



Parametrización de un Volante de Inercia para la Estabilización Energética entre una Turbina Eólica y una Planta Desaladora

Pedro Cabrera¹, José A. Carta¹, Juan Carlos Torres-Bordón¹, Arturo Medina-Darias¹

¹ Group for the Research on Renewable Energy Systems, Departamento de Ingeniería Mecánica, Universidad de Las Palmas de Gran Canaria, pedro.cabrerasantana@ulpgc.es, jose.carta@ulpgc.es

El acceso a agua potable es un desafío global, particularmente en regiones áridas y costeras. La desalinización por ósmosis inversa ha surgido como una solución efectiva, aunque depende tradicionalmente de energías fósiles. En este contexto, las energías renovables, como la eólica, han ganado protagonismo gracias a su madurez y costo reducido. No obstante, la variabilidad de los recursos renovables plantea desafíos operativos, requiriendo soluciones como almacenamiento en baterías, modularidad de plantas o estabilización mediante volantes de inercia.

Este trabajo se enmarca en el Proyecto INERTIA, que busca desarrollar un sistema innovador de volantes de inercia de bajo costo con gestión inteligente, para optimizar el uso de energía eólica en plantas desalinizadoras. Como primer paso, se presenta la parametrización mecánica de un prototipo de volante de inercia, analizando variables críticas como potencia, energía, velocidad angular, vibraciones y temperatura del motor para ajustarse a la inherente variabilidad del viento. Este desarrollo permitirá garantizar la estabilidad dinámica y eficiencia energética, contribuyendo a una transición sostenible hacia energías renovables en sistemas de desalinización.

Los resultados obtenidos demuestran la factibilidad del uso de esta tecnología, aunque evidencian diferencias significativas en la precisión del modelo dependiendo del tipo de operación. Cuando se utiliza el conjunto total de datos y un único modelo, se alcanzan errores medios en torno a 244 rpm y un error absoluto porcentual medio (MAPE) aproximado del 17,8%. Sin embargo, al generar modelos diferenciados para la aceleración y la desaceleración del volante, se observa una mejora notable en la predicción de la aceleración, con un error absoluto medio (MAE) de 137 rpm y un MAPE de 7,5%. En contraste, el modelo de desaceleración presenta un mayor margen de error, con un MAE de 308,5 rpm y un MAPE de 18,65%. La validación cruzada con diez iteraciones confirma estas diferencias de desempeño, lo que sugiere la necesidad de optimizar el proceso de descarga de energía. A pesar de estas disparidades, el sistema demuestra su potencial para integrarse en microrredes de desalación alimentadas por energía eólica, allanando el camino hacia una producción de agua potable más sostenible y autónoma.

1. Introducción

El acceso a agua potable sigue siendo uno de los grandes desafíos del siglo XXI, especialmente en regiones áridas o costeras donde las fuentes de agua convencionales resultan insuficientes o inestables [1]. En este contexto, la desalinización por ósmosis inversa se consolida como una alternativa prometedora, aunque históricamente ha dependido de energías fósiles para su funcionamiento) [2]. El auge de la energía eólica como recurso renovable competitivo, limpio y cada vez más económico, abre la puerta a sistemas de desalinización más sostenibles y menos costosos desde el punto de vista ambiental [2].

Sin embargo, la naturaleza fluctuante del viento introduce incertidumbres y desequilibrios en la operación de las plantas desaladoras [3]. Para abordar este reto, se han planteado múltiples estrategias de estabilización energética, entre las que destacan los sistemas de almacenamiento en baterías [4–6], la modularidad de las plantas [4–6], y el uso de volantes de inercia [7]. En particular, los volantes de inercia ofrecen una respuesta rápida de inyección o absorción de potencia, lo que los hace especialmente útil es para suavizar las variaciones del viento y garantizar la continuidad del proceso de desalación [7–9].

Este artículo se enmarca en el Proyecto INERTIA, orientado al desarrollo de un sistema basado en un volante de inercia de bajo costo y con gestión inteligente de la velocidad angular. El objetivo es optimizar la integración de la energía eólica en sistemas de desalación, proporcionando una alternativa de almacenamiento que reduzca el impacto de las fluctuaciones de potencia. Para ello, como primer paso es necesario parametrizar el comportamiento del volante, para posteriormente gestionar su operatividad. Por tanto, para abordar la parametrización, en este trabajo se propone aplicar el método de extracción de conocimiento (KDD), combinando técnicas de Minería de Datos y algoritmos de aprendizaje automático, con la finalidad de estimar y ajustar en tiempo real la velocidad angular del volante según las exigencias de la red y la planta desaladora.

La estructura del presente trabajo incluye la descripción de los componentes y las mediciones experimentales realizadas (secciones de Materiales y Métodos), así como el proceso de ajuste y validación de los modelos predictivos de velocidad angular (minería de datos y sus resultados). Adicionalmente, se presenta el procedimiento para el cálculo del coeficiente de pérdidas del volante de inercia, un parámetro necesario para determinar la eficiencia energética del sistema. Finalmente, se discuten los resultados más destacados y se exponen las conclusiones, perfilando posibles líneas de investigación futura que permitan afianzar esta solución en escenarios de alta penetración de energías renovables y alta demanda de agua potable.

2. Materiales

A continuación, se explicará brevemente las principales partes del sistema:

1. Un volante de inercia en forma de disco, fabricado en acero AISI 1045. Posee un peso de 790 N, un diámetro de 450 mm, un espesor de 80 mm y un volumen de 9784.6 cm³.
2. Un motor eléctrico trifásico de inducción (modelo *TECHTOP T2ARI32S2-2*) diseñado para operar a una velocidad nominal de 2920 rpm, con una tensión de 400V en corriente alterna (CA) y una potencia nominal de 7.5 kW.
3. Un sistema de adquisición, control y monitorización de las variables electromecánicas que intervienen en el proceso, compuesto por los elementos que se aprecian en la Figura 1.
 - A) Elementos de seguridad y control, compuesto por un diferencial con una sensibilidad de 300mA-40A e interruptores automáticos Q2, Q3, Q4 y Q5.
 - B) Analizadores de red situados a la entrada y a la salida del sistema. Estos nos permitiría registrar datos tales como la potencia reactiva, la potencia aparente etc.
 - C) Dos filtros diferentes, uno de línea y uno de armónicos (LCL). Ambos de la marca *EPCOS*. El filtro de línea es un dispositivo diseñado para reducir o eliminar las interferencias electromagnéticas que pueden propagarse a través de la red eléctrica. En general, estos filtros se utilizan para suprimir el ruido existente, proteger el circuito y mejora el rendimiento del sistema. Los filtros LCL de armónicos es un dispositivo categorizado por tener dos inductores y un capacitor lo que le permite atenuar las frecuencias armónicas que pueden afectar el rendimiento de la red y dañar otros equipos. Por este motivo se coloca entre la fuente y la carga.
 - D) Un convertidor regenerativo de potencia, *D1000*, diseñado para aplicaciones de accionamiento de motores trifásicos en entornos industriales. Técnicamente, se trata de un sistema de conversión de energía AC-DC-AC que integra funciones tales como rectificación, conversión e inversión AC-DC con capacidad de control de la frecuencia, regeneración de energía, sistemas de diagnóstico y comunicación y operable en amplios rangos de potencia.

- E) Un variador de velocidad *OMRON* es el que permite el control dinámico de la velocidad y el par de un motor eléctrico, mediante el ajuste de la frecuencia y el voltaje de la energía suministrada. Sus componentes y funciones principales son el Bus de DC, etapa de rectificación, etapa de inversión y control y modulación.

