas, curvas de operación, técnicas de la inteligencia artificial, procesos de optimización, y combinaciones de los esquemas anteriores.

Teniendo en cuenta las limitaciones de las técnicas de control clásicas, como las oscilaciones de potencia y la baja velocidad de seguimiento (Manasa et al. 2022), se han explorado estrategias alternativas para mejorar la acción de control. En la literatura se encuentran metodologías inteligentes, concretamente Redes Neuronales Artificiales (*Artificial Neural Networks, ANN*), aprendizaje por refuerzo (*Reinforcement Learning, RL*), y Control Borroso (*Fuzzy Logic Control, FLC*) con diferentes arquitecturas que se han aplicado al control de estos convertidores de energía.

4.1. Redes neuronales artificiales para control MPPT de turbinas eólicas

Las redes neuronales artificiales (ANN) se han aplicado en numerosos problemas de control, incluido el MPPT en aerogeneradores. Una red neuronal es una representación artificial de la estructura del cerebro humano. Este esquema trabaja con la interconexión entre unidades neuronales a través de las cuales se procesan señales de entrada para dar una respuesta de salida.

Las redes neuronales perceptrón multicapa (*multilayer perceptron, MLP*) son arquitecturas clásicas en las que se pueden conectar secuencialmente varias capas. En la capa de entrada se introducen los datos de partida que debe gestionar la red. Ésta se conecta a continuación con una o varias capas ocultas. La capa de salida proporciona una señal $y(x_{ent})$ como resultados del procesamiento global de la red neuronal. Esta función puede ser descrita en términos de la entrada x_{ent} , del peso de la conexiones W (factor donde está representado el conocimiento), y de una señal de sesgo, b , como se expresa a continuación:

$$y(x_{ent}) = \Phi^{(n+1)}(W^{(n+1)} \cdot \Phi^{(n)}(W^{(n)} \cdot \dots \Phi^{(2)}(W^{(2)} \cdot \Phi^{(1)}(W^{(1)} \cdot x_{ent} + b^{(1)}) + b^{(2)}) \dots + b^{(n)}) + b^{(n+1)} \quad (7)$$

donde Φ es la función de activación de la neurona y los superíndices numéricos indican la capa en la que se aplica, siendo n el número total de capas ocultas de la red y $n + 1$ la capa de salida.

Las redes neuronales MLP se han usado para el control MPPT de aerogeneradores con distintos enfoques. Por mencionar algunos recientes, en (Rhaili et al. 2018) se crea una ANN que incluye como entradas el error de velocidad del rotor y su derivada, y como salida el paso de par electromagnético correspondiente. Siguiendo el concepto de TSR, para estimar la referencia de velocidad óptima del rotor y así obtener el error de entrada a la red se requiere la medición de la velocidad del viento. Esta red se entrena fuera de línea con el algoritmo de retropropagación (*backpropagation*) para determinar los pesos neuronales, utilizando una base de datos obtenida de la aplicación de un controlador PI. En (Korlepara et al. 2022), la red recibe la potencia generada y la velocidad del rotor como entradas, y la salida es la potencia de referencia. El entrenamiento se realiza mediante retropropagación utilizando el algoritmo supervisado Levenberg-Marquardt (LM). En (Chojaa et al. 2021) se propone una red MLP que complementa la técnica de control TSR. En esta arquitectura, la red recibe en la capa de entrada la velocidad del viento y la velocidad mecánica. A continuación se conectan dos capas ocultas con una función de activación sigmoidea hiperbólica, para obtener el par electromagnético de referencia en la capa de salida. El entrenamiento se realiza en modo *fuera de línea* utilizando la técnica LM para obtener el valor de los pesos con los que funcionará el controlador neuronal.

Hay trabajos en los que se usan las redes neuronales de función de base radial (*Radial Basis Function Neural Network, RBFNN*) en los aerogeneradores. En ellas se aplica la distancia radial, utilizando una sola capa oculta (Figura 7). Estas técnicas tienen como ventaja el lograr una rápida convergencia (Sitharthan et al. 2019). Se emplea típicamente una función Gaussiana como función de base radial (8) en la capa oculta. Las salidas de la red se expresan como el sumatorio del producto de la función radial y los pesos neuronales (9).

$$\Phi_j(x_{ent}) = \exp\left(-\frac{|x_{ent} - c_j|^2}{2\sigma_j^2}\right); j = 1, \dots, m \quad (8)$$

$$y_k = \sum_{j=1}^m W_{jk} \cdot \Phi_j; k = 1, \dots, s \quad (9)$$

En estas ecuaciones, $|x_{ent} - c_j|$ representa la norma de la diferencia entre la entrada x_{ent} y el centro de cada neurona c_j , W_{jk} es el peso asignado a la neurona j para el cálculo de la salida y_k , m es el total de neuronas de la capa oculta y s corresponde al número de salidas de la red.

Este enfoque se ha implementado con eficiencia en sistemas eólicos. Por ejemplo, en (Mariprasath et al. 2023) se presenta un control MPPT basado en una RBFNN de paso variable

mejorado. En (Kumar et al. 2017) se utilizan señales de tensiones y corrientes como entradas a la red de control MPPT, y las señales de ciclo de trabajo se determinan en la capa de salida. Para el seguimiento del máximo punto de potencia, en (Kumar et al. 2019) se diseña una RBFNN para actuar sobre el control del ciclo de trabajo, donde la tensión y la potencia se miden como entradas en la red. De esta forma, el control actúa directamente sobre el convertidor DC-DC que deriva en la regulación de las variables eléctricas del generador para lograr la máxima producción de potencia.

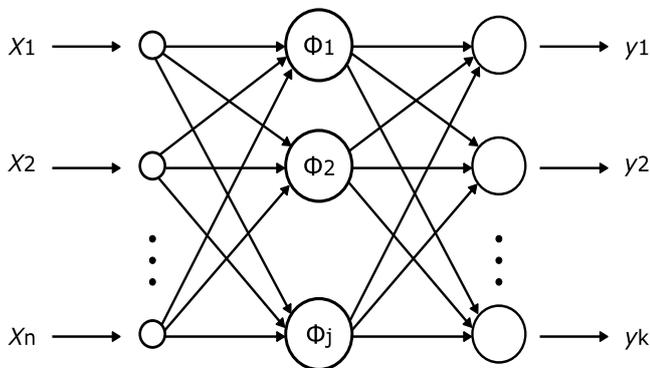


Figura 7. Arquitectura de una red neuronal de base radial

4.2. Control borroso en MPPT

El controlador basado en lógica difusa o borroso (*Fuzzy Logic Controller, FLC*) es otro método de control inteligente muy utilizado en sistemas de potencia. Es una opción robusta y sencilla basada en la experiencia y el conocimiento experto para escenarios no lineales con relaciones de datos complejas (Muñoz et al. 2021). Se basa en un proceso de inferencia que produce una respuesta rápida y suave.

