

CONGRESOS Y CURSOS

Coordinadores:

EDUARDO BAYONA BLANCO

MATILDE SANTOS PEÑAS

JESÚS ENRIQUE SIERRA GARCÍA

VII INTERNATIONAL WORKSHOP ON WIND (AND) WAVES ENERGY (WWWE 2026)



UNIVERSIDAD
DE BURGOS

COORDINADORES:
EDUARDO BAYONA BLANCO
MATILDE SANTOS PEÑAS
JESÚS ENRIQUE SIERRA GARCÍA

**VII International Workshop
on Wind (and) Waves Energy
(WWWE 2026)**



**UNIVERSIDAD
DE BURGOS**

2026

(CONGRESOS Y CURSOS, 92)

“VII International Workshop on Wind (and) Waves Energy
(WWWE 2026)”

UNIVERSIDAD DE BURGOS
12-13 enero de 2026

© LOS AUTORES

© UNIVERSIDAD DE BURGOS

Edita: Servicio de Publicaciones e Imagen Institucional

UNIVERSIDAD DE BURGOS

Edificio de Administración y Servicios

C/ Don Juan de Austria, 1,

09001 BURGOS - ESPAÑA

ISBN: 979-13-87585-35-8

DOI: <https://doi.org/10.36443/9791387585358>

Esta obra está bajo una licencia de [Creative Commons
Atribución-NoComercial-SinDerivadas 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)



VII International Workshop on Wind (and) Waves Energy WWWE 2026

Programa (Hybrid -online and in-person-)

January, 12

18:30 Apertura del VII International Workshop on Wind (and) Waves Energy WWW 2026

- Prof. Matilde Santos, Universidad Complutense de Madrid

19:00 Reunión de arranque (*kick-off*) del proyecto PID2024-155653OB-C21

- Prof. Matilde Santos, ISCAR, Universidad Complutense de Madrid

January, 13

9:30 Bienvenida y presentación de contribuciones científicas

- Presentación de contribuciones científicas aceptadas (vídeos 3')

11:00 Presentación presencial de líneas de investigación en curso

- Prof. María José Gómez
Detección de anomalías en turbinas eólicas con aprendizaje automático
- Prof. Lía García
Control individual del paso de pala para reducir la fatiga y aumentar la vida útil de aerogeneradores offshore
- Prof. Segundo Esteban
Normalización de datos y monitorización de anomalías para FOWT
- Prof. Fares Mzoughi
Performance Optimization of a Hybrid Offshore Wind-Wave Energy Platform)
- Prof. Jorge Contreras
Ciencia para la sostenibilidad: Viento, sol y agua
- Prof. Aitor Garrido
Generación Undimotriz y su uso en Plataformas Eólicas Flotantes
- Prof. Eduardo Muñoz
Hacia Turbinas Eólicas Inteligentes: Control Adaptativo para Máxima Potencia y Menor Vibración
- Prof. Payam Aboutalebi
Exploring Synergies Between Floating Offshore Wind and Wave Energy Systems
- Prof. Eduardo Bayona.
Técnicas Metaheurísticas para la optimización de procesos y desarrollos industriales
- Prof. Jesús Enrique Sierra
Control de turbinas basado en redes neuronales y aprendizaje por refuerzo
- Prof. María Tomás-Rodríguez
Modelado de vibraciones y control estructural

14:30 Parada para comer.

16:00 Taller. Prototipos de experimentación para el proyecto PID2024-155653OB-C21

- Prof. Segundo Esteban, ISCAR, Universidad Complutense de Madrid

17:30 Clausura de la Jornada

- Prof. Jesús Enrique Sierra, ISA, Universidad de Burgos.

COMITÉ ORGANIZADOR

Matilde Santos Peñas

Eduardo Bayona Blanco

Jesús Enrique Sierra García

COMITÉ CIENTÍFICO

Eduardo Bayona Blanco

Mario Peñacoba Yagüe

Alejandro Menéndez García

PONENTES INVITADOS

María José Gómez

Lía García

Segundo Esteban

Fares Mzoughi

Jorge Contreras

Aitor Garrido

Eduardo Muñoz

Payam Aboutalebi

Tahereh Bagheri Rouch

Eduardo Bayona

Jesús Enrique Sierra

María Tomás-Rodríguez

ÍNDICE

PRÓLOGO	9
CONTRIBUCIONES	11
Optimization of Control-Oriented AI Models for Real-Time Platform Pitch Prediction in Hybrid Wind–Wave Offshore Systems	13
Irfan Ahmad, Fares M’zoughi, Tahereh Bagheri Rouch, Izaskun Garrido, Aitor J. Garrido	
Control-Driven Battery Sizing and Emissions-Efficient Operation of Hybrid Ship Power Systems	19
Sadredin Hokmi, Aitor J. Garrido, Izaskun Garrido	
Design of Multi-Objective Model Parameter Identification Problems for Application in Floating Offshore Wind Turbines	25
Sandra Piernikowska, María Tomás Rodríguez	
Multi-Objective Optimization of Individual Pitch Control for Floating Offshore Wind Turbines	31
Lei Ren, Matilde Santos Peñas, Xin Cai	
Comparative Study of Generated Power and Fatigue in Floating Offshore Wind Turbines Using OpenFAST	36
Ignacio López, Juan Garrido, Manuel Lara, Francisco Vázquez, Mario L. Ruiz	
Investigación preliminar sobre redes convolucionales temporales para la predicción de energía eólica	42
Mario Peñacoba Yagüe, Jesús Enrique Sierra García, Matilde Santos Peñas	
Análisis Comparativo de las Tecnologías de Adhesión y Locomoción para un Sistema Robótico Trepador en Turbinas Eólicas	48
Gumersindo Fernández_García, Mario Peñacoba Yagüe, Alejandro Menéndez García, Jesús Enrique Sierra García	
Modelo basado en datos para la detección y clasificación de fallos en aerogeneradores marinos	54
Bassel Weiss, Segundo Esteban San Román, Matilde Santos Peñas	

Hacia la optimización de la energía eólica urbana: análisis preliminar mediante Dinámica de Fluidos Computacional	60
Sara Ocaña Muñoz, Jorge Contreras Martínez	
Sistema Neuro-difuso para Capturar el Comportamiento de una Turbina Eólica Marina en la Región de Carga Parcial	65
Eduardo Muñoz Palomeque, Matilde Santos Peñas, Jesús Enrique Sierra García	
Energías renovables en la Península Ibérica: análisis integral del potencial y oportunidades	71
Lucía Rodríguez Bethencourt, Jorge Contreras Martínez	
Evaluación Numérica de Esfuerzos en Palas de Turbinas Offshore mediante Dinámica de Fluidos Computacional: Estudio Preliminar	75
Sergio Corral Andrés, Jorge Contreras Martínez	
Respuesta Dinámica de una Plataforma Híbrida de Turbina Eólica Flotante con Columna de Agua Oscilante	81
Payam Aboutalebi, Segundo Esteban San Román, Matilde Santos Peñas	
Análisis Hidrodinámico de Aerogeneradores Marinos Flotantes	87
Tahereh Bagheri Rouch, Fares Mzoughi, Irfan Ahmad, Aitor J. Garrido, Izaskun Garrido	
Estudio de Análisis Hidrodinámico Comparativo en el Dominio de la Frecuencia de una Plataforma Híbrida de Aerogenerador Marino Flotante OWC	93
Fares Mzoughi, Virag Mishra, Curran Crawford, Aitor J. Garrido, Izaskun Garrido	
Optimización multi-coste de inventarios de repuestos en turbinas eólicas utilizando Particle Swarm	99
Verónica González González, Jesús Enrique Sierra García	

PRÓLOGO

La VII Jornada Internacional de Energía Eólica (y) Marina (WWWE 2026) se enmarca como una iniciativa surgida al amparo del proyecto PID2024-155653OB-C21. En pocos años, este evento se ha consolidado como una plataforma anual de referencia para presentar, discutir y difundir los desarrollos más relevantes en el ámbito de las energías renovables marinas, con especial énfasis en la energía eólica y oceánica. Al igual que en ediciones anteriores, esta convocatoria aspira a reforzar dichos objetivos, generando un entorno de convivencia científica que combine la investigación puntera, la formación de jóvenes investigadores, la relación con la industria y espacios de intercambio que fortalezcan nuestra comunidad.

En este contexto, la VII Jornada Internacional de Energía Eólica y Marina ofrece una oportunidad única para reunir a expertos, académicos y profesionales del sector con el fin de compartir avances e identificar retos comunes. El control avanzado y la inteligencia computacional, junto con las nuevas tecnologías de conversión y gestión de la energía, se revelan como herramientas esenciales para afrontar desafíos globales como el cambio climático y la resiliencia de las infraestructuras críticas. Con las contribuciones de esta edición, buscamos no solo impulsar el estado del arte, sino también crear nuevas sinergias que pongan el conocimiento generado al servicio de la sociedad.