La combinación del convertidor *D1000* y el variador de velocidad *OMRON* permite no solo controlar la velocidad y el par del motor, sino también recuperar energía durante el frenado, aportando ventajas significativas en términos de eficiencia energética y protección de la red eléctrica.

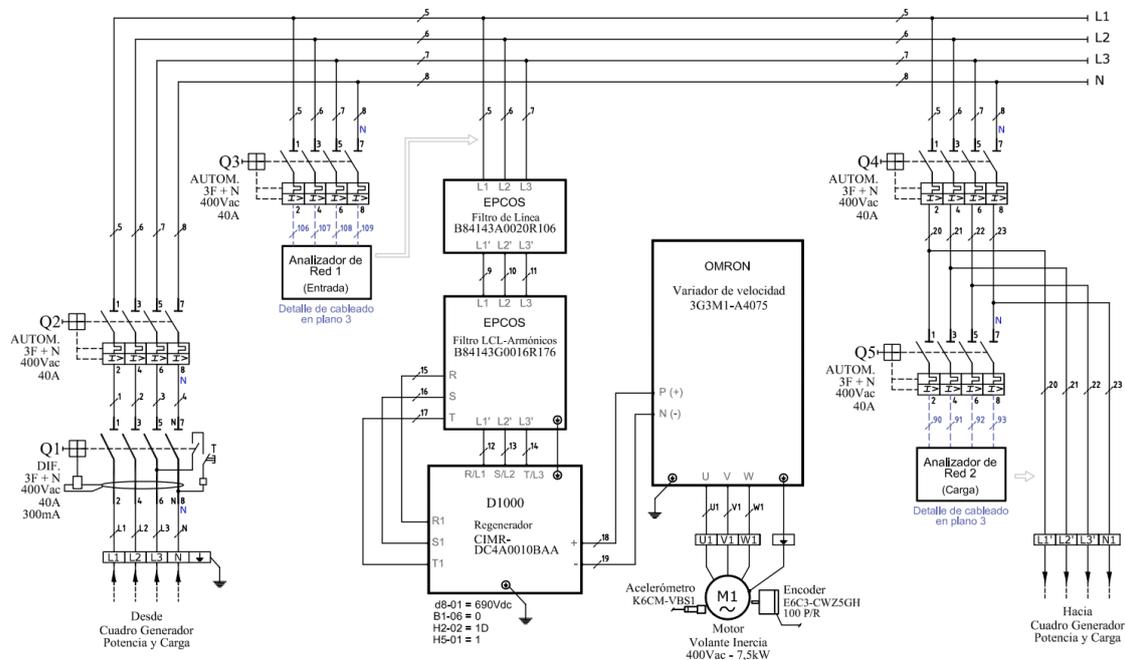


Figura 1: Sistema electrónico diseñado para analizar el volante de inercia.

4. Un autómata programable *OMRON* que se encarga de la monitorización y gestión de los datos. Este muestra en un sinóptico específico instalado en el cuadro del volante las diferentes medidas y registra los datos con un periodo de muestreo especificado por el usuario y establecido para este trabajo en 100 ms.

3. Métodos

El método empleado en este trabajo para gestionar de forma inteligente la velocidad angular del volante de inercia se fundamenta en el enfoque *KDD* (por sus siglas en inglés: *Knowledge Discovery in Databases*), propio del área de la Minería de Datos. Dicho proceso se define como la identificación y extracción de conocimiento útil a partir de una colección de datos [10]. Aunque en inglés se utiliza el término “*Discovery*” (descubrimiento), algunos autores optan por traducirlo directamente como “Proceso de extracción del conocimiento” [11]. Sin embargo, resulta más adecuado partir del concepto de “descubrimiento”, ya que implica hallar algo que previamente era desconocido [12]. Así, el *KDD* es un método que posibilita encontrar y extraer un conocimiento que no se tenía, pero que es potencialmente útil para comprender un sistema y alcanzar un objetivo específico. De forma similar a como el ser humano asimila nueva información en sus primeras etapas de aprendizaje, el *KDD* relaciona la información nueva con los objetivos concretos que se desean cumplir, apoyándose en técnicas de Aprendizaje Automático o *Machine Learning* para detectar los patrones idóneos y utilizar esa información en la dirección pretendida.

A continuación, se describen las diversas etapas seguidas para aplicar el método *KDD* al sistema mecánico objeto de estudio, tal como se detalló en el apartado anterior.

3.1. El proceso general de extracción del conocimiento (*KDD*)

Varios autores han propuesto múltiples variaciones y planteamientos del método *KDD*. Sin embargo, todos siguen una estructura muy similar a la representada en la Figura 2: De acuerdo a la interpretación que hacen Hernández-Orallo *et al.* [11] y Fayyad *et al.* [13] del método, el *KDD* consta de una secuencia iterativa de cinco etapas y fases [11]:

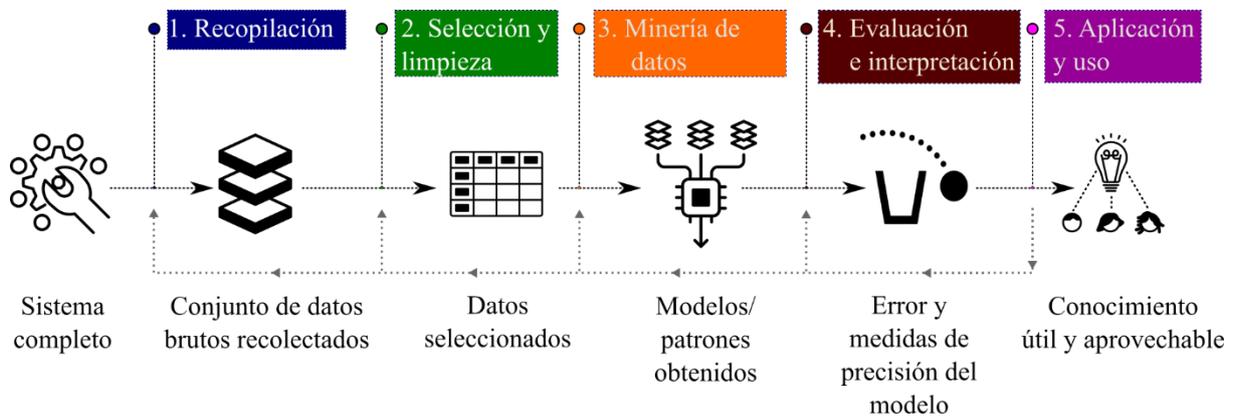


Figura 2: Esquema general del proceso de extracción del conocimiento (inspirado en los modelos propuestos por Hernández-Orallo et al. [12] y Fayyad et al. [14]).