La estrategia FLC se construye en tres etapas principales, (Santos et al. 2005), como se muestra en la Figura 8. En primer lugar, la fuzzificación asigna una estructura lingüística a los datos numéricos de entrada. A continuación, se realiza el proceso de inferencia según el estado lingüístico actual de la entrada y se infiere una salida en base al conjunto de reglas lógicas de control si-entonces, que representan el conocimiento. Por último, la etapa de defuzzificación aplica una relación matemática simple para obtener el valor de salida numérico a partir de la variable lingüística.

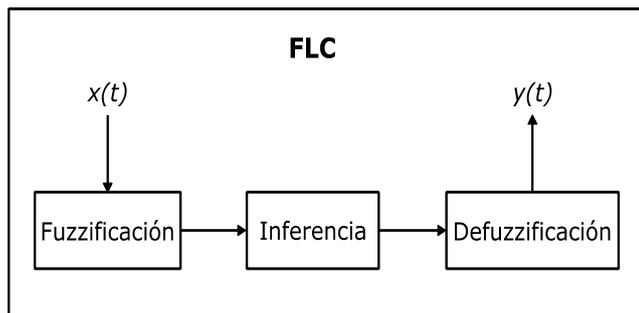


Figura 8. Etapas de funcionamiento de un controlador borroso

Algunos trabajos fundamentados en el control borroso aplicados al control MPPT de las turbinas eólicas son los siguientes. En (Salem et al. 2019) los autores implementan un control FLC basado en el modelo de Mamdani para estimar un valor de cambio en el par electromagnético que permita mantener la velocidad óptima del generador. Las entradas del controlador son el error de velocidad y la variación del error de velocidad, obtenidas a partir del método de control TSR. En (Thanh et al. 2016) se diseña un FLC para ajustar el ciclo de trabajo del convertidor DC-DC como variable de salida y, a continuación, controlar la potencia necesaria para el seguimiento del MPPT. Se trabaja con dos entradas: el cambio de la potencia y el cambio de la señal del ciclo de trabajo. Siguiendo el mismo objetivo de proporcionar un ciclo de trabajo óptimo, en (Zerouali et al. 2019) se crea un FLC para trabajar con la variación de la potencia y la variación de la tensión como variables de entrada.

Utilizando el cambio de la potencia de salida y el cambio de la velocidad del generador como variables de control, en (Ngo et al. 2020) se propone un FLC para estimar la señal de referencia del cambio de la velocidad del generador para el seguimiento de la curva de potencia máxima. Así mismo, en (George et al. 2022) un FLC de tipo Mamdani se introduce como una técnica de control MPPT que estima una señal de referencia de error de velocidad del generador, que se suma a la señal medida para obtener la referencia de velocidad que proporciona la máxima generación de potencia. Las entradas del controlador corresponden a las señales de error de velocidad y de potencia, que son ponderadas previamente mediante el uso de factores de escala.

4.3 Aprendizaje por refuerzo

Dentro del campo de la inteligencia artificial, y en particular de las técnicas de aprendizaje máquina (*machine learning*), el método de aprendizaje por refuerzo (*reinforcement learning, RL*) surge como una alternativa de aprendizaje autónomo de un sistema o agente. Esta estrategia se basa en el aprendizaje impulsado por recompensas cuando el comportamiento o resultado deseado ha sido alcanzado, optimizando el sistema tras cada acción ejercida en el entorno de operación del agente.

Como se explica en (Sierra-García et al. 2022), según el estado del entorno y las recompensas recibidas en iteraciones anteriores, el agente decide una nueva acción que genera cambios en el entorno, con la que supone que se obtendrá una recompensa superior. El lazo de control se cierra cuando existe realimentación desde el entorno al agente, proporcionando información sobre el impacto que produjo la acción, específicamente el nuevo estado generado y la recompensa obtenida. Se pueden encontrar algunas similitudes con un sistema de control tradicional, ya que el agente podría ser el controlador y el actuador, y el entorno sería análogo a la planta. Este proceso se ilustra en la Figura 9.

La relación discreta o continua entre el estado actual y las acciones a emprender se describe con el término "política". Cuando los estados y las acciones son discretas, esta relación también es discreta y generalmente se utiliza una tabla de datos para su implementación. Por otra parte, cuando los elementos son continuos la relación entre ellos es también continua,

siendo posible la utilización de una red neuronal en este caso (Sierra-García, and Santos 2021).

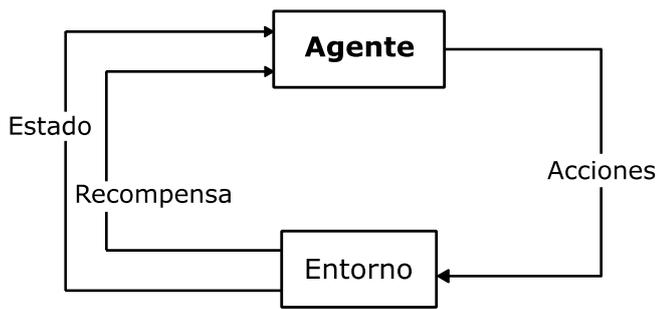


Figura 9. Diagrama general de la técnica de aprendizaje por refuerzo.

En el campo de estudio de los aerogeneradores, y particularmente en el control MPPT, la técnica de RL ha sido propuesta por algunos autores. En (Wei et al. 2016) se diseña un controlador MPPT adaptativo utilizando una ANN *feedforward* basada en el aprendizaje por refuerzo para aplicaciones en línea. En este enfoque, la ANN y la técnica de *Q-learning* son las principales etapas de aprendizaje del comportamiento del sistema, concretamente la relación entre las variables de velocidad del rotor y potencia eléctrica. La acción resultante determina el valor de cambio de la velocidad del rotor necesario para regular el sistema de energía eólica. La recompensa establecida en este trabajo puede tomar un valor de +1 o -1, en función de la variación de la potencia medida. A continuación se utiliza la relación óptima aprendida para el seguimiento de la potencia máxima. El proceso de aprendizaje se activa cuando la respuesta diverge de la relación actual aprendida. De forma similar, en (Wei et al. 2015) se presenta la aplicación de aprendizaje por refuerzo implementado con la técnica *Q-learning*. Emplea la potencia y velocidad como estados del entorno sobre los cuales aprende. El agente trabaja para proporcionar una señal de velocidad óptima que permita extraer la máxima energía del viento. Para ello recibe una recompensa con tres valores posibles, +1, 0, -1, que se determinan en función del valor de la potencia de salida. En (Vu et al. 2022) los autores proponen un controlador fuzzy adaptativo basado en la aplicación de RL para abordar el estudio de MPPT. El trabajo de (Vamvakas et al. 2023) emplea la técnica actor-crítico, donde el crítico se implementa mediante la técnica neuro-fuzzy (*Neuro-Fuzzy Inference System, ANFIS*) y se encarga de minimizar la función de error. Posee un controlador y un estimador, ambos fuzzy adaptativos, cuyos parámetros son actualizados por el algoritmo de aprendizaje. El crítico toma como entrada una función de error entre la salida del sistema y el estimador. Este dato determina la recompensa de 0 o 1 que refuerza el aprendizaje de la estrategia de control.