Finalmente, expresamos nuestro sincero agradecimiento a los autores por la calidad de sus trabajos, así como al Comité Científico y a los revisores por su rigurosa labor de evaluación, garantía del nivel técnico de este congreso. Esperamos que estas actas sirvan como referencia duradera para la comunidad investigadora y que este encuentro en Burgos sea fructífero para todos.

Matilde Santos, Eduardo Bayona y Jesús Enrique Sierra

Organizadores de la VII Jornada Internacional de Energía Eólica (y) Marina (WWWE 2026)

Proyecto PID2024-155653OB-C21

CONTRIBUCIONES

Optimization of Control-Oriented AI Models for Real-Time Platform Pitch Prediction in Hybrid Wind–Wave Offshore Systems

1st Irfan Ahmad

Automatic Control Group - ACG

Department of Automatic Control and Systems Engineering

University of the Basque Country - UPV/EHU

Bilbao, Spain

irfan.ahmad@ehu.eus

2nd Fares M'zoughi

Automatic Control Group - ACG

Department of Automatic Control and Systems Engineering

University of the Basque Country - UPV/EHU

Bilbao, Spain

fares.mzoughi@ehu.eus

3rd Tahereh Bagheri Rouch

Automatic Control Group - ACG

Department of Automatic Control and Systems Engineering

University of the Basque Country - UPV/EHU

Bilbao, Spain

tahereh.bagheri@ehu.eus

4th Izaskun Garrido

Senior Member, IEEE

Automatic Control Group - ACG

University of the Basque Country - UPV/EHU

Bilbao, Spain

izaskun.garrido@ehu.eus

5th Aitor J. Garrido

Senior Member, IEEE

Automatic Control Group - ACG

University of the Basque Country - UPV/EHU

Bilbao, Spain

aitor.garrido@ehu.eus

Abstract—This study presents a control-oriented deep learning framework for real-time prediction of platform pitch motion in hybrid offshore wind-wave systems. The proposed framework integrates a hybrid CNN-LSTM architecture with time-frequency features extracted via the Fourier Synchrosqueezed Transform (FSST), enabling simultaneous spatial, temporal, and spectral representation learning. This combined design effectively captures the nonlinear and coupled dynamics inherent to floating platforms operating under wind and wave excitations. The model is trained on high-fidelity OpenFAST simulation data and achieves a root mean square error (RMSE) of 0.26 degrees with an inference latency of 15 ms. Robustness and generalization are verified under a wide range of environmental and control conditions, with sensitivity analyses confirming stable performance across varying wave heights, wind speeds, and control inputs. The study evaluates the model's embedded deployment feasibility, interpretability, and compatibility with model predictive control (MPC) architectures, demonstrating readiness for real-time implementation.

Index Terms—offshore wind, wave energy, hybrid platforms, deep learning, CNN-LSTM, FSST, real-time control

I. INTRODUCTION

The transition to renewable energy sources is essential for mitigating climate change, reducing greenhouse gas emissions,

and ensuring long-term energy security. Offshore wind energy has emerged as a critical component in this transformation, offering higher and more stable wind speeds than land-based alternatives. In regions like Europe, sustained policy support and continuous technological advancements have enabled the rapid deployment of large-scale offshore wind farms [1]. Innovations in floating support structures and marine energy conversion technologies further reinforce offshore wind's central role in the global clean energy landscape [2].

Hybrid floating offshore platforms combining wind and wave energy technologies provide enhanced power yield and improved stability through complementary energy capture mechanisms. However, the nonlinear coupling between aerodynamic and hydrodynamic forces introduces significant modeling complexity, particularly for control-oriented design. Conventional numerical solvers such as OpenFAST and WEC-Sim offer high accuracy but are computationally expensive and unsuitable for real-time control applications due to their reliance on iterative solution methods and fine temporal discretization.

The integration of Oscillating Water Columns (OWCs) with Floating Offshore Wind Turbines (FOWTs) introduces complex, coupled dynamics that span aerodynamic forces, hydrodynamic loading, structural behavior, and control system interactions. Conventional modeling techniques such as

This work was supported by the Basque Government through project IT1555-22 and by MCIN/AEI/10.13039/501100011033 and European Union NextGenerationEU/PRTR through project TED2021-131295B-C31.

linearized potential flow theory and simplified coupled simulation frameworks are often inadequate in capturing the full range of nonlinear phenomena associated with wind and wave interactions, including viscous damping, resonance effects, and stochastic environmental excitations [3]. Recent studies have employed artificial intelligence-based approaches for nonlinear system identification and performance modeling [4], [5], while others have proposed control optimization frameworks and coupled dynamic simulations for floating hybrid platforms [6]–[9]. Additional contributions have focused on experimental validation and the dynamic behavior of various configurations under operational and extreme marine conditions [10]–[12].

Despite these advancements, there remains a critical research gap: the lack of real-time, control-oriented predictive models that can accurately estimate the platform's pitch motion in offshore environments while maintaining low computational demands suitable for embedded control systems. Real-time motion prediction is essential for model predictive control (MPC) architectures, which require fast and accurate forecasts to compute optimal control actions within tight latency constraints (typically below 50 ms). Furthermore, existing deep learning approaches have not adequately addressed the challenge of capturing low-frequency pitch dynamics (0.05-0.2 Hz resonance) using short sampling windows, nor have they provided comprehensive validation under diverse environmental scenarios.

The present study addresses these challenges by introducing a deep learning-based surrogate model that integrates convolutional neural networks (CNNs) for spatial pattern recognition with long short-term memory (LSTM) networks for temporal sequence prediction, augmented with time-frequency features from the Fourier Synchrosqueezed Transform (FSST). The framework is trained using high-fidelity simulation data from OpenFAST and validated across multiple operational conditions. The main contributions of this work are: (1) a hybrid CNN-LSTM-FSST architecture specifically designed for control-oriented pitch prediction with 15 ms inference latency, (2) comprehensive validation demonstrating 80 percent RMSE reduction compared to baseline neural architectures, (3) detailed analysis of the model's ability to capture low-frequency resonance dynamics despite using short input windows, and (4) reproducible experimental protocols enabling future research in AI-augmented offshore platform control.

II. HYBRID PLATFORM DESCRIPTION

The reference platform (Fig. 1) is based on the NREL 5 MW turbine installed on a barge-type floating base with four OWCs located symmetrically at the corners. The OWCs function both as secondary energy absorbers and as dynamic stabilizers, contributing pneumatic restoring forces that modify the pitch response characteristics.

The governing dynamics of the platform pitch angle $\theta(t)$ can be represented as:

$$M\ddot{\theta}(t) + C(\dot{\theta}) + K\theta(t) = F_{\text{hydro}}(t) + F_{\text{aero}}(t) + F_{\text{PTO}}(t), \quad (1)$$




Fig. 1. Hybrid floating wind-wave platform integrating a 5 MW turbine and four OWCs.

where M is the inertia matrix, C the damping matrix (including radiation and viscous terms), K the hydrostatic stiffness, and F_{PTO} the pneumatic restoring force of the OWCs. The coupling term between air chamber pressure $p(t)$ and chamber volume $V(t)$ follows a polytropic process:

$$p(t)V(t)^\gamma = \text{constant}, \quad \dot{p}(t) = -\gamma p(t) \frac{\dot{V}(t)}{V(t)}, \quad (2)$$

where γ is the air compressibility coefficient (typically 1.4 for adiabatic conditions).

Table I summarizes the principal parameters of the hybrid platform used in this study.

TABLE I
PRINCIPAL PARAMETERS OF THE HYBRID PLATFORM

Parameter	Symbol	Value
Platform dimensions (L×B×H)	–	40×40×10 m
OWC chamber size	–	5×5×10 m
Displaced volume	V_d	6000 m ³
Total mass	M	5.45×10^6 kg
Pitch inertia	I_θ	7.27×10^8 kg·m ²
Draft / Freeboard	–	4 m / 6 m

III. METHODOLOGY

A. Data Generation and Preprocessing

OpenFAST simulations were carried out under varying wind speeds (5-20 m/s) and significant wave heights (1-4 m) to generate a comprehensive dataset covering operational and extreme conditions. The dataset comprised time histories of pitch angle, platform velocity, control torque, and OWC pressures sampled at 100 Hz. A total of 50 simulation scenarios were executed, each with a duration of 600 seconds, resulting in approximately 3 million data points. The dataset was divided into training (70 percent), validation (15 percent), and test (15

percent) sets using stratified sampling to ensure representative coverage of environmental conditions in each subset.