1. **Recopilación:** Registro, recopilación e integración de los datos procedentes de distintas fuentes, sensores, ensayos o análisis.
2. **Selección y limpieza:** Se selecciona las variables que resultan de verdadero interés para el objetivo del estudio, se eliminan los datos incorrectos e incompletos con el fin de mejorar la calidad del conjunto. Por decisión se elimina los *outliers*, que son aquellos datos que no siguen la norma general del conjunto. Estos datos pueden alterar la precisión del algoritmo que se pretende crear, pero hay veces en las cuales no se pueden eliminar.
3. **Minería de datos:** Esta es la etapa más relevante del proceso KDD, en la que se selecciona y configura el modelo que se ajusta mejor a los datos y que proporciona las predicciones más precisas de las variables objetivo implicadas en la investigación. El modelo puede ser de tipo predictivo o descriptivo, según se utilice posteriormente con datos nuevos, no evaluados en esta fase, o se limite a aquellos datos ya presentes en el conjunto evaluado.
4. **Evaluación e interpretación:** En esta fase se somete el modelo a diferentes pruebas para evaluar y medir la precisión de su desempeño. Existen diversas técnicas para llevar a cabo esta evaluación, siendo la validación cruzada una de las más efectivas. Este método asegura que el modelo no dependa únicamente de los datos seleccionados para su entrenamiento. Con la validación cruzada, los datos se dividen en k subconjuntos; uno se reserva para la prueba y los restantes ($k-1$) se utilizan para entrenar el modelo. Este proceso se repite k veces, utilizando en cada iteración un subconjunto distinto para la prueba y calculando diversas métricas de error. Finalmente, el modelo se genera con todos los datos y se obtiene la media aritmética de los resultados de cada iteración. Habitualmente, se utiliza la validación cruzada con 10 iteraciones (*10-fold cross-validation*).
5. **Aplicación y uso:** una vez realizadas las etapas anteriores se utiliza el modelo resultante en la aplicación deseada.

3.2 El proceso de extracción del conocimiento (KDD) para la gestión inteligente de un volante de inercia.

En este trabajo se ha aplicado el método KDD, adaptando dicho procedimiento a las condiciones de partida preexistentes. Dado que no se disponía de datos previos del volante de inercia diseñado, se instrumentó el sistema mecánico en estudio y se tomaron medidas experimentales reales en laboratorio.

Los datos obtenidos se almacenaban en un servidor Propio de Microsoft en formato MSSQL. Se habilitó al entorno *GRAFANA* para la monitorización en tiempo real de las variables analizadas. Por otra parte, también se hizo uso de *MATLAB* para el análisis de los datos recopilados, para realizar la selección y limpieza de los mismos, para generar y configurar los modelos y para llevar a cabo su evaluación.

3.2.1 Recopilación de datos

En este estudio, el volante de inercia ha sido diseñado por los autores y nunca antes se ha puesto en funcionamiento. Por ello, se realizó una serie de pruebas (detalladas en la Tabla 1) con el fin de obtener un conjunto de datos brutos que permita caracterizar el comportamiento del volante al variar su velocidad angular.

Por eso mismo se ha decidido el hacer dos tipos de prueba, una de arranque en el cuál se variaba la rampa de subida para las diferentes velocidades. Esto quiere decir que desde que arrancamos hasta alcanzar la máxima velocidad no pasará más tiempo que la rampa marcada. Así se tomaron pruebas de rampas de 10,15 y 20 segundos. La

segunda prueba se basó en saltos de velocidad. Mientras se mantenía a una velocidad constante el volante se le daba la orden de saltar a otra velocidad. Si el salto es a una velocidad superior será un salto de subida y si el salto es a una velocidad inferior será un salto de bajada. Así podíamos recopilar datos como (potencia activa, potencia reactiva, potencia aparente, factor de potencia, energía consumida o suministrada, velocidad angular, temperatura, etc).

Tabla 1: Relación de cambios de velocidades angulares (rpm) ensayadas para caracterizar el volante de inercia.

w_2 w_1	2920	2800	2700	2600	2500	2400	2300	2200	2100	2000	1900	1800	1700	1600	1500	1400	1300	1200	1100	1000	900	800	700	600	500	400	
2920	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2800	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2700	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2600	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2500	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2400	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2300	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2200	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2100	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
2000	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
1900	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
1800	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
1700	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X	X
1600	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X	X
1500	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X	X
1400	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X	X
1300	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X	X
1200	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X	X
1100	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X	X
1000	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X	X
900	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X	X
800	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X	X
700	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X	X
600	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X	X	X
500	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*	X
400	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	*

El objetivo final de este estudio es controlar la velocidad angular del volante para que, en cada instante, genere o consuma la potencia requerida. Este propósito influye directamente en el diseño del procedimiento de caracterización, tal como se muestra en la Tabla 1. En dicha tabla se detalla la forma de explorar todas las variaciones posibles de velocidad angular en el sistema. En la primera columna se listan los distintos valores de velocidad angular w_1 evaluados, es decir, las velocidades a las que el volante estaba girando al inicio de cada prueba. Por otro lado, la fila superior indica los valores de velocidad angular w_2 , que corresponden a las velocidades finales alcanzadas en cada experimento. Por ejemplo, en la primera fila y segunda columna se observa que el volante partió a 2920 rpm y terminó a 2800 rpm. Además, los valores resaltados en rojo indican un consumo energético, mientras que los que aparecen en verde evidencian una generación de energía.

Para cada uno de los experimentos indicados en la Tabla 1: se generó un fichero de registro independiente con las variables siguientes muestreadas en intervalos de 0.1 segundo:

- Velocidad angular inicial, w_1 .
- Velocidad angular objetivo, w_2 .
- Potencia activa inicial, P_1 (en instante previo a realizar el cambio de velocidad angular).
- Potencia máxima activa final, P_2 (al realizar el cambio de velocidad angular).
- Potencia aparente inicial, S_1 .
- Potencia reactiva inicial, Q_1 .
- Factor de potencia inicial, FP_1 .

- Tensión continua en el circuito principal del variador, V_{dc}
- Energía consumida durante el cambio, E .
- Vibración media medida en la máquina eléctrica, $Vibration$
- Temperatura interna de la máquina eléctrica, T_1 .
- Periodo de tiempo invertido en el cambio desde la velocidad angular inicial a la final, t .

3.2.2 Selección y limpieza de datos:

En este apartado se ha llevado una agrupación de los datos obtenidos en los diferentes experimentos. Al ser *muestras* de 100 milisegundos se manejaba una gran cantidad de datos por *ensayo*, por lo que se optó por hacer un programa en MATLAB que permitió filtrar los datos por intervalos temporales de interés, creando una tabla resumen en donde se plasman estos valores, tales como la velocidad inicial, la velocidad final, energía total, potencia máxima, media de temperatura y de vibración.

Se creó el conjunto bruto de datos y se procedió a su limpieza y transformación para eliminar los registros incorrectos, los huecos vacíos, los valores duplicados, así como los *outliers* que pudieran registrarse en cambios transitorios del sistema. Como resultado de este proceso se obtuvo una selección de datos de 644 filas y 10 variables (columnas). Una muestra representativa de ella se observa en la Tabla 2:.

Tabla 2: Muestra representativa del conjunto total de datos seleccionados.

w_1 (rpm)	P_1 (kW)	P_2 (kW)	S_1 (kVA)	Q_1 (kVAr)	FP_1 (p.u.)	V_{dc1} (V)	$Vibration$ (mm/s)	T_1 (°C)	w_2 (rpm)
420,0	0,2	3,7	0,5	0,5	0,4	673,0	3,5	21,0	1027,0
420,0	0,2	3,1	0,5	0,5	0,4	671,0	4,5	20,4	1130,0
420,0	0,2	6,0	0,5	0,5	0,4	669,0	4,3	20,2	1233,0
...
719,4	0,3	4,8	0,5	0,5	0,5	670,0	7,9	21,0	1335,0
719,4	0,3	6,8	0,5	0,5	0,5	669,0	11,8	21,0	1438,0
719,4	0,3	8,1	0,5	0,5	0,5	671,0	6,1	21,3	1644,0
...
1027,0	0,3	1,5	0,5	0,6	0,6	674,0	7,1	20,0	1130,0
1027,0	0,3	2,5	0,5	0,6	0,6	670,0	6,2	20,0	1233,0
1027,0	0,3	5,5	0,5	0,6	0,6	667,0	12,1	20,1	1438,0

3.2.3 Minería de datos

Con el objetivo de conseguir gestionar de forma inteligente la velocidad angular del volante de inercia, se escoge un modelo de *Machine Learning* para describir el comportamiento del sistema. Concretamente, el modelo ha de estimar el salto necesario hacia una nueva velocidad angular para cumplir con el requerimiento de potencia solicitado en cada momento.