4.4 Métodos de Optimización

Como un complemento a las estrategias de control MPPT, se han utilizado algoritmos de optimización metaheurísticos en turbinas eólicas para mejorar ese control. En (Qais, et al. 2019) se describe un algoritmo de enjambre *salp* mejorado (ESSA) para optimizar un controlador difuso Takagi-Sugeno-Kang (TSK-FLC) en una estrategia MPPT. En (Mahmoud et al.

2020) se propone un algoritmo de búsqueda cuckoo (*cuckoo search algorithm, CSA*) y un optimizador de lobo gris (*Grey Wolf optimizer, GWO*) para ser usados en la sintonización de los parámetros de los reguladores PI aplicados en la zona del convertidor de voltaje AC-DC-AC.

Los algoritmos genéticos (*Genetic algorithms, GA*) también han sido usados como una potente herramienta de optimización. A modo de ejemplo, en (Azzouz 2019) se implementa el algoritmo TSR para MPPT utilizando un controlador PID, donde se sintoniza el controlador con GA. También, en (Muñoz-Palomeque et al. 2023b) se aplica un GA para optimizar un controlador MPPT implementado mediante una RBFNN, encontrando la mejor configuración de los parámetros de la red. En (Soliman et al. 2018) se diseña otro tipo de estrategia, un algoritmo neuronal-borroso con GA para controlar el convertidor del lado del generador y del lado de la red de un sistema eólico, y calcular las tensiones de referencia en el plano d-q. En esta propuesta se introduce el GA para encontrar los mejores parámetros del sistema de control neuronal-borroso, optimizando su configuración.

4.5 Enfoque de control híbrido

Aprovechando las ventajas de las técnicas clásicas y los métodos inteligentes, estos pueden combinarse de múltiples maneras como acciones complementarias en el sistema de control MPPT de aerogeneradores. El beneficio de cada técnica ayuda a resolver los puntos débiles de las aplicaciones individuales y mejora el funcionamiento global de la producción de energía en términos de capacidad, velocidad y precisión.

Los sistemas neuro-fuzzy (ANFIS) son un ejemplo efectivo de esta integración (Kermany et al. 2017). Por ejemplo, en (Chhipa et al. 2021) se explica la aplicación de un control ANFIS que trabaja en función de una única entrada, la velocidad del rotor, para obtener como salida un par de referencia. El modelo de controlador ANFIS que se emplea es del tipo Sugeno de primer orden, y es entrenado mediante un algoritmo de retropropagación. En otras investigaciones se diseña la arquitectura ANFIS para estimar la velocidad del viento, como en (Phan et al. 2023), actualizando los parámetros de control con la técnica de mínimos cuadrados híbridos, y controlando después la velocidad del rotor mediante un algoritmo de realimentación de salida casi óptimo para completar la operación MPPT. En (Tiwari et al. 2022) se incorpora el algoritmo ANFIS en el control de un aerogenerador, mostrando mayor precisión en la estimación de la velocidad del viento y en el seguimiento del máximo punto de potencia.

Considerando acciones de control consecutivas, los autores (Elaisaoui et al. 2020) proponen un control MPPT asignando a la red neuronal el cálculo de la tensión de salida en función de la velocidad del viento de entrada, que se utiliza para calcular una potencia de referencia y su derivada; estas variables se utilizan en la segunda etapa, en la que se aplica un FLC para estimar el ciclo de trabajo necesario para controlar el convertidor DC-DC.

Por otro lado, varios controladores del mismo tipo pueden ser también una solución. Por ejemplo, en (Chandrasekaran et al. 2022) se propone un algoritmo MPPT basado en una ANN en cascada (CNN) para estimar el ciclo de trabajo necesario

para la máxima generación de energía. En (Lee et al. 2011) se proponen dos RBFNN y un algoritmo de optimización por enjambre de partículas (PSO) para completar la estructura MPPT. La primera red estima la velocidad del viento a partir de las entradas de potencia y velocidad de rotación; el segundo módulo ANN-PSO utiliza este resultado y otros parámetros eléctricos para aproximar la potencia de salida y la tensión de control óptima relacionada.

5. Ejemplos de aplicación

Con el fin de ilustrar la aplicación del control inteligente en la maximización de potencia de aerogeneradores, en esta sección se exponen dos casos de control MPPT donde se demuestra su viabilidad y eficiencia frente al control de referencia del software de NREL OpenFAST (NREL, 2023) y un regulador clásico basado en una tabla de búsqueda.

El primer ejemplo muestra el uso de redes neuronales de base radial para una turbina flotante *offshore*, mientras que el segundo ejemplo expone la aplicación de un control de lógica fuzzy en un modelo de turbina terrestre *onshore*. Las estrategias se adaptan al marco del control de velocidad DSC. Ambos están diseñados para estimar la referencia de par electromagnético óptimo y así maximizar la producción de energía.

5.1. Red neuronal aplicada al control MPPT

El control MPPT para una turbina flotante (*Floating Offshore Wind Turbine, FOWT*) de 5 MW con una red neuronal RBFNN se describe en detalle en (Muñoz-Palomeque et al. 2023a). En ese estudio se ha utilizado un modelo de la turbina realista y no-lineal, que considera la dinámica acoplada de la misma, simulado con el software multi-físico y de alta fidelidad OpenFAST. Esta turbina flotante tipo barcaza tiene una altura de 87.6 m. La relación de la caja de engranes es 97, y relaciona el movimiento del lado de la turbina y el del generador. La relación velocidad-par es el objetivo del control. El estudio utiliza el esquema DSC (Figura 5) que integra esas variables para la regulación de la turbina eólica. En ese marco las redes neuronales son la componente central del controlador. El criterio de obtención de una referencia de velocidad inicial está dado por la relación de los parámetros y el modelo de la turbina, resumidos en (5) y (6). Esta variable debe estar relacionada con el par electromagnético a través de un controlador, en este caso las redes neuronales. Además, en la estrategia de control se ha añadido un regulador PID para reducir las vibraciones estructurales de la torre. Con un enfoque no supervisado, la red neuronal se adapta en tiempo real a las condiciones de entrada en cada iteración. Así se construye una ley de control que se adapta de forma continua. La estructura de la red neuronal ha sido configurada mediante algoritmos genéticos (GA). La Figura 10 muestra este esquema de control híbrido.