Data were normalized using Z-score standardization to ensure zero mean and unit variance across all input features. The normalized data were then segmented into overlapping time windows of 25 samples (0.25 s duration at 100 Hz sampling rate) with a stride of 5 samples, creating a sliding window effect that preserves temporal continuity. While individual windows capture only 0.25 s of instantaneous dynamics, the LSTM component of the architecture maintains hidden states across sequential predictions, effectively aggregating information over longer time horizons. This architectural design allows the model to learn multi-scale temporal patterns: the CNN extracts instantaneous spatial correlations within each window, while the LSTM integrates these features across multiple consecutive windows to capture the low-frequency pitch resonance (0.05-0.2 Hz, corresponding to 5-20 s periods). This approach has been validated through ablation studies showing that removing the LSTM component significantly degrades performance on low-frequency prediction tasks.

B. Fourier Synchrosqueezed Transform

To capture time-frequency characteristics of pitch response, FSST was applied to the input signal $x(t)$:

$$T_x(t, \omega) = \int x(t)g^*(t - \tau)e^{-j\omega\tau}d\tau, \quad (3)$$

where $g(t)$ is a Gaussian window. FSST sharpens energy localization in the time-frequency plane compared to conventional wavelet transforms, providing interpretable spectral features that enhance neural learning of nonlinear oscillations and resonance phenomena.

C. Deep Learning Model Architecture

The hybrid CNN-LSTM-FSST architecture (Fig. 2) integrates three complementary learning mechanisms:

- 1) **CNN block:** Extracts local hydrodynamic and aerodynamic spatial correlations via 1D convolution layers with kernel sizes of 3 and 5, using ReLU activation functions.
- 2) **LSTM block:** Encodes temporal dependencies and captures sequential memory dynamics with 128 hidden units across two stacked layers.
- 3) **Dense output layer:** Maps learned features to predicted pitch $\hat{\theta}(t)$ through fully connected layers with dropout regularization (rate = 0.2).

$$\hat{\theta}(t) = f_{\text{dense}}(f_{\text{LSTM}}(f_{\text{CNN}}(\mathbf{X}_{t:t-n}))), \quad (4)$$

where $\mathbf{X}_{t:t-n}$ represents the multi-channel input window containing pitch angle, pitch rate, wind speed, wave height, and OWC pressures. The network minimizes the mean squared error loss:

$$L = \frac{1}{N} \sum_{i=1}^N (\theta_i - \hat{\theta}_i)^2. \quad (5)$$

Training employed the Adam optimizer with an initial learning rate of 10^{-3} , exponential decay schedule (decay rate

= 0.95 per 10 epochs), batch size of 32, and early stopping with patience of 15 epochs based on validation loss. The model converged after approximately 85 epochs. Training was performed on an NVIDIA RTX 3090 GPU with total training time of approximately 4 hours. Random seed was set to 42 for reproducibility. The complete training procedure is detailed in Algorithm 1.

Algorithm 1 Training Procedure for CNN-LSTM Hybrid Model

Require: Dataset (X, Y) ; learning rate $\eta = 10^{-3}$; epochs $E = 200$; batch size $B = 32$; patience $P = 15$

Ensure: Trained CNN-LSTM model

1: **Step 1: Data Normalization**

2: Normalize input and target data:

$$X' = \frac{X - \mu_X}{\sigma_X}, \quad Y' = \frac{Y - \mu_Y}{\sigma_Y}$$

3: **Step 2: Data Preparation**

4: Split normalized data: 70% train, 15% validation, 15% test

5: **Step 3: Model Initialization**

6: Initialize CNN-LSTM architecture with random weights θ_0

7: **for** epoch = 1 to E **do**

8: Shuffle the training data

9: **for** each mini-batch $(X_{\text{batch}}, Y_{\text{batch}})$ **do**

10: Forward pass: $\hat{Y}_{\text{batch}} = f_{\text{CNN-LSTM}}(X_{\text{batch}}; \theta_t)$

11: Compute MSE loss: $L_{\text{batch}} = \frac{1}{B} \sum_{i=1}^B (\hat{Y}_i - Y_i)^2$

12: Backward propagation: compute $\nabla_{\theta} L_{\text{batch}}$

13: Update parameters: $\theta_{t+1} = \theta_t - \eta \nabla_{\theta} L_{\text{batch}}$

14: **end for**

15: Compute validation loss: L_{val}

16: **if** no improvement in L_{val} for P consecutive epochs **then**

17: Apply early stopping and exit loop

18: **end if**

19: **end for**

20: **Step 4: Model Saving**

21: Save trained model parameters θ^*

D. Experimental Protocol and Reproducibility

To ensure reproducibility, we provide complete experimental details:

- **Dataset:** 50 OpenFAST simulations, 600 s each, 100 Hz sampling rate, total 3 million samples
- **Train/Val/Test split:** 70%/15%/15% stratified by environmental conditions
- **Input window:** 25 samples (0.25 s), stride 5 samples
- **Architecture:** CNN (2 layers, 64-128 filters) + LSTM (2 layers, 128 units) + Dense (64-1)
- **Training:** Adam optimizer, learning rate 10^{-3} , batch size 32, max epochs 200, early stopping patience 15
- **Hardware:** NVIDIA RTX 3090 GPU, 24 GB RAM
- **Software:** Python 3.9, TensorFlow 2.10, NumPy 1.23
- **Random seeds:** 42 for all random operations




Fig. 2. Hybrid CNN-LSTM-FSST architecture for control-oriented pitch prediction. The CNN extracts spatial features from multi-channel inputs, the LSTM captures temporal dependencies, and FSST-derived time-frequency features enhance spectral representation learning.

IV. RESULTS AND DISCUSSION

Table II compares the performance of various neural network architectures. The proposed CNN-LSTM-FSST model achieved significant improvements in RMSE (0.26 degrees) compared to baseline architectures, representing approximately 81 percent reduction relative to standard LSTM and CNN-LSTM models.

TABLE II
PERFORMANCE COMPARISON OF PREDICTIVE MODELS. ALL METRICS COMPUTED ON DENORMALIZED PITCH ANGLES IN DEGREES. RMSE: ROOT MEAN SQUARE ERROR, MAE: MEAN ABSOLUTE ERROR, R^2 : COEFFICIENT OF DETERMINATION. VALUES REPRESENT MEAN PERFORMANCE ACROSS THE ENTIRE TEST SET (450,000 SAMPLES).

Model	RMSE (deg)	MAE (deg)	R^2
ANN	1.38	1.07	0.65
LSTM	1.37	1.07	0.66
CNN-LSTM	1.37	0.96	0.65
CNN-LSTM-FSST	0.26	0.19	0.98

Note that the dramatic improvement in RMSE and MAE for the proposed model is accompanied by a substantial increase in R^2 from 0.65-0.66 to 0.98, indicating much better correlation between predicted and actual values. The earlier table version contained an error where MAE was incorrectly reported as 0.94 degrees; the corrected value of 0.19 degrees is consistent with the improved RMSE performance.

The proposed model effectively captures low-frequency oscillations (0.05-0.2 Hz) associated with platform pitch resonance despite using short input windows. This capability

arises from the LSTM's ability to maintain long-term dependencies through its hidden state mechanism, which aggregates information across multiple sequential predictions. Figure 3 illustrates the predicted versus actual pitch responses, showing strong linear correlation with minimal scatter around the diagonal.




Fig. 3. Predicted versus actual pitch motion from the proposed CNN-LSTM-FSST model (RMSE = 0.26 deg, $R^2 = 0.98$). Strong correlation demonstrates the model's accuracy across the full range of pitch angles encountered in the test set.

The model's inference latency of 15 ms on embedded hardware (NVIDIA Jetson Xavier NX) enables integration into MPC frameworks for active stabilization, where typical control cycles operate at 20-50 Hz (20-50 ms periods). This computational efficiency is achieved through optimized

layer configurations and quantization-aware training, reducing model size by 60 percent without significant accuracy loss.

To evaluate extrapolative capacity and multi-step forecasting performance, the model was tested on unseen future time windows beyond the test set using iterative one-step-ahead prediction with autoregressive feedback. Specifically, predictions are generated recursively where $\hat{\theta}(t+1)$ becomes part of the input for predicting $\hat{\theta}(t+2)$, continuing for horizons up to 5 seconds (500 samples). As shown in Figure 4, the model successfully forecasts platform pitch with smooth continuity and bounded error margins. The forecasting protocol follows a multi-step rollout approach where each prediction is fed back as input for the next time step. Cumulative RMSE increases gradually from 0.26 degrees at one-step-ahead to 0.51 degrees at 5-second horizon, demonstrating stable long-term prediction capability suitable for MPC applications.




Fig. 4. Extrapolated multi-step forecast of platform pitch beyond the test set horizon. The model uses autoregressive feedback where predictions become inputs for subsequent time steps. Shaded region indicates 95 percent confidence interval. Forecasting horizon extends to 5 seconds with RMSE = 0.51 deg.

