

Redes neuronales y aprendizaje por refuerzo en el control de turbinas eólicas

Sierra-García, J. E.^{a*}, Santos, M.^b

^a Departamento de Ingeniería Electromecánica, Universidad de Burgos, Av. Cantabria, s/n, 09006 Burgos, España.

^b Instituto de Tecnología del Conocimiento, Universidad Complutense de Madrid, Profesor G^a Santemas 9, 28040-Madrid, España.

To cite this article: Sierra-García, J.E., Santos, M. 2021. Neural networks and reinforcement learning in wind turbine control. Revista Iberoamericana de Automática e Informática Industrial 18, 327-335. <https://doi.org/10.4995/riai.2021.16111>

Resumen

El control del ángulo de las palas de las turbinas eólicas es complejo debido al comportamiento no lineal de los aerogeneradores, y a las perturbaciones externas a las que están sometidas debido a las condiciones cambiantes del viento y otros fenómenos meteorológicos. Esta dificultad se agrava en el caso de las turbinas flotantes marinas, donde también les afectan las corrientes marinas y las olas. Las redes neuronales, y otras técnicas del control inteligente, han demostrado ser muy útiles para el modelado y control de estos sistemas. En este trabajo se presentan diferentes configuraciones de control inteligente, basadas principalmente en redes neuronales y aprendizaje por refuerzo, aplicadas al control de las turbinas eólicas. Se describe el control directo del ángulo de las palas del aerogenerador y algunas configuraciones híbridas de control. Se expone la utilidad de los neuro-estimadores para la mejora de los controladores. Finalmente, se muestra un ejemplo de aplicación de algunas de estas técnicas en un modelo de turbina terrestre.

Palabras clave: Turbinas eólicas, aerogeneradores, control del ángulo de las palas, control inteligente, redes neuronales aprendizaje por refuerzo.

Neural networks and reinforcement learning in wind turbine control

Abstract

Pitch control of wind turbines is complex due to the intrinsic non-linear behavior of these devices, and the external disturbances they are subjected to related to changing wind conditions and other meteorological phenomena. This difficulty is even higher in the case of floating offshore turbines, due to ocean currents and waves. Neural networks and other intelligent control techniques have been proven very useful for the modeling and control of these complex systems. Thus, this paper presents different intelligent control configurations applied to wind turbine pitch control. Direct pitch control based on neural networks and reinforcement learning, and some hybrid control configurations are described. The usefulness of neuro-estimators for the improvement of controllers is also presented. Finally, some of these techniques are used in an application example with a land wind turbine model.

Keywords: Wind turbines, pitch control, intelligent control, neural networks reinforcement learning.

1. Introducción

Dentro de los objetivos de desarrollo sostenible (ODS) de Naciones Unidas establecidos en la Agenda 2030 se establece la necesidad de asegurar el acceso a una energía asequible, fiable, sostenible y moderna para todos (Naciones Unidas, 2021). La energía eólica tiene un papel fundamental para hacer

que este objetivo se haga realidad. De hecho, su uso crece año tras año y actualmente es la segunda energía renovable más utilizada después de la hidráulica (Our World in Data, 2021). Se prevé que esta tendencia creciente se mantenga, hasta convertirse en la principal fuente de generación de energía en el 2050 (IRENA, 2019). Aunque la energía eólica puede considerarse una tecnología madura, el control de los

*Autor para correspondencia: jesierra@ubu.es

Attribution-NonCommercial-NoDerivatives 4,0 International (CC BY-NC-ND 4,0)

aerogeneradores para maximizar su eficiencia sigue siendo aún un reto por las características de los rotores de las turbinas y sobre todo por la aleatoriedad del recurso eólico.

El control de aerogeneradores persigue varios objetivos: estabilización de la potencia de salida en torno a su valor nominal, maximización de la energía generada, minimización de las pérdidas de energía, reducción de las vibraciones y de la fatiga en la estructura, etc. Todo ello a la vez que se garantiza la seguridad en todas las condiciones de operación. Esto es especialmente complejo en las turbinas flotantes marinas (FOWT), del inglés “floating offshore wind turbines”, ya que se ha observado que el control del sistema puede además afectar a la estabilidad de la estructura flotante (Tomás-Rodríguez y Santos, 2019).

Una turbina eólica es un sistema formado por una torre, la góndola (en cuyo interior se encuentra el generador), y el rotor, con las palas que el viento hace girar. Dependiendo del tipo de turbina se pueden aplicar diferentes acciones de control, de las cuales las más relevantes son: el control del ángulo de las palas (*pitch*), el control de la velocidad del generador, y el control del ángulo de guiñada (*yaw*). El control de las palas o control de *pitch* se emplea para frenar la turbina y mantener la potencia a su valor nominal cuando el viento supera un cierto umbral. El control del generador persigue alcanzar la velocidad del rotor óptima cuando la velocidad del viento es inferior a la nominal. Por último, el control de ángulo de guiñada modifica la orientación de la góndola de la turbina para alinearla con la dirección del viento y así maximizar la captación del recurso eólico.

El control de *pitch* de las turbinas eólicas es complejo debido a que el aerogenerador es un sistema altamente no lineal y, además, está sometido a fuertes perturbaciones externas como el viento, y en el caso de las turbinas marinas, hielo, las corrientes y sobre todo las olas. Las técnicas inteligentes han demostrado ser muy útiles en el modelado y el control de sistemas de ingeniería complejos (Sierra-García y Santos, 2018; Phan y Lai, 2019; Guo y Wang, 2019). En la literatura se encuentran algunos trabajos que abordan este problema usando control inteligente. En (Tomás-Rodríguez y Santos, 2019) se muestran diferentes tipos de control para turbinas eólicas flotantes. La lógica borrosa ha sido frecuentemente utilizada en este campo. Por ejemplo, en (Rubio et al., 2019) se plantea el uso de un sistema basado en lógica borrosa para el control de un aerogenerador instalado en una plataforma semisumergible. En (Jeon y Paek, 2021) se diseña un regulador cuadrático lineal basado en lógica difusa para una turbina eólica de velocidad y paso variable. En el trabajo de (Chavero-Navarrete et al, 2020) se propone un controlador borroso jerárquico para resolver los efectos no lineales producidos por vientos atípicos. El algoritmo se implementó en una turbina pequeña de eje horizontal y se realizó una comparación con un controlador PID convencional. Y en (Ngo et al, 2020) se aplica un PID que es sintonizado por lógica difusa para el control del ángulo de las palas de turbinas eólicas de pequeña escala, y también se compara con un controlador PID convencional, por mencionar algunos trabajos recientes.