El modelo de regresión múltiple y su particular implementación como *Random Forests*

Como ya se ha indicado en el resumen y en la introducción de este artículo, para construir el modelo que estimará la velocidad angular del volante de inercia, se utiliza una técnica de *Machine Learning* que permite obtener valores continuos de dicha variable objetivo. Concretamente, se emplea la técnica conocida como Bosques Aleatorios o *Random Forest*, que pertenece a la categoría llamada *Methods* [1]. La característica común de estas técnicas es que entrenan múltiples funciones de regresión a la vez para modelar un mismo problema [1]. En la etapa final del ajuste, se ponderan las distintas soluciones de cada una de las funciones entrenadas y se obtiene la solución global del modelo.

Para entender bien los fundamentos matemáticos que respalda al método de regresión escogido, en primer lugar, se describe la función de regresión múltiple, aplicable a cualquier modelo de regresión. Posteriormente, se describe la particular variante que convierte a esta ecuación en un modelo de Bosques Aleatorios.

La salida determinada por un modelo de regresión está basada en el ajuste y el consecuente uso de la función de regresión múltiple definida por la Eq. 1.

$$y_i = f(x_1, x_2, \dots, x_k; \boldsymbol{\beta}) + \varepsilon_i, \quad i = 1, \dots, n \quad (1)$$

Donde, para una observación y_i de la variable de respuesta Y (o variable dependiente):

- el vector $\mathbf{x}_i = (x_1, x_2, \dots, x_k)^T$ es una observación de cada una de las k variables de entrada, comúnmente llamadas regresores o variables independientes;
- ε_i es el ruido aleatorio de cada observación de la variable respuesta;
- y $\boldsymbol{\beta}$ son los coeficientes, o parámetros, que definen las relaciones entre las variables de entrada y la variable de respuesta en la función.

Asimismo, para poder aproximar la variable respuesta y obtener nuevas estimaciones a partir de las variables de entradas, es necesario obtener una función basada en un conjunto de entrenamiento dado con n muestras de cada variable.

La técnica de *Machine Learning* conocida como Bosques Aleatorios (*Random Forest*)

En el caso concreto de los Bosques Aleatorios, se entrenan múltiples funciones de regresión conocidas como Árboles de Regresión y se combina el resultado que proporciona cada uno de ellos utilizando diferentes técnicas estadísticas [15]. De acuerdo con Hastie et al. [16], cada una de estas funciones de regresión individuales (árboles de regresión) responde a la forma expresada en la Eq.(1):

$$f(\mathbf{x}) = \sum_{i=1}^M \gamma_i I(\mathbf{x} \in R_i) \quad (2)$$

donde,

- γ_i son constantes para cada nodo “hoja” R_i . Para cada observación recogida en el interior de un nodo “hoja”, se establece la misma predicción. Como puede observarse en la Eq. (3), esta predicción es obtenida mediante el cálculo de la media \bar{y}_{R_i} de los valores objetivo y_j pertenecientes a dicho nodo hoja.

$$\gamma_i = \bar{y}_{R_i} = \frac{1}{n_i} \sum_{x_j \in R_i} y_j \quad (3)$$

- $I(\cdot)$ es una función que proporciona el valor 1 si el argumento de la condición (variable condicionante) que define al árbol es verdadero y 0 en caso contrario.
- n_i es el número total de observaciones de la variable objetivo Y pertenecientes al nodo hoja R_i .

Asimismo, los Bosques Aleatorios utilizan una mejora de la técnica estadística *bagging* (*bootstrap aggregating*) [17] que:

- genera T subconjuntos de entrenamiento aleatorios a partir del conjunto total de los n datos seleccionados para el estudio representada en la Tabla 2: (remuestreo con reemplazo),
- elige un conjunto aleatorio de variables condicionantes para los árboles de regresión que modelan cada subconjunto.

Con estas subdivisiones del conjunto total de datos se ajustan separadamente T árboles de regresión $f_j(x)$ (una por subconjunto) y después se promedian como indica la Eq.(4).

$$f_{RF}(x) = \frac{1}{T} \sum_{j=1}^T f_j(x) \quad (4)$$

Esta técnica se muestra especialmente útil en aquellos conjuntos de datos que presentan una alta varianza. Debido a que los *outliers* no pueden estar presentes en todas las subdivisiones del conjunto de datos, se reduce el ruido que provocan los mismos. En términos generales, puede decirse que esta técnica permite buscar respuestas diferentes en un mismo conjunto de datos. Cada algoritmo o función individual de regresión (árbol) trabaja con una subdivisión de datos diferentes, por lo que cada uno crea una hipótesis de trabajo distinta para representar la realidad que define el conjunto completo de datos. La programación de los Bosques Aleatorios se ha realizado con la función *TreeBagger* de la *Statistics and Machine Learning Toolbox* de *Matlab* [18].

3.2.4 Evaluación e interpretación

En este apartado se describen las métricas empleadas para medir la precisión de las estimaciones del modelo, así como el método empleado para llevar a cabo esta evaluación.

Métricas utilizadas para evaluar las estimaciones numéricas del modelo

Las métricas empleadas en este trabajo para evaluar las estimaciones numéricas del modelo propuesto han sido:

- El error absoluto medio (MAE, de las siglas en inglés *mean absolute error*)
- El error absoluto porcentual medio (MAPE, de sus siglas en inglés *mean absolute percentage error*).

El MAE está definido por la Eq. (5) donde los n valores estimados están representados por la letra "e" y los n valores observados por la letra "o". El MAE está expresado en las mismas unidades de los parámetros que compara [19].

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - \hat{e}_i| \quad (5)$$

El MAPE está definido por la Eq. (6) y es una medida relativa que expresa el error como porcentaje de los datos observados [19].

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{o_i - \hat{e}_i}{o_i} \right| \quad (6)$$

Método de entrenamiento y evaluación del modelo analizado

En la Figura 3: se muestra una representación esquemática del procedimiento utilizado para evaluar el modelo no lineal usado en este estudio. En la parte superior de la figura se distinguen los regresores (entradas al modelo) y la respuesta (salida del modelo) en el conjunto total de datos seleccionados para el estudio. Posteriormente, se aplica la técnica de validación cruzada de 10 iteraciones [16] para entrenar el modelo y ensayarlo 10 veces. Esta técnica sigue el procedimiento descrito a continuación:

1. Se reordenan aleatoriamente todas las muestras de la tabla de datos por filas, para garantizar la representabilidad de todos los datos.
2. El conjunto completo de datos se divide en 10 partes de igual tamaño, *pliegues* o *folds*, cada uno de ellos con el mismo número aproximado de muestras.
3. Se escogen 9 de esos *folds* (que representan el 90% del total de los datos) y se consideran estos temporalmente como el *subconjunto de entrenamiento*, que servirá para ajustar el modelo. El *fold* restante (que representa el 10% restante de las muestras totales de los datos) se considera temporalmente como el *subconjunto de ensayo* y, con él, se llevará a cabo un ensayo del modelo.
4. Con el *subconjunto de entrenamiento* (90% de los datos) se entrena un modelo de Bosques Aleatorios.
5. Este procedimiento se repite 10 veces para ir rotando el *subconjunto de ensayo* y obtener un total de 10 evaluaciones del modelo con subconjuntos diferentes de la misma tabla de datos. Como resultado, se obtienen 10 valores de error calculados mediante la aplicación de una métrica estadística. En este estudio, se emplean las dos métricas estadísticas mencionadas previamente (MAE y MAPE). Con ellas se puede cuantificar objetivamente el error entre el valor real de la variable objetivo (velocidad angular del volante) y el valor estimado por el modelo.
6. Por último, se calculan los valores medios y la desviación típica de los 10 valores obtenidos para cada métrica de error.