Como el objetivo es controlar el par del generador, las entradas a la red son el error de velocidad del generador y su derivada, $E\omega_g$ y $E\dot{\omega}_g$ respectivamente. Este error es la diferencia entre la velocidad angular de referencia y su valor actual. El número de neuronas de la red N_T , será el producto de la cantidad de neuronas de cada variable, $N_{E\omega_g}$ y $N_{E\dot{\omega}_g}$ (10).

$$N_T = N_{E\omega_g} \cdot N_{E\dot{\omega}_g} \quad (10)$$

La ley de control se basa en la distancia euclídea normalizada, d_r , calculada en función de la entrada y los centros de cada una de las neuronas de la red (11).

$$d_r(i, E\omega_g, E\dot{\omega}_g) = \sqrt{\frac{(c_{i1} - E\omega_g)^2}{\max(E\omega_g)^2} + \frac{(c_{i2} - E\dot{\omega}_g)^2}{\max(E\dot{\omega}_g)^2}} \quad (11)$$

donde i es la neurona con respecto a la cual se calcula la distancia, siendo c_{i1} y c_{i2} las coordenadas del centro de la neurona.

Esta distancia se utiliza para generar la referencia de par $T_{em_{NN}}$ (12) que el aerogenerador debe seguir.

$$T_{em_{NN}} = - \sum_{i=1}^{N_T} W_i \cdot e^{-\left(\frac{d_r(i, E\omega_g, E\dot{\omega}_g)}{\delta}\right)} \quad (12)$$

En esta expresión también se identifica un parámetro de influencia de la neurona, δ , así como el peso W que se asigna a la misma. Como resultado, la suma de las contribuciones de cada conexión neuronal da lugar a la estimación del par requerido.

El aprendizaje de la red se realiza a través de la variación de los pesos. La ley de aprendizaje (13) considera los pesos neuronales actuales que dependen de las mediciones radiales y los modifica según el valor del error de velocidad y su derivada. Esta expresión está inspirada en el algoritmo de aprendizaje clásico de actualización de los pesos de la capa de salida de las redes de función de base radial. En el algoritmo clásico la señal de error viene dada por la diferencia entre la salida esperada y la salida de la red. En este caso de aplicación, la señal de error de entrenamiento se sustituye por la señal de error del controlador. En ambos casos el objetivo del entrenamiento es reducir la señal de error a cero.

$$W_i(t) = W_i(t-1) + \left(K_1 E\omega_g(t) + K_2 E\dot{\omega}_g(t) \right) \cdot \mu \cdot e^{-\left(\frac{d_r(i, E\omega_g, E\dot{\omega}_g)}{\delta}\right)} \quad (13)$$

Por último, el controlador PID utiliza el error de aceleración del movimiento de la torre, Ea_{TT} , medido a la altura de la góndola, para encontrar un par (14) que es combinado con el obtenido por la red neuronal y que ayuda a reducir las vibraciones. Este par final será utilizado por el aerogenerador para el seguimiento del punto de potencia máximo.

$$T_{em_{PID}}(t) = k_p E a_{TT}(t) + k_d \frac{d(E a_{TT}(t))}{dt} + k_i \int E a_{TT}(t) dt \quad (14)$$

En las pruebas de simulación el sistema es sometido a un perfil de viento aleatorio que oscila entre los 9 m/s y 11.5 m/s, y un estado de olas que varían su elevación entre 4 m por debajo del nivel del mar y 3.5 m por encima del nivel del mar.

Como resultado de la aplicación de esta estrategia de control híbrida se observa un aumento de la energía extraída, a la vez que se reduce la amplitud de las vibraciones en la estructura de la turbina respecto a la solución de referencia implementada por el software OpenFAST. La Figura 11(a) muestra la potencia generada, donde se observa un nivel muy próximo al valor nominal de 5MW para las condiciones de mayor velocidad de viento, y con menos oscilaciones que el correspondiente obtenido con OpenFAST.

Esto es debido a que se ha conseguido una mayor velocidad de rotación, cercana al valor nominal de la turbina, de 1200

rpm. El coeficiente de potencia se mantiene cercano y con pocas variaciones en su valor óptimo, que para esta turbina específica es 0.48.

Como se observa en la Figura 11(b), también se consigue la reducción en el movimiento de la estructura. La amplitud de los picos significativos en el rango de frecuencias de 0.05 Hz a 0.15 Hz es menor. Con este resultado se evidencia que el controlador basado en redes neuronales logra atenuar el efecto de las vibraciones y mejora la productividad en la conversión de energía.