Sin embargo, no es fácil encontrar en la literatura trabajos que utilicen redes neuronales en este campo para el control, salvo contadas excepciones. En la mayoría de los casos las redes neuronales en el ámbito de la energía eólica se utilizan

para predicción o detección de fallos en turbinas (Jove et al, 2019; Jove et al, 2020; El Maati y Bahir, 2020; Li y Wang, 2019; Vives et al, 2020).

En este trabajo se exponen diferentes configuraciones de control basadas en redes neuronales y aprendizaje por refuerzo, en ocasiones combinadas con otras técnicas, aplicadas al control de los aerogeneradores y, particularmente, al control del ángulo de las palas. También se muestra un ejemplo de aplicación de algunas de estas técnicas en un modelo de turbina terrestre.

La estructura del artículo es la siguiente. En la sección 2 se expone el control directo de *pitch* mediante redes neuronales. En la sección 3 se presenta el control directo de *pitch* mediante aprendizaje por refuerzo. En la sección 4 se expone la mejora de los controladores mediante estimadores neuronales. En la sección 5 se recogen algunas técnicas híbridas. La sección 6 presenta un ejemplo de aplicación. El trabajo termina con las conclusiones y líneas futuras.

2. Regulación directa de *pitch* con redes neuronales

Las redes neuronales artificiales han sido ampliamente utilizadas en el modelado y control de sistemas complejos debido a su capacidad para aproximar funciones $f: \mathbb{R}^N \rightarrow \mathbb{R}^M$. De forma general están formadas por una capa de entrada, un conjunto de capas intermedias ocultas, y una capa de salida. En cada una de las capas hay un conjunto de neuronas. Las salidas de las neuronas de cada capa se encuentran conectadas a las entradas de la capa siguiente. El enlace entre cada dos neuronas tiene asociado un coeficiente denominado peso.

Cada neurona implementa una función matemática $f: \mathbb{R}^N \rightarrow \mathbb{R}$, donde N es el número de neuronas de la capa anterior. Además, cada neurona puede tener coeficientes que modifica el algoritmo de aprendizaje, como por ejemplo, el umbral de activación en un perceptrón, o los centros de la red en una función de base radial. Cada capa puede tener un número de neuronas diferente. Habitualmente todas las neuronas de la misma capa son del mismo tipo. El algoritmo de aprendizaje ajusta los pesos de la red y los coeficientes de las neuronas para que la red implemente la función esperada.

Dependiendo de la función matemática ejecutada por las neuronas y la estructura de la red, las redes neuronales se clasifican en: redes de base radial, perceptrón multicapa, etc.

La arquitectura de la estrategia de regulación directa de *pitch* mediante redes neuronales propuesta se muestra en la Figura 1 (Sierra-García y Santos, 2020a). Como puede apreciarse, la variable controlada es la potencia de salida de la turbina, P_{out} , para mantenerla a su valor nominal, y para conseguirlo la variable manipulada es la referencia del ángulo de *pitch*, θ_{ref} . Esta referencia del *pitch* se lleva al actuador, normalmente implementado mediante un variador y un motor. Un esquema similar podría plantearse para estabilizar la velocidad del rotor.

El error de potencia, P_{err} , se obtiene como la diferencia entre la referencia de potencia, P_{ref} (normalmente la potencia nominal) y la potencia de salida. La señal de error y su derivada se llevan a un saturador para ajustarlas al rango de entrada de la red neuronal. La red neuronal recibe estas señales y genera la señal de control. La salida de la red NN_o se multiplica por -

1 para invertir su signo y se le suma un offset de $\pi/4$. De esta forma se ajusta el rango de salida de la red al rango de entrada del pitch $[0, \pi/2]$ (rad). Esta señal se lleva a un saturador para limitarla a los valores adecuados. El resultado de este proceso es la obtención de la señal de referencia del ángulo de las palas, θ_{ref} .




Figura 1: Regulación directa de pitch mediante redes neuronales

El rango de entrada de la red, y por ende los centros de las neuronas, deben configurarse en base a la potencia de la turbina. En (Sierra-García y Santos, 2020a) el rango de entrada se dimensiona para una turbina de 7kW. Además, se analiza la influencia de los límites de saturación del error de potencia y su derivada, P_{err_s} y \dot{P}_{err_s} . Si el límite es demasiado bajo muchos valores se saturan y la red no discrimina bien los valores de entrada, lo que hace que el error cuadrático medio aumente; en cambio, si es demasiado elevado la varianza de la potencia de salida aumenta. Por tanto, es conveniente llegar a un compromiso y fijar un valor intermedio.

La red neuronal debe aprender la ley de control, $f: \mathbb{R}^2 \rightarrow \mathbb{R}$, para que sea capaz de estabilizar la potencia de salida en torno a su valor nominal. Esta función no se conoce previamente. En otros esquemas de control los pesos de la red se actualizan usando aprendizaje supervisado. Esto requiere disponer de un conjunto de datos de entrada y salida para poder entrenar la red. De esta forma, la red genera la salida esperada cuando recibe una entrada similar a la empleada durante el entrenamiento. Sin embargo, estos datos no están siempre disponibles por lo que se propone emplear aprendizaje no supervisado.

En (Sierra-García y Santos, 2020a), siguiendo esta estrategia, se emplea una red neuronal de funciones de base radial (RBF) con la siguiente ley para el ajuste de los pesos de la red.

$$PID_L = K_{pL} \cdot P_{err_s}(t_i) + K_{dL} \cdot \dot{P}_{err_s}(t_i) + K_{iL} \cdot \int P_{err}(t_i) \quad (1)$$

$$W_j(t_i) = W_j(t_{i-1}) + \frac{\mu \cdot PID_L \cdot e^{-\frac{dist(P_{err_s}(t_i), \dot{P}_{err_s}(t_i), c_{j1}, c_{j2})}{\sigma_j}}}{\forall j \in \mathcal{N} \cup 0 | j < M} \quad (2)$$

Donde M es el número de neuronas en la capa oculta, $dist$ representa la función de distancia euclídea, μ es la tasa de aprendizaje, y $[K_{pL}, K_{dL}, K_{iL}]$ es un conjunto de constantes positivas.

Los resultados obtenidos para una turbina pequeña prueban que la red es capaz de aprender a controlar el ángulo de las palas de forma eficiente, manteniendo la potencia de salida en su valor nominal.