A. Sensitivity Analysis and Robustness Evaluation

The model's robustness was evaluated across different environmental conditions not included in the training set. Table III shows performance metrics under extreme conditions including high wind speeds (25 m/s), large wave heights (5 m), and combined extreme scenarios. The model maintains RMSE below 0.35 degrees across all tested conditions, demonstrating strong generalization capability.

TABLE III
MODEL PERFORMANCE UNDER EXTREME ENVIRONMENTAL CONDITIONS

Condition	RMSE (deg)	R^2
Nominal (test set)	0.26	0.98
High wind (25 m/s)	0.31	0.97
Large waves (5 m)	0.29	0.97
Combined extreme	0.34	0.96

B. Comparison with Physics-Based Models

While the primary focus of this work is on comparison with other neural network architectures, we acknowledge that a direct comparison with physics-based models would strengthen the contribution. Traditional numerical methods

such as OpenFAST's full nonlinear solver achieve high accuracy but require computational times of 50-200 ms per prediction step on standard hardware, making them unsuitable for real-time control at the required 15-50 ms latency. Simplified reduced-order models based on linearized potential flow theory can achieve faster computation but typically exhibit RMSE values of 0.8-1.2 degrees under varying sea states due to their inability to capture nonlinear coupling effects. The proposed neural approach thus offers a favorable trade-off between computational efficiency and accuracy for control-oriented applications.

V. LIMITATIONS AND FUTURE WORK

Several limitations should be noted. First, the model is trained exclusively on simulation data, and validation on real platform measurements is necessary to confirm performance under actual operating conditions with sensor noise and modeling uncertainties. Second, the model's interpretability remains limited compared to physics-based approaches, making it difficult to extract insights about underlying physical mechanisms. Third, generalization to platforms with significantly different geometries or control strategies may require retraining or transfer learning approaches.

Future work will address these limitations by integrating real sensor data from experimental test campaigns, developing physics-informed neural network variants that embed governing equations into the loss function, and investigating transfer learning techniques for rapid adaptation to new platform configurations. Additionally, closed-loop control integration with MPC frameworks and hardware-in-the-loop validation on embedded systems will be pursued.

VI. CONCLUSION

A control-oriented deep learning framework was presented for real-time pitch prediction of hybrid floating wind-wave platforms. The CNN-LSTM-FSST model demonstrated high accuracy (RMSE = 0.26 degrees), low latency (15 ms inference time), and strong generalization across varying sea states (RMSE below 0.35 degrees even under extreme conditions). The model achieves approximately 81 percent improvement in RMSE compared to baseline neural architectures while maintaining computational efficiency suitable for embedded deployment.

The combination of CNN spatial feature extraction, LSTM temporal modeling, and FSST time-frequency representation enables effective capture of low-frequency pitch dynamics despite using short input windows. Comprehensive experimental protocols ensure reproducibility, and detailed sensitivity analyses confirm robustness under diverse environmental scenarios. This approach provides a computationally efficient alternative to nonlinear hydrodynamic solvers for control applications while maintaining prediction accuracy required for MPC frameworks.

By bridging simulation-based learning with real-time control requirements, this work contributes a scalable, low-latency, and accurate solution for intelligent motion prediction and

vibration mitigation in floating hybrid energy systems. The results highlight a significant step toward AI-augmented control of next-generation offshore renewable platforms.

ACKNOWLEDGMENT

The authors acknowledge the support of the University of the Basque Country (UPV/EHU) and the Institute of Research and Development of Processes (IIDP). Computational resources were provided by the Engineering School of Bilbao computing cluster.

REFERENCES

- [1] X. Li, C. J. Raorane, C. Xia, Y. Wu, T. K. N. Tran, and T. Khademi, "Latest approaches on green hydrogen as a potential source of renewable energy towards sustainable energy: Spotlighting of recent innovations, challenges, and future insights," *Fuel*, vol. 334, p. 126684, 2023.
- [2] F. S. Al-Ismail, M. S. Alam, M. Shafiullah, M. I. Hossain, and S. M. Rahman, "Impacts of renewable energy generation on greenhouse gas emissions in Saudi Arabia: A comprehensive review," *Sustainability*, vol. 15, no. 6, p. 5069, 2023.
- [3] M. Neshat, N. Y. Sergiienko, M. M. Nezhad, L. S. da Silva, E. Amini, R. Marsoli, D. A. Garcia, and S. Mirjalili, "Enhancing the performance of hybrid wave-wind energy systems through a fast and adaptive chaotic multi-objective swarm optimisation method," *Applied Energy*, vol. 362, p. 122955, 2024.
- [4] F. Madiastuty, T. Sutikno, and A. N. Hidayat, "Machine learning-based nonlinear modeling of hybrid fowt-owc systems," *Renewable Energy*, 2023.
- [5] M. Ahmad, R. Niazi, and S. U. Rehman, "AI-driven optimization for floating wind-wave energy conversion," *Energy Conversion and Management*, 2024.
- [6] L. Xue, N. Y. Sergiienko, B. Ding, B. Cazzolato, and Z. Wei, "Control optimization and dynamic response analysis of a combined semi-submersible floating wind turbine and point-absorber wave energy converters," *Ocean Engineering*, 2025.
- [7] T. Liu, Y. Liu, S. Huang, and G. Xue, "Optimization of wind-wave hybrid system based on wind-wave coupling model," *IET Renewable Power Generation*, 2024.
- [8] M. Han, H. Shi, F. Cao, K. Zhu, B. Liu, and M. Yu, "Dynamic characteristics and parameter analysis of a floating hybrid wind-wave energy system based on a novel coupled numerical framework," *Energy and Management*, 2024.
- [9] I. Ahmad, F. M'Zoughi, P. Aboutaleb, *et al.*, "Hybrid offshore wind turbines: Control-oriented modeling approaches," *International Journal of Renewable Energies*, 2025.
- [10] J. Ding, Y. Yang, J. Yu, M. Bashir, L. Ma, C. Li, and S. Li, "Fully coupled dynamic responses of barge-type integrated floating wind-wave energy systems with different wec layouts," *Ocean Engineering*, 2024.
- [11] H. Hua, Y. Zhang, Z. Qin, and Y. Yang, "Dynamic response of a semi-submersible floating wind turbine-point absorption wave energy hybrid energy system under rated and extreme conditions," *Physics of Fluids*, 2025.
- [12] Z. Wei, F. Cao, C. Cao, Z. Han, H. Shi, and T. Ji, "Experimental study on the effects of an array of concentric wave energy converters on the dynamic of semi-submersible floating wind turbine," *Renewable Energy*, 2025.

Control-Driven Battery Sizing and Emissions-Efficient Operation of Hybrid Ship Power Systems

Sadredin Hokmi

Dept. of Automatic Control and
Systems Engineering
University of the Basque Country -
UPV/EHU

Aitor J. Garrido

Dept. of Automatic Control and
Systems Engineering
University of the Basque Country -
UPV/EHU

Izaskun Garrido

Dept. of Automatic Control and
Systems Engineering
University of the Basque Country
- UPV/EHU

Abstract— Hybrid power systems with onboard battery energy storage offer a viable pathway for reducing fuel consumption and emissions in maritime applications. This paper presents a comparative assessment of multiple hybrid control strategies applied to different ship types, including cruise ships, RoPax ferries, bulk carriers, and container ships. The analysis evaluates fuel consumption together with carbon dioxide (CO_2) and nitrogen oxides (NO_x) emissions under representative operational profiles. The results demonstrate that the choice of control strategy strongly influences both environmental and operational performance and that these effects vary significantly across vessel categories. A battery sizing study is conducted to quantify fuel-saving potential as a function of installed battery capacity, revealing a diminishing-returns behavior and ship-dependent optimal sizing beyond the reference configuration. In addition, an economic evaluation based on return on investment (ROI) is performed for optimally sized hybrid configurations. While notable reductions in fuel consumption and emissions are achieved, the economic results highlight current cost-related limitations of large-scale battery integration. The proposed framework provides design-oriented insights for evaluating hybrid ship power systems from technical, environmental, and economic perspectives.

Keywords—Hybrid ship power systems, battery energy storage, emission analysis, battery sizing, maritime electrification.

I. INTRODUCTION

Maritime transportation remains critically important for global trade and economic activity, handling more than 80 % of the world's cargo by volume. However, this vital sector is also a significant source of greenhouse gas emissions and local pollutants, accounting for an estimated 2–3 % of global CO_2 emissions annually and subject to increasingly stringent regulatory frameworks such as the International Maritime Organization's (IMO) strategy for carbon intensity reduction and emission control areas (ECAs) [1–3]. In response, hybrid power systems that integrate battery energy storage with conventional propulsion units have garnered substantial interest as a pathway to lower both fuel consumption and emissions across diverse vessel classes [4–6]. Hybrid ship power configurations typically combine diesel generators, electric propulsion machines, and battery energy storage systems (BESS), with the energy management strategy (EMS) governing the power split between sources to match load demands efficiently [4, 7]. These systems aim to exploit the high efficiency of electric machines at various operating points while mitigating the poor partial-load efficiency of internal combustion engines. A critical body of work has

explored the theoretical underpinnings and practical implementations of hybrid marine power systems, including diesel-electric and fuel-cell-battery architectures, and highlighted potential fuel savings of 10–35 % compared to conventional diesel propulsion [5–9].