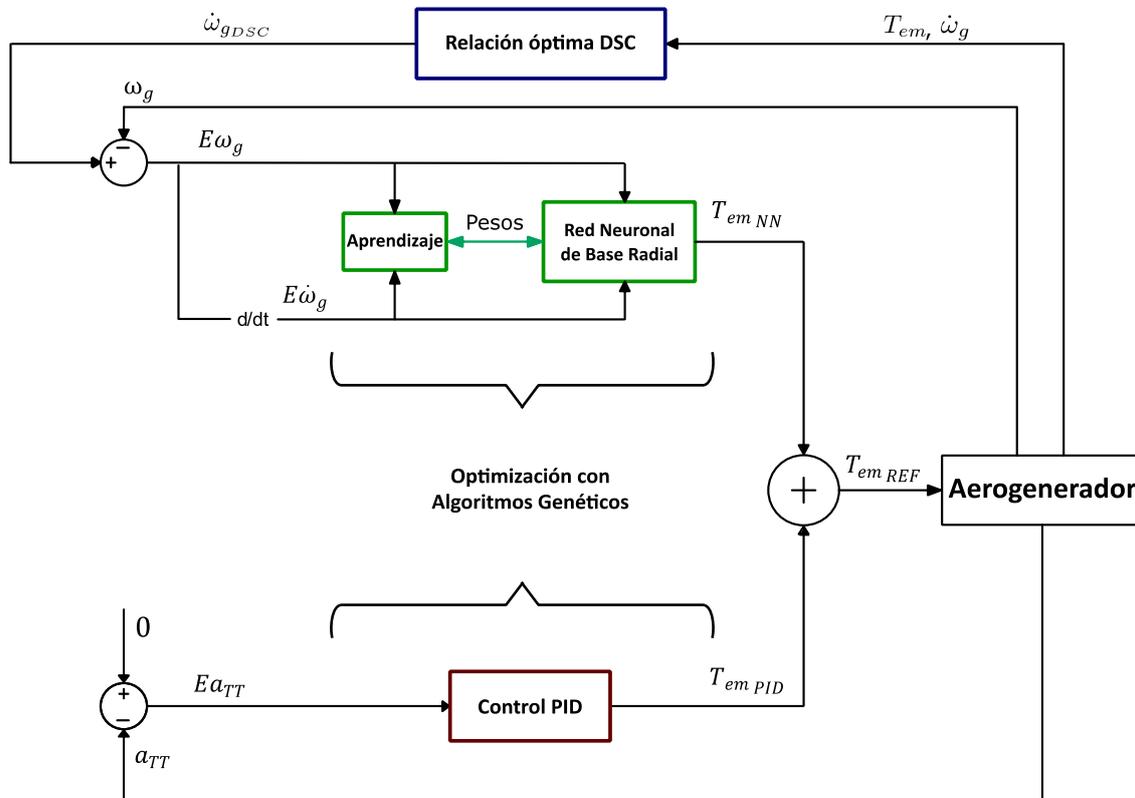


Figura 10. Esquema de control MPPT con red neuronal, PID y GA para una turbina eólica flotante (Muñoz-Palomeque et al. 2023a)

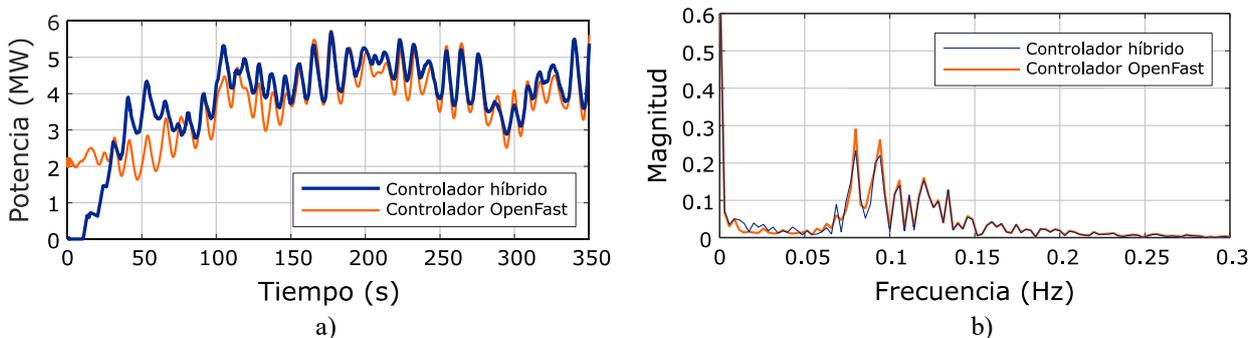


Figura 11. Potencia extraída (a) y Espectro de frecuencia de las vibraciones (b) con control híbrido basado en redes RBFNN (Muñoz-Palomeque et al. 2023a)

Con esta estrategia de control se consigue un incremento del 4.28% en la potencia media generada por la turbina eólica (de 3.69 a 3.85 MW) y, a la vez, una reducción del 9.88% de la tasa de vibraciones. Esta última métrica se calcula como la

diferencia de las desviaciones estándar de las señales de oscilaciones con OpenFAST y con el control híbrido, dividido entre la correspondiente a OpenFAST. Estos resultados corroboran las ventajas de la estrategia de control inteligente.

5.2. Lógica fuzzy aplicada al control MPPT de una turbina eólica

Otra alternativa de la inteligencia artificial para sistemas no lineales es la lógica borrosa. Un ejemplo de aplicación de este tipo de control inteligente para el MPPT de una turbina eólica onshore se describe en (Muñoz et al. 2021). En este trabajo se diseña un control borroso de tipo Mamdani para regular el par electromagnético mediante cambios en la señal. De esta manera, el par producido permite ajustar la velocidad de la turbina siguiendo la referencia que da lugar a la máxima generación de energía. En la Figura 12 se resume el esquema de control donde se observa la relación entre estos elementos. En esta propuesta la referencia de velocidad es calculada utilizando la relación de control DSC, que hace uso del modelo mecánico de transmisión y los parámetros de óptima operación del aerogenerador. Se ha aplicado a un modelo de turbina eólica terrestre de 1.5 MW, con 85.5 m. de diámetro, con una relación de engranes de 72, y con una entrada de viento que oscila entre los 5.5 m/s y los 10 m/s.

Las entradas del controlador son el error de velocidad del generador y su variación, que guardan una relación directa con el par electromagnético. Para el diseño del controlador se utilizan 7 conjuntos borrosos con funciones de pertenencia triangulares y dos trapezoidales en los extremos, como se muestra en la Figura 13.

Las etiquetas con las que se identifican a las funciones de pertenencia son Cero (Z), Alto-Positivo (HH-P), Medio-Positivo (MM-P) y Bajo-Positivo (LW-P), y Alto-Negativo (HH-N), Medio-Negativo (MM-N) y Bajo-Negativo (LW-N).

El conjunto de las reglas de control para procesar la información de entrada se presenta en la Tabla 1. La salida del controlador difuso es un factor de cambio que se aplica a la señal de par con el objeto de incrementar o disminuir su valor actual y lograr que el sistema alcance la referencia de velocidad.

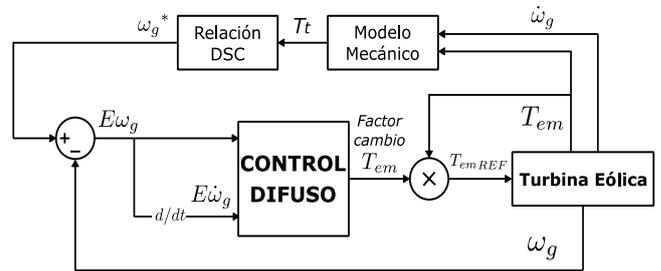


Figura 12. Esquema de control MPPT de una turbina eólica con lógica difusa.

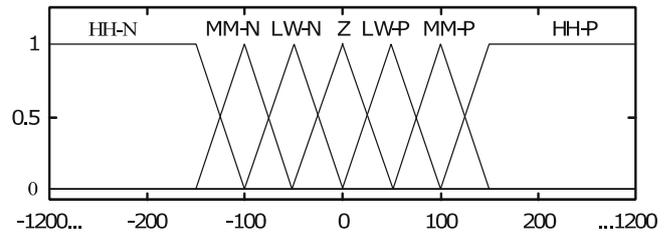


Figura 13. Funciones de pertenencia del error de velocidad del control borroso MPPT (Muñoz et al. 2021).