Hay otros trabajos en los que se emplean redes neuronales para el control y optimización de aerogeneradores. Por ejemplo, Asghar y Liu en (Asghar y Liu, 2018a) diseñan un algoritmo neuro-difuso para obtener la velocidad óptima del rotor. En (Ren et al, 2020) se aplica una red neuronal combinada con un PID para el control de turbinas. La red neuronal se usa para ajustar los parámetros del PID mientras el sistema está en funcionamiento. De forma similar en (Du y Wang, 2020), se emplean redes neuronales combinadas con un PI para el control de pitch. La red neuronal optimiza los parámetros del PI. En (Jie et al, 2020) se usaron los datos de un parque eólico en una red neuronal profunda para obtener el modelo predictivo de algunas variables de la turbina eólica. Con esos valores se aplicó una red neuronal de base radial para el control de pitch, que además se muestra que puede mitigar las cargas de manera efectiva. En (Demirleden et al, 2019) se combinan redes neuronales artificiales y modelos de optimización para predecir parámetros de los aerogeneradores a partir de condiciones meteorológicas.

3. Control directo de pitch mediante aprendizaje por refuerzo

El aprendizaje por refuerzo (AR), en inglés “reinforcement learning” (RL), es una técnica del campo de la inteligencia artificial que imita la forma en la que los humanos aprendemos a realizar tareas mediante recompensas que refuerzan nuestra conducta (Sutton y Barto, 2015). Normalmente se identifican tres elementos: un entorno, un agente y un intérprete. El agente, teniendo en consideración el estado del entorno y las recompensas obtenidas previamente, selecciona la acción con la cual estima que va a obtener una mayor recompensa. Esta acción produce un cambio en el entorno. El intérprete observa el efecto de la acción en el entorno y proporciona información al agente sobre el nuevo estado y la recompensa a la última acción ejecutada, cerrando así el lazo de control. Pueden observarse ciertas semejanzas con un lazo de control tradicional: el entorno sería equivalente a la planta, el agente podría ser el controlador y actuador, y la función del intérprete es similar a la de un sensor o un observador. Algunos autores consideran que el intérprete está embebido en el agente o en el entorno, pero en cualquier caso la función del intérprete está siempre presente.

La relación entre el estado actual y la acción a ejecutar se suele denominar política. Esta relación puede ser discreta, y entonces tanto el conjunto de estados como el conjunto de acciones son discretos, o continua, si los estados y el conjunto de acciones son continuas. Si la política es discreta se suele implementar mediante una tabla, y si es continua es habitual usar una red neuronal.

A partir del esquema de la Figura 1 y considerando la estrategia de aprendizaje por refuerzo descrita en (Sierra-García y Santos, 2020b), se propone el esquema de control de pitch basado en aprendizaje por refuerzo de la Figura 2.

El esquema está compuesto por un estimador de estado, un mecanismo de cálculo de recompensas, una política, un actuador, y un método para actualizar la política. El estimador de estado recibe el error de potencia, P_{err} y su derivada, \dot{P}_{err} . Estas señales son discretizadas y se obtiene el estado actual, $s_t \in S$, donde t es el instante actual.

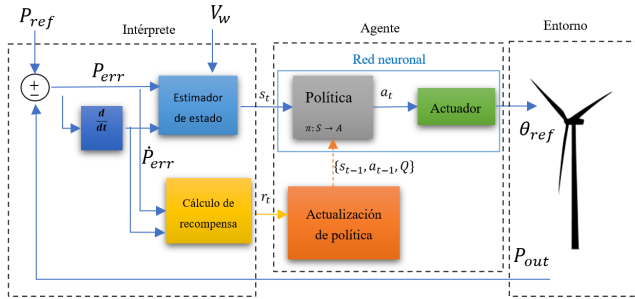


Figura 2: Control directo de pitch mediante aprendizaje por refuerzo

La política se define como una función $\pi: S \rightarrow A$ que asigna una acción $a_t \in A$ a cada estado en S . La acción a_t se selecciona para maximizar la recompensa esperada a largo plazo.

En su aplicación al control del ángulo de las palas, el actuador transforma la acción discreta a_t en una señal de control de pitch en el rango $[0, \pi/2]$. Si la política se implementa mediante una red neuronal, la salida de la red puede ser directamente la señal θ_{ref} . Cada vez que una acción se ejecuta, en la siguiente iteración el mecanismo de cálculo de recompensa, en función del nuevo estado, calcula una recompensa o penalización r_t para la acción a_{t-1} . El algoritmo de actualización de política emplea esta recompensa para modificar la política asociada al estado s_{t-1} .

En el caso discreto (estados discretos y acciones discretas) la política puede implementarse como una tabla, $T_{(s,a)}: S \times A \rightarrow \mathbb{R}$, junto con una función $f_a: S \rightarrow A$. La tabla relaciona cada par $(s, a) \in S \times A$ con un número real que representa la estimación de la recompensa a largo plazo. Normalmente en la nomenclatura de aprendizaje por refuerzo a esta recompensa se la denota mediante la variable Q . Esta estimación Q almacenada en la tabla se actualiza mediante el algoritmo de actualización de política. Por tanto, la tabla tiene tantas filas como estados y tantas columnas como acciones. Por otro lado, dado un estado s , es decir, una fila en la tabla, la función f_a devuelve la acción, es decir, la columna con el máximo valor de Q .

En el caso continuo (estados discretos y acciones continuas), la política y el actuador se podrían implementar mediante una red neuronal. En la Figura 2 se muestran los bloques cuya función sería asumida por la red neuronal. La red tendría tantas entradas como variables conforman el estado, en este caso: P_{err} , \dot{P}_{err} y V_w , y una salida, θ_{ref} . La actualización de política se encargaría de modificar los pesos de la red.

Existe además una opción intermedia, estados continuos y acciones discretas. En este caso la política se implementaría mediante una red neuronal junto con la función $f_a: S \rightarrow A$. Las entradas de la red serían las mismas que en el caso continuo, pero tendría tantas salidas como acciones discretas existen en el conjunto A . La salida de cada neurona de la capa de salida representa la variable Q , es decir, la recompensa a largo plazo, que se obtiene al ejecutar la acción relacionada con esa salida de la red. Al igual que en el caso discreto, la función f_a devuelve la acción, pero en este caso es la neurona de la capa de salida con el máximo valor de Q .