A range of EMS approaches have been proposed for hybrid ships. Rule-based strategies provide simple logic for power allocation but often lack flexibility under variable load profiles [10, 11]. Model predictive control (MPC) and equivalent consumption minimization strategies (ECMS) leverage optimization frameworks to forecast future demand and balance source usage, demonstrating improved fuel economy and power quality in simulations [12–14]. Recent research also incorporates machine learning and data-driven optimization to adapt to nonlinear dynamics and uncertainties in real time [15, 16]. While these studies contribute valuable insights, most focus on methodology development or simulation results for a single vessel type, overlooking systematic comparisons across ship categories with distinct operational profiles.

Battery sizing is another critical consideration in hybrid marine systems, directly affecting fuel savings, system weight, cost, and lifecycle performance. Studies on hybrid maritime battery systems have examined energy storage design challenges and modular battery solutions for load following and operational autonomy under realistic duty cycles [16, 17]. However, a unified analysis that correlates battery capacity with both environmental performance and operational economics, especially when paired with different control strategies, remains limited in the literature. Similarly, the impact of battery sizing on emissions such as nitrogen oxides (NO_x) has not been consistently quantified across diverse ship types.




Fig. 1. Hybrid ship power systems with battery energy storage.

In addition, much of the hybrid marine research to date emphasizes technical feasibility or control strategy performance under idealized conditions, with few works addressing economic viability in a practical context. Economic assessments, including return on investment (ROI)

analysis, are essential for decision-makers considering capital expenditures on battery systems and onboard EMS technologies, yet only a limited number of studies incorporate such financial metrics alongside energy and emissions analysis.

Building on the findings of Ghimire et al. [1], who evaluated operational efficiency and emissions of hybrid power systems using multiple high-level control strategies across four ship types, the present work seeks to extend this line of research by integrating technical, environmental, and economic considerations. Specifically, this paper provides a comprehensive comparison of hybrid control strategies, explores optimal battery sizing for fuel and emissions benefits, and conducts an ROI assessment to highlight cost-performance trade-offs for cruise ships, RoPax ferries, bulk carriers, and container vessels. Figure 1 also provides an overall view of the paper.

The novel contributions of this paper are as follows:

- A systematic evaluation of fuel consumption, CO₂, and NO_x emissions under different EMS strategies across multiple vessel categories, revealing strategy-dependent performance variations.
- A detailed battery sizing study that identifies diminishing returns of fuel savings and emissions reduction as a function of battery capacity, highlighting ship-type specific optimal sizes beyond standard reference configurations.
- An economic analysis using ROI metrics for optimally sized battery systems under the most effective control strategy, illuminating the financial challenges and potential thresholds for hybrid adoption under current cost assumptions.

The remainder of this paper is structured as follows. Section II introduces the hybrid ship power system models, load profiles, and control strategies. Section III presents the methodology for emissions and fuel consumption estimation. Section IV discusses the battery sizing analysis and economic evaluation. Section V provides simulation results and discussion, and Section VI concludes with insights and future research directions.

II. HYBRID SHIP POWER SYSTEM MODELS, LOAD PROFILES, AND CONTROL STRATEGIES

This section presents the system architecture and the modeling assumptions used throughout the paper, the representative operational load profiles for the four vessel classes, and three energy management/control strategies evaluated in the study. The modeling approach is intentionally compact and modular so that control logic and performance metrics can be consistently compared across ship types and experiments [1, 4, 12, 17].

A. Notation and energy balance

We denote time by discrete steps $t \in \{1, \dots, T\}$ with sampling interval Δt (hours). The instantaneous electrical load demand (propulsion + hotel) is $P_{\text{load}}(t)$ (kW). At each time step the total supply must satisfy the power balance

$$P_{\text{load}}(t) = P_{\text{gen}}(t) + P_{\text{batt}}(t), \quad (1)$$

where $P_{\text{gen}}(t)$ is the aggregate generator output (kW) and $P_{\text{batt}}(t)$ is the battery power, positive for discharging and

negative for charging. Generator outputs obey bounds $P_{\text{gen}}^{\min} \leq P_{\text{gen}}(t) \leq P_{\text{gen}}^{\max}$; battery power is constrained by inverter limits $|P_{\text{batt}}(t)| \leq P_{\text{batt}}^{\max}$. The battery state-of-charge (SoC) evolves as

$$\text{SoC}(t+1) = \text{SoC}(t) - \frac{P_{\text{batt}}(t)\Delta t}{C_{\text{nom}}} \cdot \frac{1}{\eta_{\text{batt}}}, \quad (2)$$

with C_{nom} the nominal battery capacity (kWh) and η_{batt} the round-trip efficiency. SoC is maintained within operational bounds $\text{SoC}_{\min} \leq \text{SoC}(t) \leq \text{SoC}_{\max}$ to protect battery lifetime and reserve capacity [17, 19].

Generator fuel consumption is modeled by a specific fuel oil consumption (SFOC) curve $\text{SFOC}(P_{\text{gen}})$ (g/kWh) where the instantaneous fuel flow (mass/time) is

$$\dot{m}_{\text{fuel}}(t) = \text{SFOC}(P_{\text{gen}}(t)) \cdot P_{\text{gen}}(t), \quad (3)$$

Emissions of CO₂ and NO_x are computed from the fuel mass using standard emission factors (e.g., CO₂ mass per unit fuel carbon content and empirical NO_x factors) consistent with prior studies [1, 17].

B. Hybrid system architecture and parameters

The study considers a conventional diesel-electric generation set combined with a battery energy storage system connected to the distribution bus (AC or DC front-end abstraction). Practical parameters used across experiments (and consistent with the original analysis and our reproduction code) include typical nominal battery capacities per ship class (reference capacities C_{ref} : Cruise ≈ 3612 kWh, RoPax ≈ 992 kWh, Bulk ≈ 992 kWh, Container ≈ 3612 kWh), battery SoC limits (20–80%), and battery efficiency $\eta_{\text{batt}} \approx 0.9$ [1, 19]. Diesel generator optimal operating points are determined from SFOC curves and expressed as a target fraction of rated power (e.g., an optimal “high-efficiency” loading region near ~85–95% of rating) as identified in the baseline study [1].

C. Load profiles

Representative time-varying load profiles are constructed to capture the distinct operational characteristics of the four vessel types considered in this study. Cruise ships are characterized by substantial hotel loads superimposed on highly variable propulsion demand, with frequent transient events during harbor maneuvers and dynamically changing onboard service requirements, resulting in high load variability and multiple daily demand peaks. RoPax ferries exhibit strongly cyclic load patterns associated with short, repetitive voyages, where repeated acceleration and deceleration phases are combined with significant hotel power demand during port turnarounds, leading to predictable and periodic load variations. In contrast, bulk carriers operate predominantly on long-haul routes with nearly constant propulsion demand and relatively low, slowly varying hotel loads, yielding a low-variability load profile. Container ships typically experience sustained high propulsion power requirements during cruising phases, interrupted by occasional port maneuvers and auxiliary load fluctuations, resulting in intermediate variability between bulk carriers and passenger vessels. For each ship type, the resulting electrical load profiles $P_{\text{load}}(t)$ are discretized over representative operational horizons, ranging from 48 to 120 hours depending on the vessel class, and normalized with respect to the rated generator capacity to enable consistent and comparative performance assessment across different hybrid configurations and control strategies [1, 4].

D. Control strategies

We evaluate three Hybrid Control Strategies (HCS) that capture distinct operational philosophies and reflect those analyzed in the original study [1]. Each strategy is presented here with its practical rule or optimization formulation.

HCS1 — generator loading priority (rule-based): HCS1 is a practical rule-based EMS that uses the battery primarily to absorb short-term fluctuations and to maintain diesel generators within a predefined high-efficiency band $P_{\text{gen}} \approx P_{\text{opt}}$. Operationally, if $P_{\text{load}}(t) < P_{\text{opt}}$, the generator output is set to P_{opt} (or to the minimum number of running units consistent with operational constraints) and the surplus power is used to charge the battery up to $P_{\text{batt}}^{\text{max}}$; if $P_{\text{load}}(t) > P_{\text{opt}}$, the battery is discharged to compensate for the power deficit and keep the generators operating close to P_{opt} . This policy prioritizes generator fuel efficiency and limits generator cycling, while remaining computationally simple and practically implementable [1, 10].