Tabla 1. Reglas de control fuzzy para MPPT (Muñoz et al. 2021).

		Variación del Error, ΔE(n)						
		HH-N	MM-N	LW-N	Z	LW-P	MM-P	HH-P
Error, E(n)	HH-N	HH-P	HH-P	MM-P	MM-P	MM-P	LW-P	Z
	MM-N	MM-P	MM-P	LW-P	LW-P	LW-P	Z	LW-N
	LW-N	MM-P	LW-P	Z	Z	Z	LW-N	LW-N
	Z	MM-P	LW-P	Z	Z	Z	Z	LW-N
	LW-P	MM-P	LW-P	Z	Z	LW-N	LW-N	MM-N
	MM-P	MM-P	Z	LW-N	LW-N	LW-N	MM-N	MM-N
	HH-P	LW-P	LW-N	MM-N	MM-N	MM-N	HH-N	HH-N

Los resultados de esta estrategia de control inteligente muestran rapidez y precisión en el seguimiento del estado óptimo de la turbina, como se puede apreciar en la señal de potencia (Figura 14), como resultado de la evolución del coeficiente de potencia (valor máximo 0,5) y de la velocidad de rotación. El par inducido se adecúa a la dinámica de la turbina eólica y se equilibra con la velocidad para lograr una máxima extracción de energía. Este control fuzzy ha sido comparado con un control convencional que utiliza una tabla de búsqueda para relacionar la potencia y la velocidad del rotor en la región MPPT.

El controlador actúa rápidamente en respuesta a las fluctuaciones del viento que alteran la dinámica del sistema. La potencia generada alcanza niveles más altos con el control fuzzy que con el clásico, en una relación de 0.67 MW a 0.64 MW de potencia media extraída, respectivamente. Es decir, un

incremento del 5.11% al utilizar el controlador inteligente basado en lógica fuzzy. Este resultado da lugar a una mejora de productividad del convertidor de energía eólica.

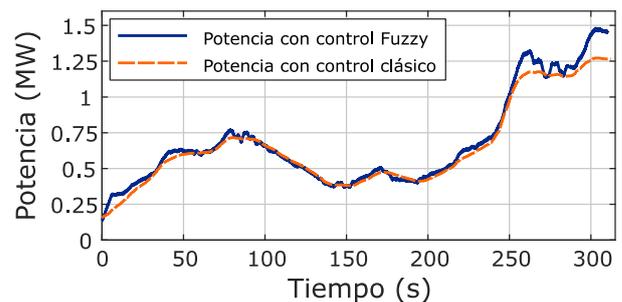


Figura 14. Potencia extraída con el control fuzzy (Muñoz et al. 2021).

6. Conclusiones

En este artículo se muestra la importancia de las estrategias de la inteligencia artificial para cumplir los objetivos del control MPPT en aerogeneradores. Se han resumido algunas técnicas de control convencional para el control MPPT, y se introducen técnicas de control inteligente que han mostrado su aplicabilidad en este ámbito de control.

Se han presentado dos ejemplos de esquemas de control inteligente, que emplean redes neuronales y lógica difusa. Con estos métodos se ilustra la implementación de controladores MPPT inteligentes para la correspondiente región de operación de la turbina eólica. Los resultados corroboran una mejora de la potencia generada y la reducción de vibraciones.

Al ser las energías renovables, y en particular la energía eólica, un sector emergente, éste es un campo abierto a la investigación y a la exploración de nuevas soluciones de control que aporten al mejoramiento de su eficiencia de operación tanto en turbinas *onshore* como *offshore*.

Agradecimientos

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación español en el marco del Proyecto MCI/AEI/FEDER número PID2021-123543OB-C21.