Existen varios mecanismos para actualizar la política. El más sencillo es sumar todas las recompensas previas (3), aunque tiene el inconveniente de tender a elegir las acciones ya seleccionadas previamente.

$$T_{(s_{t-1}, a_{t-1})}^{\pi}(t_i) = T_{(s_{t-1}, a_{t-1})}^{\pi}(t_{i-1}) + r_t \quad (3)$$

El mecanismo de actualización que más se suele emplear es el que se conoce comúnmente como Q-Learning (Alvarez-Ramos et al, 2010) (4-5), que utiliza una tasa de aprendizaje α , y un factor de descuento γ , ambos pertenecientes al rango $[0,1]$.

$$a_{max} = \arg \text{MAX}_a (T_{(s_t, a)}^{\pi}(t_{i-1})), \quad (4)$$

$$T_{(s_{t-1}, a_{t-1})}^{\pi}(t_i) = (1 - \alpha) \cdot T_{(s_{t-1}, a_{t-1})}^{\pi}(t_{i-1}) + \alpha [r_t - \gamma \cdot T_{(s_{t-1}, a_{max})}^{\pi}(t_{i-1})] \quad (5)$$

Por otro lado, existen diferentes estrategias para calcular la recompensa r_t . Por ejemplo, se puede emplear el error de potencia P_{err} (6), o su derivada \dot{P}_{err} (7-8), o la combinación de ambas (9). Estas y otras estrategias se explican en detalle en (Sierra-García y Santos, 2020b).

$$\text{PRS: } r_{t_i} = P_{errMAX} - |P_{err}(t_i)| \quad (6)$$

$$r_v = \begin{cases} -\dot{P}_{err}(t_i) & P_{err}(t_i) > 0 \\ \dot{P}_{err}(t_i) & P_{err}(t_i) \leq 0 \end{cases} \quad (7)$$

$$\text{VRS: } r_{t_i} = \begin{cases} -r_v & \text{sgn}(\dot{P}_{err}(t_i)) \neq \text{sgn}(\dot{P}_{err}(t_{i-1})) \wedge \\ & |\dot{P}_{err}(t_i)| < |\dot{P}_{err}(t_{i-1})| \\ r_v & \text{otro caso} \end{cases} \quad (8)$$

$$r_{t_i} = \text{PRS} \cdot \text{VRS} \quad (9)$$

Los acrónimos PRS y VRS significan “Position Reward Strategy” y “Velocity Reward Strategy”, para indicar que la recompensa se calcula en base a la posición de la señal respecto de la referencia (PRS), o a la velocidad con la que se aleja o se acerca a la misma (VRS).

Algunos trabajos en los que se utiliza aprendizaje por refuerzo para el control de aerogeneradores son, por ejemplo, el de (Fernandez-Gauna et al, 2017), donde se emplea para facilitar la adaptación a condiciones de viento cambiantes. En otro trabajo posterior los mismos autores aplican AR condicionado (Fernandez-Gauna et al, 2018). En (Abouheaf, 2018) se usa aprendizaje por refuerzo iterativo de políticas con la técnica del actor-crítico adaptativo para el control de turbinas eólicas con generador de doble inducción.

Sedighzadeh ajusta un controlador PID adaptativo mediante AR y lo aplica para el control de turbinas eólicas (Sedighzadeh y Rezazadeh, 2008). En (Saénz-Aguirre et al, 2019) se aplica una red neuronal basada en AR para el control del ángulo de yaw . En un artículo más reciente los mismos autores mejoran el rendimiento de este neuro-controlador mediante optimización multi-objetivo (Saénz-Aguirre et al, 2020).

En (Tomin et al, 2019) se emplean técnicas de control adaptativo combinadas con aprendizaje por refuerzo. Primero, extraen las propiedades estocásticas de la velocidad del viento mediante un agente AR, y después utilizan la política óptima

obtenida en un controlador adaptativo. En (Hosseini et al, 2020) se emplea AR pasivo resuelto mediante optimización de enjambre de partículas en un sistema de inferencia neuro-difuso de tipo 2 con clustering no supervisado, para controlar el ángulo de pitch de una turbina eólica. Chen et al. desarrollan un controlador robusto que emplea programación dinámica adaptativa basada en AR y datos del estado del sistema (Chen et al, 2020). En (Zhao et al, 2020) se aplica aprendizaje por refuerzo profundo, asistido por conocimiento experto, para controlar granjas eólicas cooperativas.

4. Mejora del control mediante estimadores neuronales

Las redes neuronales, además de poder utilizarse para obtener modelos computacionales de los aerogeneradores, también pueden ayudar a estimar señales que pueden ser difíciles de medir, como es el caso del viento efectivo en una turbina. Las turbinas eólicas, especialmente las marinas, están sometidas a fuertes perturbaciones externas, entre otras las olas, que provocan oscilaciones y hacen que el viento efectivo, es decir, el que realmente se transforma en energía mecánica, sea diferente del medido por el anemómetro de la góndola. La estimación de este viento efectivo y su consideración en la estrategia de control puede mejorar el funcionamiento de los controladores de pitch.

En la Figura 3 se muestra un esquema en el que este concepto se emplea para mejorar un controlador compuesto por una tabla de búsqueda y un PID (Sierra-García y Santos, 2021a). En general puede emplearse para mejorar cualquier controlador que considere el viento en la estrategia de control.

En la Figura 3 el viento efectivo se representa mediante la señal V_{wd} . Como puede apreciarse, este viento es la combinación del viento medido por el sensor V_w y la perturbación $dist$. El neuroestimador obtiene una estimación de este viento efectivo, \tilde{V}_{wd} , que se tiene en cuenta como entrada en la tabla de búsqueda. Esta tabla de búsqueda asigna una señal de pitch, θ_{TAB} , en función del viento estimado por el neuroestimador, \tilde{V}_{wd} . Como el mapeo entre el viento y el valor del pitch no es perfecto, se incluye en el esquema un regulador PID que permite reducir este error. La salida de la tabla, θ_{TAB} , y del PID, θ_{PID} se combinan para obtener la referencia del ángulo de pitch, θ_{ref} . Finalmente, el aerogenerador recibe como entradas la referencia de pitch y el viento incluyendo la perturbación externa, V_{wd} , es decir el viento efectivo.

El estimador neuronal recibe el viento medido por el sensor V_w , la velocidad angular del rotor w y su derivada \dot{w} , la corriente en el generador I_a , y el ángulo de pitch θ . A partir de estos valores el estimador neuronal o neuroestimador genera una estimación del viento efectivo, \tilde{V}_{wd} . Los detalles sobre el funcionamiento del neuroestimador pueden consultarse en (Sierra-García y Santos, 2021a).

La estimación de la velocidad del viento aplicada al control de las turbinas eólicas se ha estudiado en otros trabajos. En el ya mencionado artículo de Asghar y Liu (Asghar y Liu, 2018a), se propone el diseño de un estimador de viento usando un algoritmo difuso neuro-adaptativo (ANFIS). Los autores intentan obtener la relación entre la velocidad del viento, el tip speed ratio (TSR), la velocidad del rotor, y la potencia mecánica.