$$\overline{MAE} = \frac{1}{10} \sum_{i=1}^{10} MAE_i \quad (7)$$

$$\overline{MAPE} = \frac{1}{10} \sum_{i=1}^{10} MAPE_i \quad (8)$$

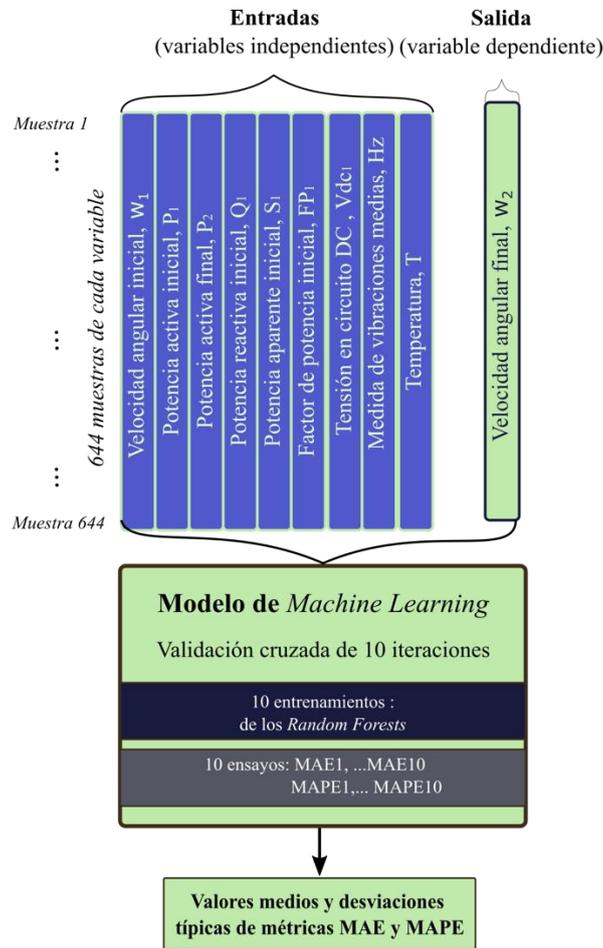


Figura 3: Método de entrenamiento y evaluación del modelo analizado.

3.2.5 Aplicación y uso.

Una vez creado y validado el modelo de regresión, se procede a su integración en el programa desarrollado en LabVIEW, para la gestión inteligente de la velocidad del volante de inercia. Así, el programa creado le solicitará al volante que varíe su velocidad angular de forma “inteligente”, para responder a las circunstancias cambiantes que se vayan produciendo en la operación. De forma simplificada, se pretende que el sistema actúe como indica el diagrama representado en la Figura 4:.

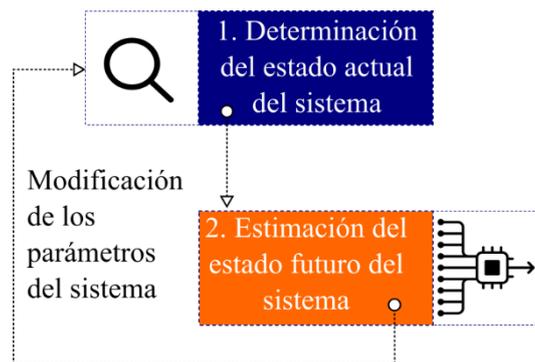


Figura 4: Diagrama de funcionamiento del sistema de gestión inteligente integrado en el volante de inercia.

De un modo más específico, en la Figura 5: se observa como el modelo de *Machine Learning* implementado gestiona la velocidad angular de forma inteligente. Por un lado, recibe como entradas las variables medidas en el instante actual, t_1 , (velocidad angular actual, potencia activa actual, potencia reactiva actual, factor de potencia actual, tensión eficaz actual, intensidad eficaz actual y temperatura actual). Por otro lado, recibe como entrada la potencia activa requerida para el instante futuro t_2 . Con esta información, el modelo estima la velocidad angular que debe tener el volante de inercia en el instante t_2 para lograr la potencia requerida.

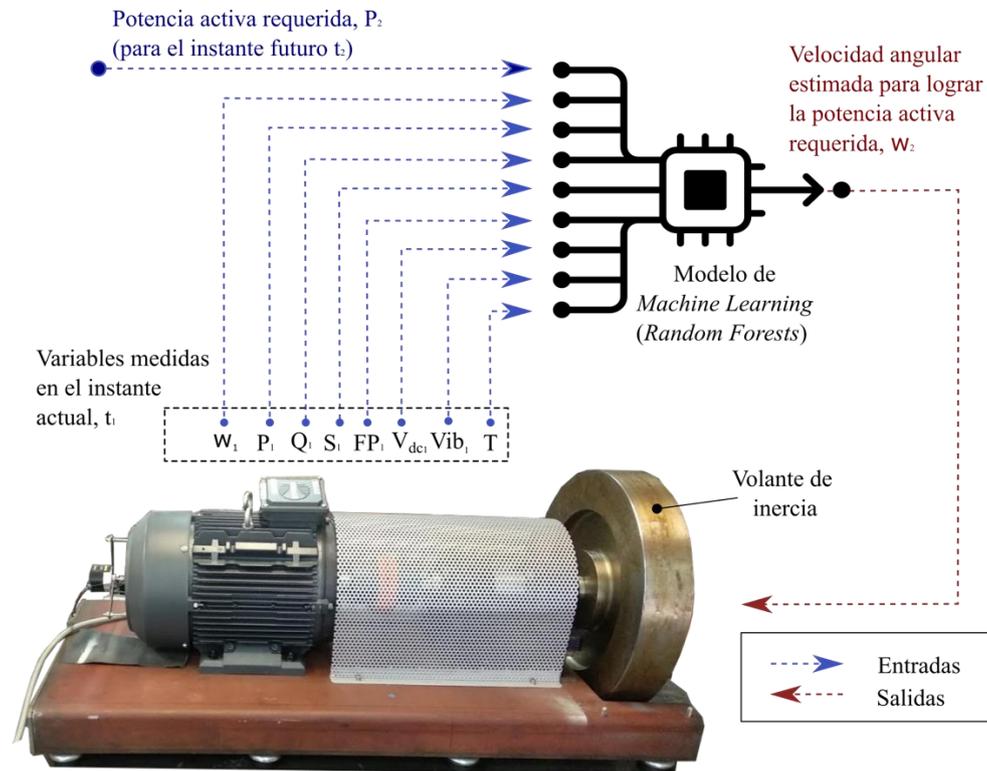


Figura 5: Esquema de gestión de variables de entrada y salida por parte del sistema inteligente implementado.

Esta implementación permite integrar al sistema de almacenamiento estudiado como un módulo más dentro de un sistema renovable más completo. Concretamente, el sistema irá integrado en una microrred eléctrica basada en una turbina eólica y una planta desaladora, cuyo propósito es la producción de agua desalada utilizando exclusivamente generación eléctrica de origen eólico. La potencia requerida P_2 se calculará a partir de la diferencia entre la potencia generada por el aerogenerador y la potencia consumida por la planta desaladora.