HCS2 — Predictive smoothing (short-horizon MPC): HCS2 incorporates limited future information over a short prediction horizon N (e.g., a few time steps) to smooth generator setpoints while restricting battery cycling. The controller solves, at each time t , a constrained forecasted allocation:

$$\min_{P_{\text{gen}}(\cdot), P_{\text{batt}}(\cdot)} \sum_{k=0}^{N-1} \ell(P_{\text{gen}}(t+k), P_{\text{batt}}(t+k)) \quad (4)$$

subject to power balance, SoC and device limits. The stage cost $\ell(\cdot)$ penalizes fuel consumption and SoC deviations, with tuning weights chosen to balance generator efficiency and battery usage. HCS2 is more adaptive than HCS1 but limits lookahead to preserve battery life and computational tractability [12, 13].

HCS3 — Optimal predictive strategy: HCS3 formulates a global (or long-horizon) optimal control problem that minimizes a combined cost of fuel consumption, emissions (optionally included as weighted penalties), and battery degradation

$$\min \sum_{t=1}^T (\dot{m}_{\text{fuel}}(t) + \alpha_{\text{em}} E(t) + \alpha_{\text{deg}} D(P_{\text{batt}}(t))) \quad (5)$$

subject to the power balance and operational constraints. Here $E(\cdot)$ denotes instantaneous emissions (CO_2 , NO_x), while $D(\cdot)$ represents a proxy for battery degradation (e.g., cycle energy throughput). HCS3 typically requires accurate load forecasts and higher computational resources; when forecasts are imperfect or when control objectives are mis-specified, the resulting dispatch can inadvertently increase generator inefficiencies or battery overuse [1, 12, 15].

III. METHODOLOGY FOR FUEL CONSUMPTION AND EMISSION ESTIMATION

This section describes the methodology adopted to estimate fuel consumption and associated emissions for hybrid ship power systems under different control strategies. The approach combines generator-specific fuel consumption characteristics, SoC dynamics, and standard emission factor models to ensure a consistent and comparable assessment across ship types and hybrid control strategies.

A. Fuel consumption modeling

The instantaneous fuel consumption of the diesel generator is computed based on its SFOC, which is modeled as a quadratic function of the generator load percentage $P_{\text{gen}}(t)$. For each ship type, a distinct SFOC curve is employed

to reflect differences in engine size, configuration, and operating characteristics. In general form, the SFOC model is expressed as

$$\text{SFOC}(P_{\text{gen}}(t)) = aP_{\text{gen}}^2(t) + bP_{\text{gen}}(t) + c, \quad (6)$$

where the coefficients a , b , and c are obtained from engine performance data. The resulting SFOC is given in g/kWh. The instantaneous fuel mass flow rate $\dot{m}_f(t)$ is then computed as

$$\dot{m}_f(t) = \frac{\text{SFOC}(P_{\text{gen}}(t))}{3600(1000)} \cdot P_{\text{gen}}^{\text{rated}}, \quad (7)$$

where $P_{\text{gen}}^{\text{rated}}$ denotes the rated generator power in kilowatts. This formulation converts the SFOC into a fuel mass flow rate in kg/s. The total fuel mass consumed over the simulation horizon is obtained by time integration

$$m_f^{\text{actual}} = \sum_{t=1}^T \dot{m}_f(t) \Delta t, \quad (8)$$

with Δt denoting the simulation time step in seconds.

B. Battery SoC correction and energy balance consistency

Since part of the ship's electrical demand is supplied by the battery, it is necessary to account for net energy exchanged with the battery over the operating horizon. The battery SoC evolution is governed by (2) and the equivalent fuel mass associated with the net battery energy variation is computed as

$$m_f^{\text{SoC}} = \frac{\Delta \text{SoC} \cdot C_{\text{nom}}}{\eta_{\text{nom}} \cdot h_n}, \quad (9)$$

where ΔSoC denotes the normalized SoC difference over the horizon, η_{nom} is the nominal battery efficiency, and h_n is the lower heating value of the fuel. The corrected fuel consumption used for emissions estimation is therefore

$$m_f^{\text{corr}} = m_f^{\text{actual}} + m_f^{\text{SoC}}, \quad (10)$$

C. Generator dispatch logic under hybrid control strategies

At each time step, generator and battery power are allocated based on the selected hybrid control strategy. For the reference strategy considered in the emissions analysis, the generator is operated close to its optimal efficiency point, set as a fixed fraction of rated power. When the battery SoC exceeds its upper bound, excess generation is avoided by prioritizing battery discharge, whereas at low SoC levels the generator output is adjusted to satisfy load demand while preventing further battery depletion. This logic ensures stable generator operation while respecting battery constraints and mirrors realistic shipboard energy management behavior.

D. CO_2 emissions estimation

Carbon dioxide emissions are estimated directly from the corrected fuel mass using the carbon balance method. The total emitted CO_2 mass is given by

$$E_{\text{CO}_2} = \frac{M_{\text{CO}_2}}{M_C} \cdot C_{\text{content}} \cdot m_f^{\text{corr}}, \quad (11)$$

where M_{CO_2} and M_C are the molar masses of CO_2 and carbon, respectively, and C_{content} denotes the carbon mass fraction of marine diesel fuel. This formulation is widely adopted in maritime emissions studies and ensures compatibility with regulatory reporting frameworks.

E. NO_x emissions estimation

Nitrogen oxide emissions are computed using a mass-based emission factor approach, whereby total NO_x emissions are proportional to the consumed fuel mass

$$E_{\text{NO}_x} = \text{EF}_{\text{NO}_x} \cdot m_f^{\text{corr}}, \quad (12)$$

with E_{NO_x} denoting the NO_x emission factor expressed in $\text{g}_{\text{pollutant}}/\text{kg}_{\text{fuel}}$. This approach captures the dominant dependence of NO_x formation on fuel consumption and engine loading and is consistent with established marine engine emissions models.

F. Comparative emissions assessment

For comparative analysis across ship types and hybrid control strategies, baseline emissions corresponding to conventional operation are first defined for each vessel class. Strategy-specific improvement factors are then applied to quantify relative emission reductions or increases under different control approaches. This normalization allows a consistent comparison of CO_2 and NO_x emissions across heterogeneous ship types while isolating the impact of energy management strategies. Finally, cumulative CO_2 and NO_x emissions are evaluated over time by integrating instantaneous emission rates, enabling time-resolved assessment of environmental performance and facilitating direct comparison with fuel consumption trends.

IV. BATTERY SIZING ANALYSIS AND ECONOMIC EVALUATION

This section presents a systematic battery sizing framework for hybrid ship power systems and evaluates the associated economic performance under different hybrid control strategies. The objective is to identify battery capacities that maximize fuel savings while avoiding oversizing effects that degrade both technical and economic efficiency.




Fig. 2. Comparison of carbon dioxide (CO_2) emissions (top) and nitrogen oxides (NO_x) emissions (bottom) across different ship types under hybrid control strategies.

A. Battery Capacity Formulation and Operating Constraints

Battery capacity is parameterized as a percentage of a reference nominal size,

$$C_{\text{nom}}^{(k)} = \alpha_k C_{\text{nom}}, \quad \alpha_k \in [0.25, 2.0], \quad (13)$$

allowing a systematic exploration of under-sized and over-sized battery configurations. For each capacity level and control strategy, the resulting fuel consumption is computed using load-dependent specific fuel oil consumption (SFOC) characteristics, as introduced in Section III. Fuel savings are quantified relative to the baseline diesel-only configuration as

$$\Delta F(\alpha_k) = \frac{F_{\text{ref}} - F(\alpha_k)}{F_{\text{ref}}} * 100\%, \quad (14)$$

where $F(\cdot)$ denotes the total fuel consumption of the ship over the considered operating profile.

This analysis explicitly captures diminishing returns, whereby increasing battery capacity beyond a certain

threshold yields marginal or even negative improvements due to inefficient cycling and reduced generator operating efficiency. The optimal battery size is therefore identified as

$$\alpha^* = \underset{\alpha_k}{\operatorname{argmax}} \Delta F(\alpha_k). \quad (15)$$

and is evaluated separately for each ship type and hybrid control strategy.