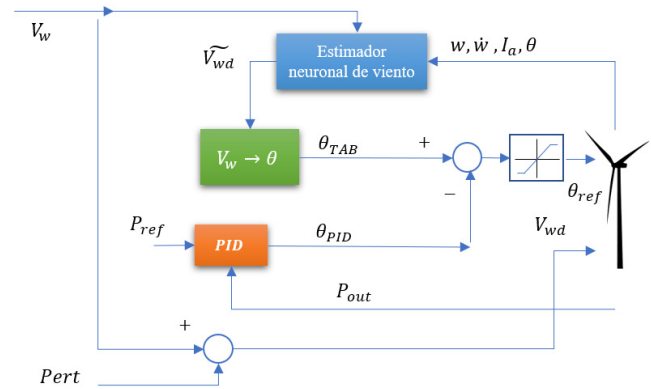


Figura 3: Controlador mejorado mediante estimadores neuronales

Se emplean mínimos cuadrados y el algoritmo de propagación de gradiente descendiente para entrenar las funciones de pertenencia difusas y estimar el viento efectivo sin usar ningún sensor. Después, el viento estimado y el TSR óptimo se emplean para calcular la velocidad del rotor óptima. En un artículo posterior (Asghar y Liu, 2018b), los mismos autores emplean un sistema neuro-difuso adaptativo híbrido para estimar la distribución de probabilidad de Weibull de la velocidad del viento.

Deng et al. presentan un controlador de velocidad de rotor que utiliza la velocidad del viento efectivo estimada por un observador. Este viento se obtiene a partir de la velocidad del rotor, el ángulo de pitch y el par aerodinámico (Deng et al, 2020). El algoritmo de estimación y el controlador se validan mediante resultados de simulación. En un trabajo anterior (Deng et al, 2019), los mismos autores proponen un algoritmo de estimación de viento efectivo basado en la observación de las perturbaciones de entrada y aprendizaje extremo. El algoritmo se valida mediante simulación y se compara con un filtro de Kalman obteniendo resultados positivos.

El viento estimado por un observador también se emplea para mejorar el rendimiento de un controlador en (Moodi y Bustan, 2019). En este caso tanto el observador como el controlador están basados en la lógica borrosa. En (Sierra-García y Santos, 2021c) se emplea aprendizaje profundo para estimar el viento efectivo y mejorar el comportamiento de un controlador borroso.

5. Estrategias de control híbridas

La hibridación de estrategias inteligentes y técnicas tradicionales se ha empleado satisfactoriamente en el modelado y el control de sistemas complejos (Santos, 2011; Casteleiro-Roca et al., 2020); por ello se presentan a continuación diferentes posibilidades para combinar las estrategias de control presentadas anteriormente que se han aplicado a las turbinas eólicas.

5.1. Controlador neural combinado con tabla de búsqueda

La Figura 4 muestra un esquema de control en el que se emplea una red neuronal y una tabla de búsqueda (Sierra-

García y Santos, 2021b). Al igual que en el esquema de la Figura 3, la tabla de búsqueda funciona en lazo abierto, generando una referencia de pitch tentativa θ_{TAB} que depende de la velocidad del viento, sin considerar la potencia actual; cuanto mayor es la velocidad del viento mayor es el ángulo de pitch para estabilizar la potencia alrededor de su valor nominal.

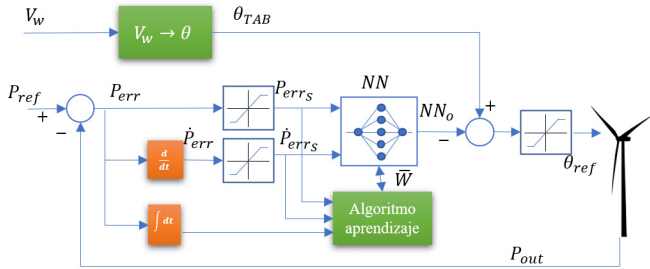


Figura 4: Controlador neuronal combinado con tabla de búsqueda

En este esquema se puede emplear el algoritmo de aprendizaje explicado anteriormente (1-2). El algoritmo recibe el error de potencia y actualiza los pesos de la red. Un aumento del error produce un incremento en los pesos de la red, y así se obtiene un menor ángulo de pitch, lo que conlleva a un aumento en la potencia y a una disminución del error.

La tabla de búsqueda y la red neuronal se complementan mutuamente. Por un lado, la red neuronal mejora los resultados producidos por la tabla; tiene un papel similar al PID mostrado en la Figura 3 cuando se combina con la tabla. Por otro lado, la tabla acelera el aprendizaje de la red neuronal. Por este motivo, no es necesario que la relación entre viento y ángulo de pitch se haga de forma muy precisa en la tabla, sino tan solo una relación creciente entre velocidad de viento y ángulo de las palas.

5.2. Aprendizaje con refuerzo combinado con tabla de búsqueda

La idea de combinar una tabla de búsqueda con un controlador que absorba los errores de mapeo de la tabla también puede aplicarse al controlador basado en aprendizaje por refuerzo de la Figura 2. En este caso a la salida de la tabla θ_{TAB} se resta a la salida del actuador del aprendizaje por refuerzo, θ_{TAB} (Figura 5).

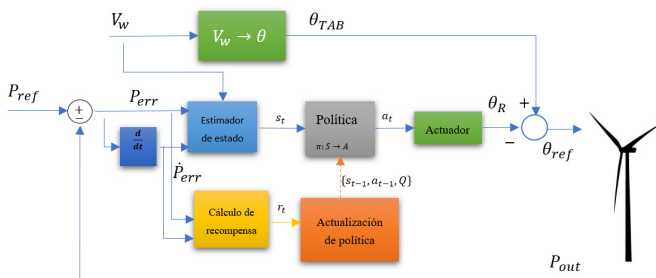


Figura 5: Controlador basado en aprendizaje por refuerzo combinado con tabla de búsqueda

Con respecto al controlador de la Figura 2, es necesario realizar un ligero cambio en el actuador para su

implementación. En el controlador de la Figura 2 el actuador ajusta el conjunto de acciones A al rango de entrada de la referencia de pitch $[0, \pi/2]$ (rad). En este caso la salida del actuador debe ajustarse al rango $[-\pi/4, \pi/4]$ (rad).

De nuevo la tabla de búsqueda puede ayudar a acelerar el aprendizaje del controlador inteligente al establecer una relación creciente entre viento y pitch. La idea es que el controlador no necesita aprender la tendencia de crecimiento general, sino que ya se encuentra predefinida en la tabla.

5.3. Aprendizaje con refuerzo combinado con un controlador PID

Existen diferentes formas en las que el aprendizaje por refuerzo puede combinarse con un controlador PID tradicional. A continuación, se explican algunos de los posibles esquemas de combinación.

La tabla de búsqueda de los esquemas anteriores puede implementarse mediante aprendizaje por refuerzo. El agente debe aprender a escoger un ángulo de las palas a partir de un viento de entrada. Este ángulo no es el que se lleva a la referencia de pitch, como en la Figura 2, sino que sirve de referencia de pitch tentativa sobre la cual el PID corrige (Figura 6).