3.3 Cálculo del coeficiente de pérdidas del volante de inercia

Por último, en este trabajo se obtiene el coeficiente de pérdidas del volante de inercia. Como punto de partida se tiene la ecuación que gobierna el comportamiento dinámico del sistema rotativo:

$$I \frac{d\omega}{dt} + \gamma\omega = T \quad (1)$$

Esta ecuación representa una manifestación de la segunda ley de Newton para sistemas rotativos. En ella, I es el momento de inercia del volante, $\frac{d\omega}{dt}$ es la aceleración angular, γ es el coeficiente de fricción, ω es la velocidad angular, y T es el par aplicado al volante de inercia.

Esta ecuación encapsula la esencia del comportamiento del sistema, donde la suma de los momentos aplicados es igual al momento de inercia multiplicado por la aceleración angular, más el producto del coeficiente de fricción por la velocidad angular. Es esencial comprender que el coeficiente γ representa las pérdidas en el sistema, como la fricción interna y otras resistencias.

La constante de inercia (I) del volante de inercia se calcula con la siguiente fórmula:

$$I = \frac{1}{2} \cdot masa \cdot R^2 \quad (2)$$

Donde:

- I es el momento de inercia del volante de inercia.

- masa del volante.
- R es el radio del volante (225 mm).

Siendo la masa:

$$\begin{aligned} \text{masa} &= V \cdot \rho = 0,0127 \text{ m}^3 \cdot 7850 \text{ kg/m}^3 \\ &= 99,695 \text{ kg} \end{aligned} \quad (3)$$

- ρ es la densidad del acero (aprox. 7850 kg/m³)
- V es el volumen (0,0127 m³).

Por lo que:

$$\begin{aligned} I &= \frac{1}{2} \cdot \text{masa} \cdot R^2 = \frac{1}{2} \cdot 99,6950 \text{ kg} \cdot 0,225^2 \\ &= 2,5235 \text{ kg} \cdot \text{m}^2 \end{aligned} \quad (4)$$

El primer paso en la minería de datos fue utilizar las mediciones de potencia y velocidad angular para calcular el par. La relación entre la potencia (P), el par (T) y la velocidad angular (ω) se expresa mediante la fórmula:

$$P = T \times \omega \quad (5)$$

Reordenando esta ecuación, se puede resolver el par como:

Con los valores de par y velocidad angular calculados, el siguiente paso fue aplicar una regresión lineal para obtener el coeficiente de pérdidas del volante de inercia. Para entender esto mejor, primero simplificamos la ecuación (1). Consideramos el caso en el que no hay aceleración angular, es decir, la velocidad angular (ω) es constante y la aceleración angular ($d\omega/dt$) es cero. Por lo tanto, cuando $d\omega/dt = 0$, la ecuación se reduce a:

$$I \cdot 0 + \gamma\omega = T \quad (6)$$

Esta forma lineal permite aplicar una regresión lineal a los datos de par y velocidad angular para determinar el coeficiente de pérdidas γ , simplificándose así la ecuación:

$$T = \gamma\omega \quad (7)$$

Esta expresión revela una relación lineal entre el par y la velocidad angular, donde el coeficiente " γ " representa las pérdidas del sistema. Sin embargo, para obtener este coeficiente con precisión, es esencial asegurarse de que la gráfica de T en función de ω pase por el origen. Esto significa que cuando la velocidad angular es cero, el par aplicado al volante de inercia también lo es. Esta condición inicial es crucial, ya que nos permite determinar el coeficiente de pérdidas directamente de la pendiente de la gráfica. Esencialmente, el coeficiente de pérdidas se interpreta como la pendiente de esta relación lineal entre el par y la velocidad angular. Aquí es donde entra en juego la regresión lineal. Esta técnica estadística permite modelar la relación entre dos variables (en este caso, el par y la velocidad angular) mediante una línea recta que mejor se ajuste a los datos experimentales. Al ajustar esta línea, podemos determinar la pendiente, que representa el coeficiente de pérdidas del volante de inercia. La regresión lineal nos proporciona una herramienta poderosa para cuantificar y comprender las pérdidas en el sistema de forma precisa y basada en datos reales.

4. Resultados

Tras la aplicación de los métodos de ajuste y evaluación del modelo descritos previamente, se han obtenido los resultados que muestran las gráficas y tablas que siguen a continuación. En primer lugar, en la Figura 6: pueden observarse los resultados de la estimación de los datos agrupados de validación del modelo, al aplicar la técnica de validación cruzada. Asimismo, en la Tabla 3: muestran los valores numéricos de las métricas de error obtenidas en la validación cruzada. En dicha tabla puede observarse que el error MAE medio obtenido por el modelo es de unas 244 rpm, mientras que el error MAPE medio es de aproximadamente un 14.7%.

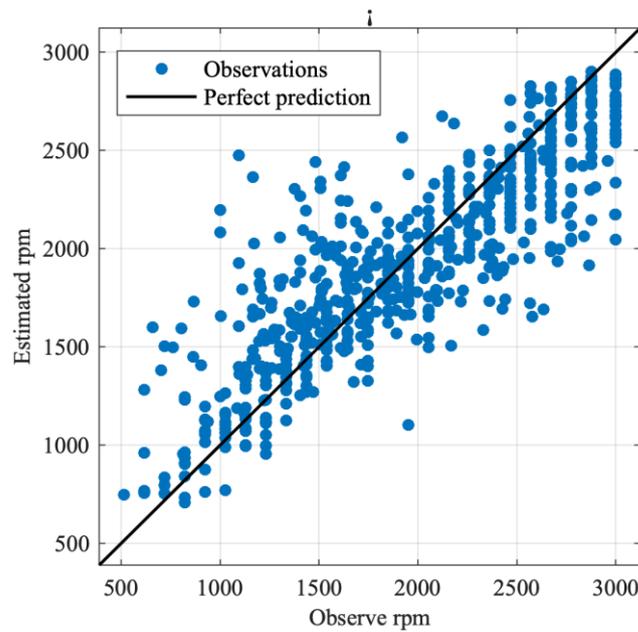


Figura 6: Resultados de las estimaciones del modelo utilizando el conjunto de validación de datos en la validación cruzada.

Tabla 3: Resultados de las métricas estadísticas obtenidos para cuantificar los errores del modelo al aplicar la validación cruzada.

MAE (rpm)	MAPE (%)
243,89	14,7

La Figura 7 muestra el análisis de importancia de Shapley para el modelo de Machine Learning aplicado a la estimación de la velocidad angular del volante de inercia. La importancia de Shapley proviene de la teoría de juegos y se ha adaptado en el campo de la interpretabilidad de modelos de Machine Learning para cuantificar la contribución que cada variable de entrada ejerce sobre la salida o predicción del modelo. En esencia, se calcula el efecto medio (marginal) que tiene cada característica al “unirse” a todas las posibles combinaciones de variables, capturando así el aporte promedio de cada una en el resultado final. En el eje vertical se listan las variables predictoras, mientras que en el eje horizontal se representa el valor medio absoluto de Shapley, indicando el impacto relativo de cada variable en la predicción del modelo. Se observa que la variable MaxP2 (potencia activa máxima tras el cambio de velocidad) es la más influyente en la predicción, seguida por Media_Vibration (vibración media) y w1 (velocidad angular inicial). Otras variables como Q1 (potencia reactiva inicial) y Media_Temperatura (temperatura media) también contribuyen al modelo, aunque con menor peso relativo. En contraste, la tensión del circuito principal en DC (MainCircuitDC_Voltage) tiene la menor relevancia en la estimación.