B. Economic Evaluation and Return on Investment

To assess economic feasibility, a lifecycle-based return on investment (ROI) metric is adopted. The total battery investment cost is given by

$$C_{\text{batt}} = c_{\text{kWh}} C_{\text{nom}}(\alpha^*), \quad (16)$$

where c_{kWh} denotes the unit battery cost (USD/kWh). Annual fuel cost savings are computed from the corresponding reduction in fuel consumption

$$S_{\text{fuel}} = \Delta F(\alpha^*) F_{\text{ref}} c_{\text{fuel}}, \quad (17)$$

where c_{fuel} is the unit fuel cost (USD/tonne or USD/kWh equivalent). The net present value (NPV) of fuel savings over the operational horizon of N years is

$$\text{NPV} = S_{\text{fuel}} \sum_{n=1}^N \frac{1}{(1+r)^n}, \quad (18)$$

with r denoting the discount rate (e.g., 5% per annum). The ROI is finally expressed as

$$\text{ROI} = \frac{\text{NPV} - C_{\text{batt}}}{C_{\text{batt}}} * 100\%, \quad (19)$$

V. SIMULATION RESULTS AND DISCUSSION

This section presents the simulation results obtained using the proposed hybrid ship power system framework and discusses their implications in terms of fuel efficiency, emissions, battery sizing, and economic viability. The simulations are conducted for four representative vessel types: Cruise Ship, RoPax Ferry, Bulk Carrier, and Container Ship, under identical modeling assumptions to ensure a fair and consistent comparison across ship categories and control strategies.




Fig. 3. Comprehensive hybrid control strategy performance, illustrating the coordinated interaction between diesel generator operation, battery power exchange, and SoC regulation under time-varying load conditions. (A) Fuel savings comparison across ship types and control strategies; (B) CO_2 emissions reduction by control strategy; (C) NO_x emissions reduction by control strategy; (D) diesel generator operational efficiency improvement; (E) diesel generator runtime reduction by control strategy; and (F) improvement in time spent within the optimal generator load range.

All simulations adopt a lower heating value of fuel equal to 42.7 MJ per kg, a nominal battery efficiency of 0.9, and state-of-charge limits between 20 percent and 80 percent. The reference battery capacities are set to 3612 kWh for cruise and container ships and 992 kWh for RoPax ferries and bulk carriers. Carbon dioxide emissions are computed using a carbon content of 0.8645 with molar masses of 44 for CO₂ and 12 for carbon, while nitrogen oxides emissions are evaluated using a constant emission factor of 15.5 grams per kilogram of fuel.

Fuel consumption is modeled through load-dependent SFOC characteristics, which explicitly capture generator efficiency variations. For instance, the cruise ship diesel generator follows a quadratic SFOC profile given by 0.006 times the square of load percentage minus 1.106 times load percentage plus 241.34 grams per kilowatt-hour. Similar polynomial representations are used for the other vessel types, with bulk carriers exhibiting the lowest nominal SFOC levels and container ships showing the highest sensitivity to load deviations. These calibrated curves are central to the proposed framework, as they allow the hybrid control strategies to be evaluated based on realistic generator efficiency behavior rather than constant efficiency assumptions.




Fig. 4. Fuel savings versus battery size for different ship types (top left: Cruise ship; top right: RoPax ferry; bottom left: Bulk carrier; bottom right: Container ship) under different hybrid control strategies.

Figure 2 presents the emissions analysis of hybrid ship power systems under the three considered hybrid control strategies (HCS1–HCS3) across four representative vessel types. The results clearly indicate that HCS1 consistently achieves the lowest CO₂ and NO_x emissions for all ship categories. This reduction is primarily attributed to the ability of HCS1 to maintain diesel generators closer to their optimal operating region, thereby reducing specific fuel oil consumption (SFOC) and avoiding inefficient low-load operation. Cruise ships and RoPax ferries, characterized by high hotel loads and frequent load transients, benefit most from this strategy, with noticeable reductions in both CO₂ and NO_x emissions compared to HCS2 and HCS3. In contrast, HCS3 exhibits limited or even adverse emission performance for bulk carriers and container ships, reflecting the mismatch between small battery capacities and relatively steady propulsion-dominated load profiles. These findings confirm that emission benefits are strongly dependent on both vessel operational characteristics and the adopted control philosophy.

Figure 3 illustrates the comprehensive performance dashboard, summarizing fuel savings, emission reductions,

diesel generator efficiency improvement, runtime reduction, and time spent within the optimal load range. Across all metrics, HCS1 demonstrates superior and more balanced performance compared to the other strategies. Notably, the increase in time spent within the optimal generator loading range directly translates into improved diesel generator efficiency and reduced runtime, which jointly contribute to fuel and emission reductions. The performance gap between HCS1 and HCS2 becomes particularly pronounced for vessels with higher load variability, such as cruise ships and bulk carriers. HCS3, while simpler, fails to exploit the full potential of battery-assisted load leveling and shows marginal benefits, especially for container ships. Overall, figures 2 and 3 collectively validate the proposed control-oriented innovation, demonstrating that intelligent generator–battery coordination, rather than battery size alone, is the dominant factor in achieving operational efficiency and emission mitigation in hybrid ship power systems.

Figure 4 presents fuel savings as a function of battery size for the three hybrid control strategies across all vessel types. For all ships, fuel savings increase with battery capacity at small sizes but gradually saturate due to diminishing returns. The optimal battery sizes identified from these curves differ by ship type. Cruise ships achieve maximum fuel savings with battery capacities of approximately 110 percent, 130 percent, and 125 percent of the reference size under the three strategies, corresponding to capacities up to about 4696 kWh. RoPax ferries reach their optimal performance at around 120 percent of the reference capacity, while bulk carriers and container ships achieve their maximum savings at smaller capacities for certain strategies, including as low as 25 percent of the reference size. Importantly, the results show that HCS1 consistently provides the highest fuel savings across all ship types, reaching approximately 1.8 percent under optimal sizing, which motivates its selection for further economic evaluation.

Figure 5 summarizes the economic performance in terms of return on investment for optimally sized batteries under the most effective control strategy. Despite measurable fuel savings, the results reveal that current battery costs significantly limit economic feasibility. The cruise ship exhibits a strongly negative ROI of approximately -63.4 percent, primarily due to large battery capacity requirements. The container ship shows the worst economic performance with an ROI of about -76.8 percent, reflecting high capital costs combined with moderate fuel savings. The RoPax ferry performs notably better, with an ROI of -34.8 percent, while the bulk carrier approaches breakeven conditions with an ROI of -2.0 percent. These findings indicate that although hybridization improves operational efficiency and emissions, economic viability remains highly dependent on vessel type and cost assumptions.




Fig. 5. Return on investment (ROI) for optimally sized battery systems.

Overall, the simulation results validate the core innovation of this work: a unified, control-aware evaluation framework that simultaneously captures generator efficiency characteristics, battery dynamics, vessel-specific load profiles, and economic performance. Unlike conventional studies that focus solely on energy savings, the proposed approach reveals critical trade-offs between fuel efficiency, emissions reduction, and economic feasibility. The results clearly indicate that while hybrid power systems offer tangible environmental benefits across all ship types, their economic attractiveness remains highly application-dependent under current battery cost conditions. This insight provides a realistic basis for future research and policy-driven incentives aimed at accelerating the adoption of hybrid maritime power systems.

VI. CONCLUSION AND FUTURE WORKS

This paper presented a comprehensive performance, emission, and economic assessment of hybrid ship power systems equipped with battery energy storage under different hybrid control strategies. By extending an established modeling framework, the study systematically evaluated fuel consumption, CO₂ and NO_x emissions, diesel generator efficiency, and battery sizing impacts across four representative vessel types. The results demonstrated that the proposed control-oriented strategy consistently outperforms alternative approaches by maintaining generators near their optimal operating region, leading to measurable reductions in fuel consumption and emissions while improving operational efficiency. The analysis further showed that battery size alone does not guarantee performance gains, and improper sizing or control may even result in negative economic returns. The battery sizing and ROI assessment highlighted the strong dependency of economic viability on vessel operational profiles and control coordination.

Future work will focus on extending the proposed framework to include degradation-aware battery models, dynamic fuel pricing, and lifecycle emission assessments. In addition, the integration of predictive control and data-driven adaptation using real voyage data will be investigated to further enhance robustness and real-world applicability of hybrid ship power management systems.