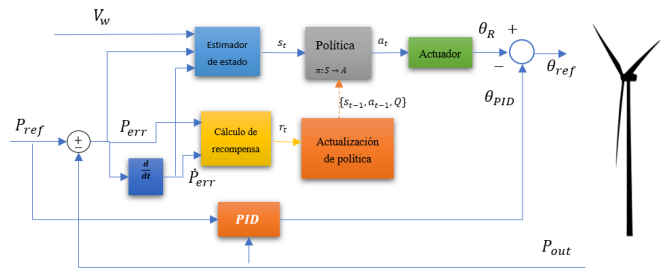


Figura 6: PID combinado con aprendizaje por refuerzo

La estimación del estado puede realizarse con el viento, el error y su derivada, o solamente con el viento. Si sólo se utiliza el viento para estimar el estado, el sistema aprende la mejor tabla de búsqueda $V_w \rightarrow \theta$. En este caso, conviene calcular la recompensa acumulada al final de cada episodio de aprendizaje en vez de en cada acción de control, ya que las reducciones del error conseguidas por el PID podrían asociarse a la acción llevada a cabo por el aprendizaje por refuerzo y asignar erróneamente una recompensa a una política.

Si el estimador de estado considera el viento, el error y su derivada, las recompensas pueden asociarse a cada acción de control, como se hace en los casos anteriores de aprendizaje por refuerzo. En cualquier caso, el cálculo de recompensas sí considera el error de potencia para aprender a hacer el ajuste. En este esquema las constantes del PID pueden ser fijas o ajustadas mediante ganancia programada en función del nivel de viento.

Otra forma de combinar el PID con las técnicas de aprendizaje con refuerzo es hacer que el agente genere las constantes del PID. De esta forma puede aprender qué constantes son más adecuadas para cada estado del sistema. La Figura 7 muestra este esquema de control.

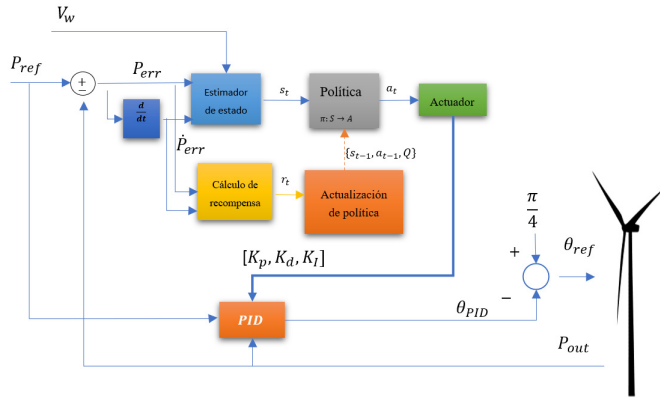


Figura 7: Controlador basado en aprendizaje por refuerzo que modifica las ganancias del PID

6. Ejemplo de aplicación

A continuación, se muestra un ejemplo de la aplicación de algunas de estas técnicas inteligentes sobre el modelo de una turbina de 7kW. Los resultados se han obtenido mediante simulación con Matlab/Simulink. Los parámetros de la turbina que se han empleado se recogen en la tabla I. Las ecuaciones del modelo de turbina se enumeran en (10-16), y se describen en detalle en (Sierra-García y Santos, 2020a; Mikati et al, 2013).

Tabla 1: Parámetros del modelo de turbina empleado (Mikati et al, 2013)

Símbolo	Descripción	Valor/Unidades
L_a	Inductancia de la armadura	13.5 mH
K_g	Constante del generador	23.31
K_ϕ	Constante de acoplamiento de flujo magnético	0.264 V/rad/s
R_a	Resistencia de la armadura	0.275 Ω
R_L	Resistencia de carga	8 Ω
J	Inercia	6.53 Kg m ²
R	Radio de la pala	3.2 m
ρ	Densidad del aire	1.223 Kg/m ³
K_f	Coefficiente de fricción	0.025 N m/rad/s
$[c_1, c_2, c_3]$	Constantes del C_p	[0.73, 151, 0.58]
$[c_4, c_5, c_6]$	Constantes del C_p	[0.002, 2.14, 13.2]
$[c_7, c_8, c_9]$	Constantes del C_p	[18.4, -0.02, -0.003]
$[K_\theta, T_\theta]$	Constantes del actuador de pitch	[0.15, 2]

$$\dot{I}_a = \frac{1}{L_a} (K_g \cdot K_\phi \cdot w - (R_a + R_L)I_a), \quad (10)$$

$$\lambda = (w \cdot R) / v_{ef}, \quad (11)$$

$$\lambda_i = \left[\left(\frac{1}{\lambda + c_8} \right) - \left(\frac{c_9}{\theta^{3+1}} \right) \right]^{-1}, \quad (12)$$

$$C_p(\lambda_i, \theta) = c_1 \left[\frac{c_2}{\lambda_i} - c_3 \theta - c_4 \theta^{c_5} - c_6 \right] e^{-\frac{c_7}{\lambda_i}}, \quad (13)$$

$$\dot{w} = \frac{1}{2 \cdot J \cdot w} (C_p(\lambda_i, \theta) \cdot \rho \pi R^2 \cdot v_{ef}^3) \quad (14)$$

$$-\frac{1}{J} (K_g \cdot K_\phi \cdot I_a + K_f w), \quad (15)$$

$$\ddot{\theta} = \frac{1}{T_\theta} [K_\theta (\theta_{ref} - \theta) - \dot{\theta}], \quad (15)$$

$$P_{out} = R_L \cdot I_a^2 \quad (16)$$

Las Figuras 8, 9 y 10 muestran la potencia, el par y el ángulo de pitch, respectivamente, cuando se aplican diferentes estrategias de control para esta turbina. Las líneas azules representan la señal cuando el ángulo de las palas se fija de forma permanente a 0°, las rojas cuando este ángulo se fija a 90°, las líneas amarillas representan las señales cuando se aplica el controlador neuronal (RBF), las líneas moradas representan la acción del controlador basado en aprendizaje por refuerzo (REINF), y finalmente la línea verde es el valor de potencia nominal.




Figura 8: Comparación de potencias de salida para diferentes controladores

En este experimento el viento se genera de forma aleatoria, con una velocidad media entre 11.5 m/s y 14 m/s. La red neuronal empleada es una red de base radial, RBF, con 25 neuronas en la capa oculta. Se ha probado con 9, 25, 49, 81 y 121 neuronas. Se ha observado que un mayor número de neuronas reduce el error cuadrático medio, pero la complejidad computacional de la red aumenta. Por este motivo, el número de neuronas en la capa oculta se ha fijado en 25 buscando un compromiso entre el rendimiento del controlador y la complejidad de la red. Es posible observar en la Figura 8 que tanto el controlador neuronal (amarillo) como el controlador basado en aprendizaje por refuerzo (morado) son capaces de estabilizar la potencia de salida cerca de su valor nominal, mejor que con las otras estrategias de control.