Referencias

- Aissaoui, H.E., Ougli, A.E., 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. DOI: 10.25046/aj060267
- Azzouz, S., 2019. Innovative PID-GA MPPT Controller for Extraction of Maximum Power from Variable Wind Turbine. *Electrotechnical Review* 1(8), 117–122. DOI: 10.15199/48.2019.08.26
- Chandrasekaran, K., Mohanty, M., Golla, M., Venkadesan, A., Simon, S.P., 2022. Dynamic MPPT Controller Using Cascade Neural Network for a Wind Power Conversion System with Energy Management. *IETE Journal of Research* 68(5), 3316–3330. DOI: 10.1080/03772063.2020.1756934
- Cheng, M., and Zhu, Y., 2014. The State of the Art of Wind Energy Conversion Systems and Technologies: A Review. *Energy Conversion and Management*, 88, 332–47. DOI: 10.1016/j.enconman.2014.08.037.
- Chhipa, A.A., Kumar, V., Joshi, R.R., Chakrabarti, P., Jasinski, M., Burgio, A., Leonowicz, Z., Jasinska, E., Soni, R., Chakrabarti, T., 2021. Adaptive Neuro-Fuzzy Inference System-Based Maximum Power Tracking Controller for Variable Speed WECS. *Energies* 14(19), 6275. DOI: 10.3390/en14196275
- Chojaa, H., Derouich, A., Chehaidia, S.E., Zamzoum, O., Taoussi, M., Elouatouat, H., 2021. Integral sliding mode control for DFIG based WECS with MPPT based on artificial neural network under a real wind profile. *Energy Reports* 7, 4809–4824. DOI: 10.1016/j.egyr.2021.07.066
- Dida, A., Benattous, D., 2015. Fuzzy logic based sensorless MPPT algorithm for wind turbine system driven DFIG. In: 2015 3rd International Conference on Control, Engineering & Information Technology (CEIT), IEEE, Tlemcen, Algeria, pp. 1–6. DOI: 10.1109/CEIT.2015.7233139
- Elaiassaoui, H., Zerouali, M., Ougli, A.E., Tidhaf, B., 2020. MPPT Algorithm Based on Fuzzy Logic and Artificial Neural Network (ANN) for a Hybrid Solar/Wind Power Generation System. In: 2020 Fourth International Conference On Intelligent Computing in Data Sciences (ICDS), IEEE, Fez, Morocco, pp. 1–6. DOI: 10.1109/ICDS50568.2020.9268747
- George, T., P, J., Francis, T., Sreedharan, C.E.S., 2022. Wind Energy Conversion System Based PMSG for Maximum Power Tracking and Grid Synchronization Using Adaptive Fuzzy Logic Control. *Journal of Applied Research and Technology* 20(6), 703–717. DOI: 10.22201/icat.24486736e.2022.20.6.1256
- Kermany, S.D., Joorabian, M., Deilami, S., Masoum, M.A.S., 2017. Hybrid Islanding Detection in Microgrid With Multiple Connection Points to Smart Grids Using Fuzzy-Neural Network. *IEEE Transactions on Power Systems* 32(4), 2640–2651. DOI: 10.1109/TPWRS.2016.2617344
- Korlepara, N.S.D., Elanchezian, E.B., Pragaspathy S., 2022. Analysis of Dual Stator Winding Induction Generator-Based Wind Energy Conversion System Using Artificial Neural Network Maximum Power Point Tracking. *International Journal of Renewable Energy Research* 12, 372–382. DOI: 10.20508/ijrer.v12i1.12759.g8411
- Kumar, K., Ramesh Babu, N., Prabhu, K.R., 2017. Design and Analysis of RBFN-Based Single MPPT Controller for Hybrid Solar and Wind Energy System. *IEEE Access* 5, 15308–15317. DOI: 10.1109/ACCESS.2017.2733555
- Kumar, R., Agrawal, H.P., Shah, A., Bansal, H.O., 2019. Maximum power point tracking in wind energy conversion system using radial basis function based neural network control strategy. *Sustainable Energy Technologies and Assessments* 36, 100533. DOI: 10.1016/j.seta.2019.100533
- Lee, C.-Y., Chen, P.-H., Shen, Y.-X., 2011. Maximum power point tracking (MPPT) system of small wind power generator using RBFNN approach. *Expert Systems with Applications* 38(10), 12058–12065. DOI: 10.1016/j.eswa.2011.02.054
- Manasa, M., Jayaprakash, P., & Kumar, N. B. (2022, July). A comparative study of maximum power tracking of turbines of wind energy conversion systems. In 2022 International Conference on Futuristic Technologies in Control Systems & Renewable Energy (ICFCR) (pp. 1-6). IEEE. DOI: 10.1109/ICFCR54831.2022.9893580
- Mahmoud, H.Y., Hasanien, H.M., Besheer, A.H., Abdelaziz, A.Y., 2020. Hybrid cuckoo search algorithm and grey wolf optimiser-based optimal control strategy for performance enhancement of HVDC-based offshore wind farms. *IET Generation, Transmission & Distribution* 14(10), 1902–1911. DOI: 10.1049/iet-gtd.2019.0801
- Mansouri, Adil, Abdelmounime El Magri, Rachid Lajouad, Ilyass El Myasse, El Khelifi Younes, and Fouad Giri. 2023. “Wind Energy Based Conversion Topologies and Maximum Power Point Tracking: A Comprehensive Review and Analysis.” *E-Prime - Advances in Electrical Engineering, Electronics and Energy* 6 (December): 100351. DOI: 10.1016/j.prime.2023.100351.
- Mariprasath, T., Shilaja, C., Hussaian Basha, CH., Murali, M., Fathima, F., Aisha, S., 2023. Design and Analysis of an Improved Artificial Neural Network Controller for the Energy Efficiency Enhancement of Wind Power Plant. In: Asari, V.K., Singh, V., Rajasekaran, R., Patel, R.B. (Eds.), *Computational Methods and Data Engineering, Lecture Notes on Data Engineering and Communications Technologies*. Springer Nature, Singapore, pp. 67–77. DOI: 10.1007/978-981-19-3015-7_6
- Mousa, H.H.H., Youssef, A.-R., Mohamed, E.E.M., 2021. State of the art perturb and observe MPPT algorithms based wind energy conversion systems: A technology review. *International Journal of Electrical Power & Energy Systems* 126, 106598. DOI: 10.1016/j.ijepes.2020.106598
- Muñoz, E., Ayala, E., Pozo, N., Simani, S., 2021. Fuzzy PID Control System Analysis for a Wind Turbine Maximum Power Point Tracking Using FAST and Matlab Simulink. In: Iano, Y., Saotome, O., Kemper, G., Mendes de Seixas, A.C., Gomes de Oliveira, G. (Eds.), *Proceedings of the 6th Brazilian Technology Symposium (BTSym'20)*, Smart Innovation, Systems and Technologies. Springer International Publishing, Cham, pp. 905–917. DOI: 10.1007/978-3-030-75680-2_100
- Muñoz-Palomeque, E., Sierra-García, J.E., Santos, M., 2023a. Hybrid Intelligent Control for Maximum Power Point Tracking of a Floating Wind Turbine. In: García Bringas, P., Pérez García, H., Martínez de Pisón, F.J., Martínez Álvarez, F., Troncoso Lora, A., Herrero, Á., Calvo Rolle, J.L., Quintián, H., Corchado, E. (Eds.), *Hybrid Artificial Intelligent Systems, Lecture Notes in Computer Science*. Springer Nature Switzerland, Cham, pp. 495–506. DOI: 10.1007/978-3-031-40725-3_42