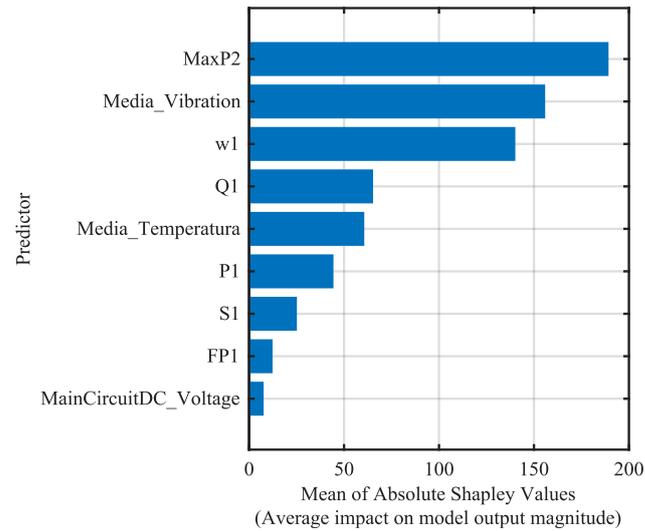
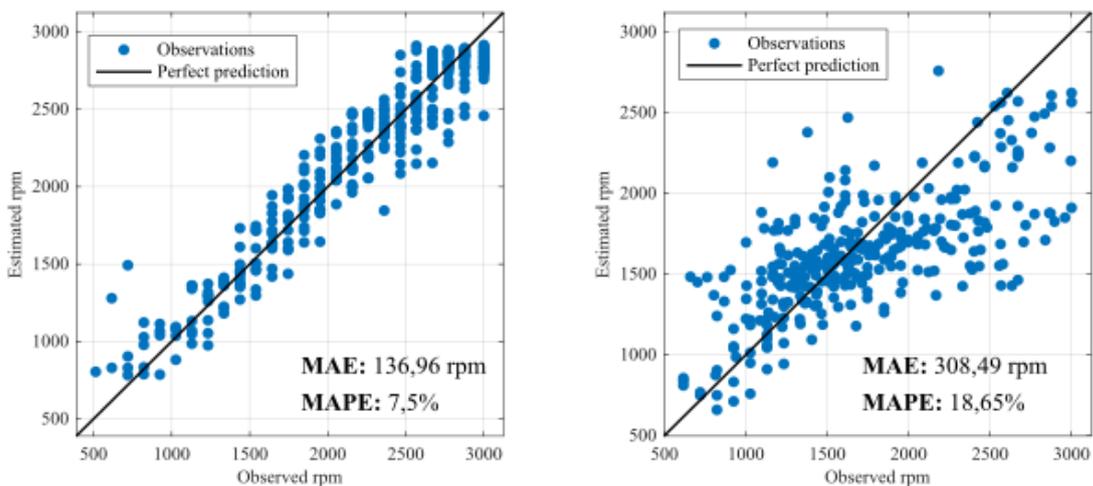


Figura 7: Importancia de Shapley de las variables predictoras en el modelo de *Machine Learning* para la estimación de la velocidad angular del volante de inercia. La variable **MaxP2** presenta el mayor impacto, mientras que la tensión en el circuito principal en DC es la de menor influencia.

Después de aplicar la validación cruzada con todo el conjunto de datos, se ha procedido a generar dos modelos, uno con los datos recopilados al acelerar el volante (carga de energía del mismo) y otros con los datos recopilados al frenar el volante (al descargar de energía al mismo). Como resultado, en la Figura 8., puede observarse gráficamente la precisión en la estimación y los errores MAE y MAPE alcanzados por el modelo para cada caso.



a) Resultados de la estimación de w_2 cuando el volante se acelera (se carga de energía)

b) Resultados de la estimación de w_2 cuando el volante se desacelera (se descarga de energía)

Figura 8: Resultados al crear dos modelos: uno para la carga de energía del volante y otro para la descarga del mismo.

Por último, la Figura 9 presenta los resultados del modelo lineal obtenido para estimar el coeficiente de pérdidas del volante. Para ello, se recopilaron datos de la velocidad angular del volante y de la potencia, a partir de los cuales se calcularon el par y el coeficiente de pérdidas [20].

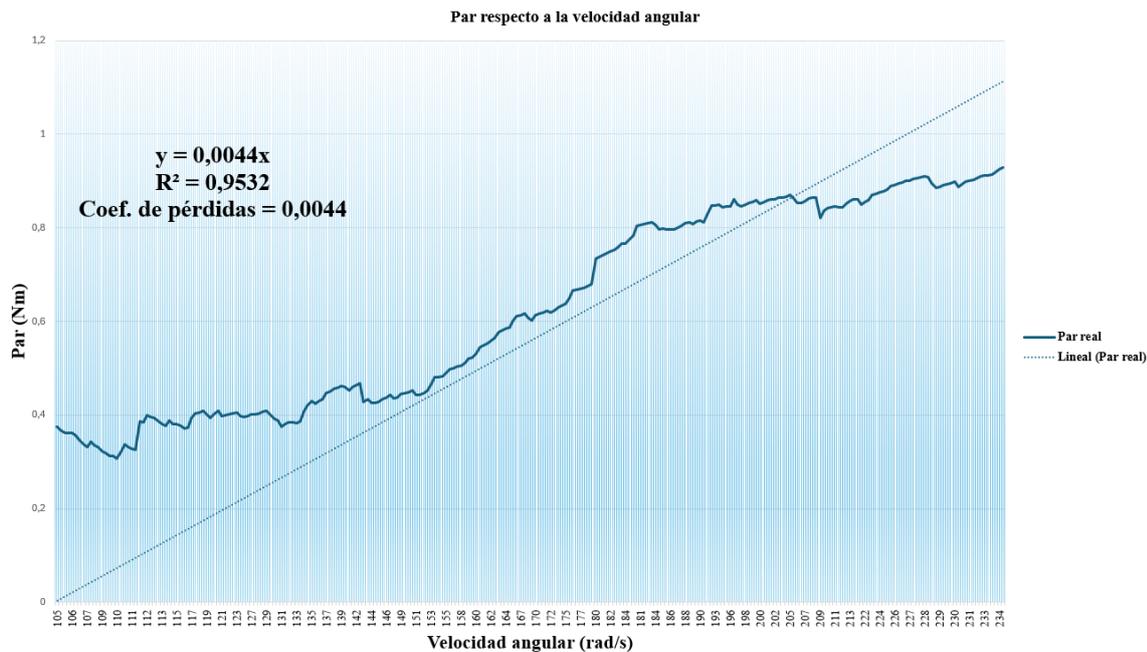


Figura 9: Resultado obtenido para la obtención del coeficiente de pérdidas del volante. Fuente: [20]

La Figura 9 revela una tendencia lineal positiva entre el par y la velocidad angular del volante de inercia. La ecuación de regresión lineal obtenida, $y = 0.0044x$, establece una relación matemática precisa entre ambas variables [20]. La solidez del modelo lineal para explicar la variabilidad del par se ve respaldada por un elevado coeficiente de determinación R^2 de 0.953, indicando que el 95.3% de los cambios en el par pueden ser explicados por la velocidad angular. Estos resultados confirman que el par generado por el volante de inercia aumenta de manera constante a medida que aumenta su velocidad angular [20]. Este comportamiento se debe a la mayor inercia rotacional del volante a mayores velocidades, lo que requiere un mayor par para su aceleración o desaceleración. La alta correlación entre el par y la velocidad angular, junto con el elevado valor de R^2 , demuestran que el modelo lineal es una herramienta confiable para predecir el par a partir de la velocidad angular [20].