El par (Figura 9) tiene una forma similar a la potencia de salida, pero con una amplitud menor. Como era predecible, las señales cuando el pitch es 0° y 90° representan los límites superior e inferior en la potencia y en el par. Como el ángulo de pitch al comienzo de la simulación, cuando se aplica el

controlador con aprendizaje por refuerzo, es mayor, aproximadamente hasta el segundo 8, el sobreimpulso obtenido en la potencia y el par es menor en este caso.




Figura 9: Comparación de par para diferentes controladores.

En la Figura 10 se puede observar cómo el controlador con la red neuronal lleva la pala a valores de pitch más altos, pero con un retardo inicial de unos 2 s. Esto hace que a partir del segundo 8, aproximadamente, el valor de potencia de salida sea menor para este controlador. En el segundo 20 la potencia es menor que el valor nominal, lo que hace que el pitch comience a disminuir. A partir de ese momento las variaciones del ángulo de las palas se reducen porque la potencia se mantiene más cerca de su valor nominal.




Figura 10: Comparación de ángulo de pitch para diferentes controladores.

En el caso del controlador con aprendizaje por refuerzo no se llegan a valores de ángulo de pitch tan altos y a partir del sobrepico la potencia de salida decrece hasta alcanzar el valor nominal. El controlador aprende a compensar el error de potencia inicial manteniendo unos valores medios de pitch. A partir del segundo 60, cuando los errores de potencia son bajos, los controladores se comportan de forma parecida.

La Figura 11 muestra la evolución del error cuadrático medio de la potencia de salida respecto del valor nominal para diferentes tamaños de red. El color de la línea se asocia al número de neuronas. Se puede observar cómo la red neuronal aprende en cada iteración, y el error de potencia se va

reduciendo. Todas las curvas tienen más o menos la misma forma, diferenciándose en la pendiente antes del punto de inflexión y en el valor del punto de inflexión. De forma general se puede afirmar que la velocidad de aprendizaje antes del punto de inflexión crece con el número de neuronas. Sin embargo, esta tasa de crecimiento no es constante, se hace más pequeña conforme se aumenta el número de neuronas.




Figura 11: Evolución del error cuadrático medio de la potencia de salida cuando se aplica el controlador neuronal.

7. Conclusiones y trabajos futuros

En este trabajo se presentan diferentes estrategias de control inteligente aplicadas al control del ángulo de las palas de una turbina eólica. Las técnicas usadas son redes neuronales y aprendizaje por refuerzo. En concreto se describe el control directo de pitch mediante redes neuronales y mediante aprendizaje por refuerzo. Estas técnicas también se combinan con una tabla de búsqueda y un controlador PID.

En el ejemplo de aplicación se puede observar cómo estos controladores inteligentes son capaces de estabilizar en simulación la potencia de salida de una turbina pequeña de 7 kW. También se muestra como el controlador neuronal aprende en cada iteración a reducir el error cuadrático medio de la potencia de salida.

Como trabajos futuros se plantea el probar estas técnicas en turbinas de gran tamaño, y considerar el caso de las turbinas flotantes, donde sería necesario analizar las vibraciones causadas por el control. También sería deseable validar estas configuraciones de control inteligente en un aerogenerador real.

Agradecimientos

Este trabajo de investigación ha sido desarrollado con financiación parcial del Proyecto MCI AEI/FEDER RTI2018-094902-B-C21, del Ministerio de Ciencia, Innovación y Universidades.