- Muñoz-Palomeque, E., Sierra-García, J.E., Santos, M., 2023b. MPPT Control in an Offshore Wind Turbine Optimized with Genetic Algorithms and Unsupervised Neural Networks. In: Maglogiannis, I., Iliadis, L., MacIntyre, J., Dominguez, M. (Eds.), *Artificial Intelligence Applications and Innovations, IFIP Advances in Information and Communication Technology*. Springer Nature Switzerland, Cham, pp. 465–477. DOI: 10.1007/978-3-031-34107-6_37
- Ngo, Q.-V., Yi, C., Nguyen, T.-T., 2020. The maximum power point tracking based-control system for small-scale wind turbine using fuzzy logic. *International Journal of Electrical and Computer Engineering (IJECE)* 10(4), 3927. DOI: 10.11591/ijece.v10i4.pp3927-3935
- NREL 2023. OpenFAST. <https://openfast.readthedocs.io/en/main/>
- Pande, J., Nasikkar, P., Kotecha, K., Varadarajan, V., 2021. A Review of Maximum Power Point Tracking Algorithms for Wind Energy Conversion Systems. *Journal of Marine Science and Engineering* 9(11), 1187. DOI: 10.3390/jmse9111187
- Phan, N.M.-L., Tung, D.-N., Thanh, T.-N., Vu, N.T.-T., 2023. ANFIS Wind Speed Estimator-Based Output Feedback Near-Optimal MPPT Control for PMSG Wind Turbine. *Journal of Control, Automation, and Electrical Systems* 34(3), 588–598. DOI: 10.1007/s40313-022-00980-5
- Qais, M.H., Hasanien, H.M., Alghuwainem, S., 2019. Enhanced salp swarm algorithm: Application to variable speed wind generators. *Engineering Applications of Artificial Intelligence* 80, 82–96. DOI: 10.1016/j.engappai.2019.01.011
- Ramadan, H., Youssef, A.-R., Mousa, H.H.H., Mohamed, E.E.M., 2019. An efficient variable-step P&O maximum power point tracking technique for grid-connected wind energy conversion system. *SN Applied Sciences* 1(12), 1658. DOI: 10.1007/s42452-019-1716-5
- Ramos-Teodoro, J. and Rodríguez, F., 2022. Distributed energy production, control and management: a review of terminology and common approaches. *Revista Iberoamericana de Automática e Informática industrial* 19(3), pp. 233–253. DOI: 10.4995/riai.2022.16497.
- Rhaili, S.E., Abbou, A., Hichami, N.E., Marhraoui, S., 2018. A New Strategy Based Neural Networks MPPT Controller for Five-phase PMSG Based Variable-Speed Wind Turbine. In: 2018 7th International Conference on Renewable Energy Research and Applications (ICRERA). IEEE, Paris, pp. 1038–1043. DOI: 10.1109/ICRERA.2018.8566822
- Sachan, Ayushi, Motilal Nehru National Institute of Technology Allahabad, India, Akhilesh Kumar Gupta, Motilal Nehru National Institute of Technology Allahabad, India, Paulson Samuel, and Motilal Nehru National Institute of Technology Allahabad, India. 2017. “A Review of MPPT Algorithms Employed in Wind Energy Conversion Systems.” *Journal of Green Engineering* 6 (4): 385–402. DOI: 10.13052/jge1904-4720.643
- Salem, A.A., 2019. A Fuzzy Logic-based MPPT Technique for PMSG Wind Generation System. *International Journal of Renewable Energy Research (IJRER)* 9(4), pp. 1751-1760. DOI: 10.20508/ijrer.v9i4.10138.g7778
- Santos, M., López, R., De la Cruz, J. M., 2005. Fuzzy control of the vertical acceleration of fast ferries. *Control Engineering Practice*, 13(3), 305-313.
- Sierra-García, J.E., Santos, M., 2021. Redes neuronales y aprendizaje por refuerzo en el control de turbinas eólicas. *Revista Iberoamericana de Automática e Informática industrial* 18(4), pp. 327-335. DOI: 10.4995/riai.2021.16111
- Sierra-García, J. E., Santos, M., Pandit, R., 2022. Wind turbine pitch reinforcement learning control improved by PID regulator and learning observer. *Engineering Applications of Artificial Intelligence*, 111, 104769.
- Sitharthan, R., Karthikeyan, M., Sundar, D.S., Rajasekaran, S., 2020. Adaptive hybrid intelligent MPPT controller to approximate effectual wind speed and optimal rotor speed of variable speed wind turbine. *ISA Transactions* 96, 479–489. DOI: 10.1016/j.isatra.2019.05.029
- Sitharthan, R., Parthasarathy, T., Sheeba Rani, S., Ramya, K., 2019. An improved radial basis function neural network control strategy-based maximum power point tracking controller for wind power generation system. *Transactions of the Institute of Measurement and Control* 41(11), 3158–3170. DOI: 10.1177/0142331218823858
- Soliman, M.A., Hasanien, H.M., Azazi, H.Z., El-kholy, E.E., Mahmoud, S.A., 2018. Hybrid ANFIS-GA-based control scheme for performance enhancement of a grid-connected wind generator. *IET Renewable Power Generation* 12(7), 832–843. DOI: 10.1049/iet-rpg.2017.0576
- Thanh, S.N., Xuan, H.H., The, C.N., Hung, P.P., Van, T.P., Kennel, R., 2016. Fuzzy logic based maximum power point tracking technique for a stand-alone wind energy system. In: 2016 IEEE International Conference on Sustainable Energy Technologies (ICSET), IEEE, Hanoi, Vietnam, pp. 320–325. DOI: 10.1109/ICSET.2016.7811803
- Tiwari, R., Krishnamurthy, K., Neelakandan, R.B., Padmanaban, S., Wheeler, P.W., 2018. Neural Network Based Maximum Power Point Tracking Control with Quadratic Boost Converter for PMSG—Wind Energy Conversion System. *Electronics* 7(2), 20. DOI: 10.3390/electronics7020020
- Tiwari, R., Kumar, K., Devi, V.L., V, S.S., Atyam, N.R., 2022. Evaluation of the MPPT for the Wind Energy Conversion System's Performance using ANN and ANFIS. In: 2022 3rd International Conference on Communication, Computing and Industry 4.0 (C2I4), pp. 1–6. DOI: 10.1109/C2I456876.2022.10051429
- Vamvakas, D., Michailidis, P., Korkas, C., Kosmatopoulos, E., 2023. Review and Evaluation of Reinforcement Learning Frameworks on Smart Grid Applications. *Energies* 16(14), 5326. DOI: 10.3390/en16145326
- Vu, N.T.-T., Nguyen, H.D., Nguyen, A.T., 2022. Reinforcement Learning-Based Adaptive Optimal Fuzzy MPPT Control for Variable Speed Wind Turbine. *IEEE Access* 10, 95771–95780. DOI: 10.1109/ACCESS.2022.3205124
- Wei, C., Zhang, Z., Qiao, W., Qu, L., 2015. Reinforcement-Learning-Based Intelligent Maximum Power Point Tracking Control for Wind Energy Conversion Systems. *IEEE Transactions on Industrial Electronics* 62(10), 6360–6370. DOI: 10.1109/TIE.2015.2420792
- Wei, C., Zhang, Z., Qiao, W., Qu, L., 2016. An Adaptive Network-Based Reinforcement Learning Method for MPPT Control of PMSG Wind Energy Conversion Systems. *IEEE Transactions on Power Electronics* 31(11), 7837–7848. DOI: 10.1109/TPEL.2016.2514370
- Zerouali, M., Boutouba, M., Ougli, A.E., Tidhaf, B., 2019. Control of variable speed wind energy conversion systems by fuzzy logic and conventional P&O. In: 2019 International Conference on Intelligent Systems and Advanced Computing Sciences (ISACS), IEEE, Taza, Morocco, pp. 1–5. DOI: 10.1109/ISACS48493.2019.9068866
- Zhou, B., Zhang, Z., Li, G., Yang, D. and Santos, M., 2023. Review of Key Technologies for Offshore Floating Wind Power Generation. *Energies*, 16(2), p.710.
- Zouheyr, D., Lotfi, B., Abdelmadjid, B., 2021. Improved hardware implementation of a TSR based MPPT algorithm for a low cost connected wind turbine emulator under unbalanced wind speeds. *Energy* 232, 121039. DOI: 10.1016/j.energy.2021.121039