Es importante destacar que el coeficiente de pérdidas obtenido, de $0.0044 \text{ Nm}/(\text{rad/s})$, indica la eficiencia del volante de inercia [20]. Un coeficiente de pérdidas bajo, como en este caso, sugiere que el volante de inercia almacena energía de manera eficiente y la libera con poca pérdida durante su rotación [20].

5. Conclusiones

En términos generales, los resultados experimentales evidencian que los volantes de inercia, apoyados en un sistema de control inteligente, constituyen una opción sumamente robusta para el almacenamiento y la estabilización de la energía procedente de un aerogenerador en plantas desaladoras. La precisión alcanzada en el ajuste de la aceleración y desaceleración del volante —con errores medios en torno a 244 rpm y un MAPE aproximado del 17,8%— demuestra la factibilidad de integrar esta tecnología en microrredes, logrando producir agua desalada sin recurrir a energías fósiles.

La aplicación del enfoque KDD y de técnicas de *Machine Learning*, en especial *Random Forest*, ha permitido identificar patrones capaces de estimar con cierta exactitud la velocidad angular más adecuada en cada situación. No obstante, la validación cruzada con diez iteraciones revela diferencias de desempeño cuando se generan dos modelos diferenciados para la carga (aceleración) y la descarga (desaceleración) del volante; este hecho sugiere la necesidad de profundizar en mejoras específicas para el proceso de descarga de energía. Aun así, el coeficiente de pérdidas, cifrado en alrededor de $0.0044 \text{ Nm}/(\text{rad/s})$, indica que el sistema presenta pérdidas relativamente bajas y mantiene una alta eficiencia en la transferencia de energía.

Gracias a su diseño modular y a la monitorización en tiempo real, el sistema es capaz de integrar fácilmente en microrredes compuestas por aerogeneradores y plantas desaladoras, aportando estabilidad al atenuar las variaciones propias de la fuente eólica. Esta capacidad para regular la velocidad angular en respuesta a fluctuaciones de potencia asegura un funcionamiento continuo y fiable de la desalación, impulsando una producción sostenible de agua potable. Con miras al futuro, se vislumbran varias vías de progreso, desde el perfeccionamiento del diseño mecánico para reducir aún más las pérdidas, hasta la incorporación de algoritmos de

inteligencia artificial más sofisticados y el escalado de las pruebas a entornos reales de gran magnitud. Con ello, se sientan bases sólidas para avanzar hacia sistemas de desalación más accesibles, resilientes y respetuosos con el medio ambiente, a la vez que se refuerza la independencia energética y se salvaguardan los recursos hídricos.

Agradecimientos

Este trabajo de investigación es parte del proyecto PID2022-142148OA-I00 financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE, integrado en la Plataforma DESAL+ Living Lab (desalinationlab.com).



Asimismo, parte de este trabajo ha sido cofinanciado por fondos FEDER, Programa INTERREG MAC 2021-2027, en el marco del proyecto IDIWATER (1/MAC/1/1.1/0022), integrado en la Plataforma DESAL+ Living Lab (desalinationlab.com).



6. Referencias

- [1] N. Alexandratos, J. Bruinsma, *World Agriculture Towards 2030/2050: The 2012 Revision*, (2012).
- [2] J. González, P. Cabrera, J.A. Carta, *Wind Energy Powered Desalination Systems*, in: *Desalination: Water from Water*, 2nd ed., John Wiley & Sons, Inc., Hoboken, NJ, USA, 2019: pp. 567–646. <https://doi.org/10.1002/9781119407874.ch14>.
- [3] J.A. Carta, P. Cabrera, J. González, *Wind Power Integration*, *Comprehensive Renewable Energy* (2022) 644–720. <https://doi.org/10.1016/B978-0-12-819727-1.00102-3>.
- [4] J.A. Carta, J. González, V. Subiela, *Operational analysis of an innovative wind powered reverse osmosis system installed in the Canary Islands*, *Solar Energy* 75 (2003) 153–168. [https://doi.org/10.1016/S0038-092X\(03\)00247-0](https://doi.org/10.1016/S0038-092X(03)00247-0).
- [5] J.A. Carta, J. González, V. Subiela, *The SDAWES project: an ambitious R&D prototype for wind-powered desalination*, *Desalination* 161 (2004) 33–48. [https://doi.org/10.1016/S0011-9164\(04\)90038-0](https://doi.org/10.1016/S0011-9164(04)90038-0).
- [6] V. Subiela, J.A. Carta, J. González, *The SDAWES project: lessons learnt from an innovative project*, *Desalination* 168 (2004) 39–47. <https://doi.org/10.1016/j.desal.2004.06.167>.
- [7] M. Mahmoud, M. Ramadan, A.G. Olabi, K. Pullen, S. Naher, *A review of mechanical energy storage systems combined with wind and solar applications*, *Energy Convers Manag* 210 (2020) 112670. <https://doi.org/10.1016/j.enconman.2020.112670>.
- [8] K.R. Pullen, *The Status and Future of Flywheel Energy Storage*, *Joule* 3 (2019) 1394–1399. <https://doi.org/10.1016/j.joule.2019.04.006>.
- [9] O. Schmidt, S. Melchior, A. Hawkes, I. Staffell, *Projecting the Future Levelized Cost of Electricity Storage Technologies*, *Joule* 3 (2019) 81–100. <https://doi.org/10.1016/j.joule.2018.12.008>.
- [10] C. Gamarra, J.M. Guerrero, E. Montero, *A knowledge discovery in databases approach for industrial microgrid planning*, *Renewable and Sustainable Energy Reviews* 60 (2016) 615–630. <https://doi.org/10.1016/j.rser.2016.01.091>.
- [11] J.; Hernández-Orallo, M.J.; Ramírez, C. Ferri, *Introducción a la Minería de Datos*, PRentice Hall, 2004.

- [12] C.J. Matheus, G. Piatetsky Shapiro, P.K. Chan, Systems for Knowledge Discovery in Databases, *IEEE Trans Knowl Data Eng* 5 (1993) 903–913. <https://doi.org/10.1109/69.250073>.
- [13] Z.H. Zhou, *Ensemble methods: Foundations and algorithms*, CRC Press, 2012. <https://doi.org/10.1201/b12207>.
- [14] U. Fayyad, G. Piatetsky-Shapiro, P. Smyth, From Data Mining to Knowledge Discovery in Databases, *AI Mag* 17 (1996) 37–54.
- [15] L. Breiman, Random forests, *Mach Learn* 45 (2001) 5–32.
- [16] T. Hastie, R. Tibshirani, J.H. (Jerome H.) Friedman, *The elements of statistical learning: data mining, inference, and prediction*, n.d.
- [17] L. Breiman, Bagging predictors, *Mach Learn* 24 (1996) 123–140. <https://doi.org/10.1007/bf00058655>.
- [18] Inc. The MathWorks, *Statistics and Machine Learning Toolbox Users Guide*, (2016).
- [19] J.A. Carta, P. Cabrera, J.M. Matías, F. Castellano, Comparison of feature selection methods using ANNs in MCP-wind speed methods. A case study, *Appl Energy* 158 (2015) 490–507. <https://doi.org/10.1016/j.apenergy.2015.08.102>.
- [20] H. Douairi, J.C. Torres-Bordón, J.A. Carta, P. Cabrera, Modelo lineal de pérdidas de un volante de inercia, in: J.E. Sierra García, M. Peñacoba Yagüe, P.J. Cabrera Santana (Eds.), *XIX Simposio CEA de Control Inteligente. Libro de Actas*, Universidad de Burgos, Burgos, 2025. <https://doi.org/10.36443/9788418465970>.