Referencias

- Abouheaf, M., Gueaieb, W., Sharaf, A. 2018. Model-free adaptive learning control scheme for wind turbines with doubly fed induction generators. *IET Renewable Power Generation* 12(14), 1675–1686.
- Alvarez-Ramos, C. M., Santos, M., López, V. 2010. Reinforcement learning vs. A* in a role playing game benchmark scenario. In *Computational Intelligence: Foundations and Applications* (pp. 644–650).
- Asghar, A. B., Liu, X. 2018a. Adaptive neuro-fuzzy algorithm to estimate effective wind speed and optimal rotor speed for variable-speed wind turbine. *Neurocomputing* 272, 495–504.
- Asghar, A. B., Liu, X. 2018b. Estimation of wind speed probability distribution and wind energy potential using adaptive neuro-fuzzy methodology. *Neurocomputing*, 287, 58–67.
- Casteleiro-Roca, J.L., Quintián, H., Calvo-Rolle, J.L., Méndez-Pérez, J. A., Perez-Castelo, F.J., Corchado, E. 2020. Lithium iron phosphate power cell fault detection system based on hybrid intelligent system. *Logic Journal of the IGPL*, 28(1), 71–82.
- Chavero-Navarrete, E., Trejo-Perea, M., Jáuregui-Correa, J. C., Carrillo-Serrano, R. V., Ronquillo-Lomeli, G., Ríos-Moreno, J. G. 2020. Hierarchical pitch control for small wind turbines based on fuzzy logic and anticipated wind speed measurement. *Applied Sciences*, 10(13), 4592.
- Chen, P., Han, D., Tan, F., Wang, J. 2020. Reinforcement-based robust variable pitch control of wind turbines. *IEEE Access* 8, 20493–20502.
- Demirdelen, T., Tekin, P., Aksu, I. O., Ekinçi, F. 2019. The prediction model of characteristics for wind turbines based on meteorological properties using neural network swarm intelligence. *Sustainability*, 11(17), 4803.
- Deng, X., Yang, J., Sun, Y., Song, D., Xiang, X., Ge, X., Joo, Y. H. 2019. Sensorless effective wind speed estimation method based on unknown input disturbance observer and extreme learning machine. *Energy*, 186, 115790.
- Deng, X., Yang, J., Sun, Y., Song, D., Yang, Y., Joo, Y. H. 2020. An effective wind speed estimation based extended optimal torque control for maximum wind energy capture. *IEEE Access*, 8, 65959–65969.
- Du, J., Wang, B. 2020. Pitch Control of wind turbines based on BP neural network PI. In *Journal of Physics: Conference Series* (Vol. 1678, No. 1, p. 012060). IOP Publishing.
- El Maati, Y. A., El Bahir, L. 2020. Optimal fault tolerant control of large-scale wind turbines in the case of the pitch actuator partial faults. *Complexity*.
- Fernandez-Gauna, B., Fernandez-Gamiz, U., Grana, M. 2017. Variable speed wind turbine controller adaptation by reinforcement learning. *Integrated Computer-Aided Engineering* 24(1), 27–39.
- Fernandez-Gauna, B., Osa, J. L., Graña, M. 2018. Experiments of conditioned reinforcement learning in continuous space control tasks. *Neurocomputing* 271, 38–47.
- Guo, C., Wang, D. 2019. Frequency regulation and coordinated control for complex wind power systems. *Complexity*, 2019.
- Hosseini, E., Aghadavoodi, E., Ramírez, L. M. F. 2020. Improving response of wind turbines by pitch angle controller based on gain-scheduled recurrent ANFIS type 2 with passive reinforcement learning. *Renewable Energy*, 157, 897-910.
- IRENA. 2019. Future of wind: Deployment, investment, technology, grid integration and socio-economic aspects (A Global Energy Transformation paper), International Renewable Energy Agency, Abu Dhabi. https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2019/Oct/IRENA_Future_of_wind_2019.pdf
- Jeon, T., Paek, I. 2021. Design and verification of the LQR controller based on fuzzy logic for large wind turbine. *Energies*, 14(1), 230.
- Jie, W., Jingchun, C., Lin, Y., Wenliang, W., Jian, D. 2020. Pitch control of wind turbine based on deep neural network. In *IOP Conference Series: Earth and Environmental Science* (Vol. 619, No. 1, p. 012034). IOP Publishing
- Jove, E., Casteleiro-Roca, J. L., Quintián, H., Méndez-Pérez, J. A., Calvo-Rolle, J. L. 2019. A fault detection system based on unsupervised techniques for industrial control loops. *Expert Systems*, 36(4), e12395.
- Jove, E., Casteleiro-Roca, J., Quintián, H., Méndez-Pérez, J. A., Calvo-Rolle, J. L. 2020. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador. *Revista Iberoamericana de Automática e Informática industrial*, 17(1), 84–93.
- Li, M., Wang, S. 2019. Dynamic fault monitoring of pitch system in wind turbines using selective ensemble small-world neural networks. *Energies*, 12(17), 3256.
- Mikati, M., Santos, M., Armenta, C. 2013. Electric grid dependence on the configuration of a small-scale wind and solar power hybrid system. *Renewable energy*, 57, 587–593.
- Moodi, H., Bustan, D. 2019. Wind turbine control using TS systems with nonlinear consequent parts. *Energy*, 172, 922–931.
- Naciones Unidas. 2021. <https://sdgs.un.org/2030agenda>. Accedido por última vez en 15/08/2021
- Ngo, Q. V., Chai, Y., Nguyen, T. T. 2020. The fuzzy-PID based-pitch angle controller for small-scale wind turbine. *International Journal of Power Electronics and Drive Systems*, 11(1), 135.
- Our World in Data. 2021. <https://ourworldindata.org/renewable-energy>. Accedido por última vez en 15/08/2021.
- Phan, B. C., Lai, Y. C. 2019. Control strategy of a hybrid renewable energy system based on reinforcement learning approach for an isolated microgrid. *Applied Sciences*, 9(19), 4001.
- Ren, H., Hou, B., Zhou, G., Shen, L., Wei, C., Li, Q. 2020. Variable pitch active disturbance rejection control of wind turbines based on BP neural network PID. *IEEE Access*, 8, 71782–71797.
- Rubio, P. M., Quijano, J. F., López, P. Z., Lozano, J. J. F., Cerezo, A. G., Casanova, J. O. 2019. Control inteligente para mejorar el rendimiento de una plataforma semisumergible híbrida con aerogeneradores y convertidores de oleaje: sistema de control borroso para la turbina. *Revista Iberoamericana de Automática e Informática industrial*, 16(4), 480-491.
- Saénz-Aguirre, A., Zulueta, E., Fernández-Gamiz, U., Lozano, J., Lopez-Guede, J. M. 2019. Artificial neural network based reinforcement learning for wind turbine yaw control. *Energies* 12(3), 436.
- Saénz-Aguirre, A., Zulueta, E., Fernandez-Gamiz, U., Ulazia, A., Teso-Fz-Betono, D. 2020. Performance enhancement of the artificial neural network-based reinforcement learning for wind turbine yaw control. *Wind Energy* 23(3), 676–690.
- Santos, M. 2011. Un enfoque aplicado del control inteligente. *Revista Iberoamericana de Automática e Informática Industrial IRAI* 8(4), 283–296.
- Sedighizadeh, M., Rezazadeh, A. 2008. Adaptive PID controller based on reinforcement learning for wind turbine control. In: *Proc. World Academy of Science, Engineering and Technology* 27, 257–262.
- Sierra, J. E., Santos, M. 2018. Modelling engineering systems using analytical and neural techniques: Hybridization. *Neurocomputing*, 271, 70–83.
- Sierra-García, J. E., Santos, M. 2020a. Performance analysis of a wind turbine pitch neurocontroller with unsupervised learning. *Complexity*, 2020.
- Sierra-García, J. E., Santos, M. 2020b. Exploring reward strategies for wind turbine pitch control by reinforcement learning. *Applied Sciences*, 10(21), 7462.
- Sierra-García, J. E., Santos, M. 2021a. Improving wind turbine pitch control by effective wind neuro-estimators. *IEEE Access*, 9, 10413–10425.
- Sierra-García, J. E., Santos, M. 2021b. Lookup table and neural network hybrid strategy for wind turbine pitch control. *Sustainability*, 13(6), 3235.
- Sierra-García, J. E., Santos, M. 2021c. Deep learning and fuzzy logic to implement a hybrid wind turbine pitch control. *Neural Computing and Applications*, 1–15.
- Sutton, R. S., Barto, A. G. 2015. Reinforcement learning an introduction—Second edition, in progress.
- Tomás-Rodríguez, M., Santos, M. 2019. Modelado y control de turbinas eólicas marinas flotantes. *Revista Iberoamericana de Automática e Informática Industrial*, 16(4), 381–390.
- Tomin, N., Kurbatsky, V., Guliyev, H. 2019. Intelligent control of a wind turbine based on reinforcement learning. In *16th Conf. on Electrical Machines, Drives and Power Systems ELMA*, 1–6. IEEE.
- Vives, J., Quiles, E., García, E. 2020. AI techniques applied to diagnosis of vibrations failures in wind turbines. *IEEE Latin America Transactions*, 18(08), 1478–1486.
- Zhao, H., Zhao, J., Qiu, J., Liang, G., Dong, Z. Y. 2020. Cooperative wind farm control with deep reinforcement learning and knowledge assisted learning. *IEEE Transactions on Industrial Informatics*.