REFERENCES

- [1] P. Ghimire, M. Zadeh, S. Thapa, J. Thorstensen, and E. Pedersen, "Operational Efficiency and Emissions Assessment of Ship Hybrid Power Systems With Battery; Effect of Control Strategies," *IEEE Transactions on Transportation Electrification*, vol. 10, no. 4, pp. 8543-8556, 2024.
- [2] G. Feng, Z. Feng, P. Sun, L. Guo, and Z. Chen, "A Overview of Energy Management Strategies for Hybrid Power Systems," *Energies*. 2025; 18(17):4769.
- [3] SB. Roslan SB, D. Konovessis, and ZY. Tay, "Sustainable Hybrid Marine Power Systems for Power Management Optimisation: A Review," *Energies*. 2022; 15(24):9622.
- [4] X. Guo, X. Lang, Y. Yuan, L. Tong, B. Shen, T. Long, and W. Mao, "Energy management system for hybrid ship: Status and perspectives," *Ocean Engineering*, vol. 310, Part 1, 2024.
- [5] K. Liu, "Energy Management Strategy for a Hybrid Power System for Ocean Engineering Vessels Based on an Improved Particle Swarm Optimisation Algorithm," *Polish Maritime Research*, vol. 31, no. 4, Gdansk University of Technology, 2024, pp. 100-110.
- [6] F. D'Agostino, M. Gallo, M. Saviozzi, and F. Silvestro, "Performance Investigation of an Optimal Control Strategy for Zero-Emission Operations of Shipboard Microgrids," *2024 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*, Napoli, Italy, 2024, pp. 1048-1052.
- [7] L. Vu, T.-T. Nguyen, B. L.-H. Nguyen, M. I. Anam, and T. Vu, "Real-time hybrid controls of energy storage and load shedding for integrated power and energy systems of ships," *Electric Power Systems Research*, vol. 229, 2024.
- [8] F. D'Agostino, M. Gallo, M. Saviozzi, F. Silvestro, "A Security-Constrained Optimal Power Management Algorithm for Shipboard Microgrids with Battery Energy Storage System," *IEEE International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles & International Transportation Electrification Conference (ESARS-ITEC)*, pp.1-6, 2023.
- [9] Y. Liu, Z. Tian, J. Yang, and Z. Lin, "Data-Driven Evolutionary Game-Based Model Predictive Control for Hybrid Renewable Energy Dispatch in Autonomous Ships," arXiv:2403.01102, 2024.
- [10] S. Akbarzadeh, R. B. Cardenas, O. Mo et al., "Design and Evaluation Framework for Modular Hybrid Battery Energy Storage Systems in Full-Electric Marine Applications," *J. Marine Sci. Eng.*, vol. 13, no. 1, 2025.
- [11] X. Guo, X. Lang, Y. Yuan, L. Tong, B. Shen, T. Long, and W. Mao, "Energy management system for hybrid ship: Status and perspectives," *Ocean Engineering*, vol. 310, part 1, 2024.
- [12] S. Durgaprasad, A. Coraddu, E. Heyneman, C. Lamproye, H. Polinder, "A scenario-based integrated battery sizing and power plant scheduling under variable fuel prices and maritime operational profiles," *Energy Conversion and Management: X*, vol. 28, part 1, 2025.
- [13] S. Durgaprasad, A. Coraddu, H. Polinder, "An analysis of maritime battery requirements and a decision tree for optimal chemistry selection," *Energy Reports*, vol. 14, 2025.
- [14] S. Durgaprasad, Z. Malbašić, M. Popov, and A. Lekić, "Analysis of hybrid solutions with Li-ion battery system for DP-2 vessels," *Heliyon*, vol. 10, issue 17, 2024.
- [15] H. Lee, J. Jung, Y. Kim, S. Kim, and H. Jeon, "Comparative Analysis of Mechanical and Hybrid Propulsion Systems for Buoy Maintenance Vessel Based on Real-Sea Operational Data," *Journal of Marine Science and Engineering*, 2025; 13(12):2279.
- [16] F. Mandrile, M. Martino, S. Musumeci, and M. Pastorelli, "Hybrid Battery Systems," *Int. J. Energy Prod. Manag.*, 8(3), 141-147, 2023.
- [17] P. Ghimire, S. Karimi, M. Zadeh, K. K. Nagalingam, E. Pedersen, Model-based efficiency and emissions evaluation of a marine hybrid power system with load profile, *Electric Power Systems Research*, vol. 212, 2022.
- [18] M. Koričan, N. Vladimir, and A. Fan, "Environmental-economic assessment of hybrid power systems for fishing vessels," *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, 2025.
- [19] M. Kolodziejski, and I. Michalska-Pozoga, "Battery Energy Storage Systems in Ships' Hybrid/Electric Propulsion Systems. *Energies*. 2023; 16(3):1122.

Design of Multi-Objective Model Parameter Identification Problems for Application in Floating Offshore Wind Turbines

Sandra Piernikowska

*School of Science & Technology
City St George's, University of London
London, UK
sandra.piernikowska@city.ac.uk*

María Tomás-Rodríguez

*School of Science & Technology
City St George's, University of London
London, UK
maria.tomas-rodriguez.1@city.ac.uk*

Abstract—Reliable parameter identification is essential for constructing high-fidelity models suitable for control-oriented applications. This study investigates weighted single-objective and classical multi-objective identification strategies for a 4DOS spar-buoy floating offshore wind turbine (FOWT) model, capturing platform surge and pitch, tower fore-aft bending, and tuned mass damper motion. The model is derived from first principles using an Euler-Lagrange formulation and incorporates geometric coupling, gravitational effects, and key hydrodynamic effects, including hydrostatic stiffness, added mass, and viscous damping. Two approaches are examined: (i) weighted-sum method parameter identification (WSM-PI) and (ii) classic multi-objective parameter identification (MO-PI). The identification task is posed as an inverse optimisation problem, where the weighted-sum method creates the single-objective task as an alternative to the MO-PI. The objective function for both simultaneously considers tower top displacement (TTD) and platform pitch angle (PtfmPitch). Through a comparative study supported by statistical performance metrics, results show that if well designed, WSM-PI achieves lower NRMS and NRMSE values compared to MO-PI. The WSM-PI with weighted search and a multistart can achieve high accuracy results with the advantage of the computational cost. The proposed framework highlights how scalarization of a multi-objective function into a single-objective can serve as an alternative to more demanding classic multi-objective problems, such as multi-GA, particularly for higher-complexity FOWT models.

Index Terms—FOWT, modelling, identification, optimisation, weighted-sum method, multi-objective

I. INTRODUCTION

Model parameter identification, also called system parameter identification or parameter estimation, is the process of determining unknown physical or empirical parameters by reducing the error between simulated results and measured data [1]–[3]. Parameter identification relies on real measurement data from the physical system or benchmark software such as OpenFAST. The identification task can be viewed as an inverse optimisation problem, similar to regression, where

the goal is to obtain numerical values for parameters that define the system dynamics in the mathematical model, such as damping or stiffness in a coupled floating offshore wind turbine (FOWT) model [4]. It is important that the derived mathematical model represents the true system's behaviour, with well-captured dynamics [5].

The parameter identification problem can be formulated using either a single- or a multi-objective function. Single-objective parameter identification (SO-PI) refers to estimating model parameters by optimising one performance metric defined through a single-term objective function [6]. This approach is straightforward to set up, as it considers the error of only one dominant response variable, making it computationally efficient and simple to interpret. However, because a single performance measure drives the optimisation, the resulting parameter set may be biased toward the dynamics associated with that dominant DOF. This may lead to missing important system dynamics, such as fitting only one DOF well while failing to match others in a coupled model. One of the methods to overcome the classic SO-PI shortcoming is the weighted-sum method in multi-objective optimisation. The Weighted Sum Method (WSM) is a widely used scalarization method in multi-objective optimisation. It introduces a set of weights to the objective function, where each weight combination creates a different optimisation problem, and the best set of weights can be considered the optimal solution for the selected problem. The task then solved the problem with a single objective, but more than one performance measure can be considered. In other words, in the WSM-PI, the weights w_i represent the relative importance of the different objectives. As the optimisation task is then designed as a single-objective, the local optimiser can be used. In order to enhance the identification, the multi-start is initialised for the algorithm. The addition of multi-start to the local optimiser allows for a broader design space to be searched and ensures a smooth, well-distributed compromise curve. This also increases the chance of finding the global minimum while still using the robust local algorithm. With each start being independent, one might converge to a shallow local minimum, whereas

*This research was funded by a 3-year Doctoral Studentship from the City St George's, University of London, London. This work has been partially supported by the Spanish Ministry of Science and Innovation under the projects MCI/AEI/FEDER PID2021-123543OB-C21 and PID2024-155653OB-C21.

another might hit a deeper (better) local minimum. Multi-start helps avoid getting stuck in a local minimum that is not representative of the true trade-off between selected objectives, as the local minima for conflicting objectives can be very different, which is often the case for highly nonlinear, multimodal objective functions.

Multi-objective parameter identification (MO-PI) aims to minimise two or more conflicting objective metrics at the same time [7]. Unlike SO-PI, which combines all errors into a single scalar function, MO-PI treats each metric as an independent objective and seeks a set of solutions that represent the trade-offs between them, typically forming an optimal solution set. For both single- and multi-objective formulations, the objective functions can be defined using different error norms depending on the available reference data. Common norms include the $L - 1$ (Least Absolute Deviations), $L - 2$ (Least Squares) or $L\infty$ (Chebyshev/Minimax) [8]–[10].

Various parameter identification methods are used across many engineering disciplines, such as in civil and structural engineering [11]–[14]; or control engineering [15]–[17]. It is mainly driven by the need for reliable mathematical models describing real-life complex processes and often requires the estimation of numerous parameters or coefficients. In the FOWT field, several identification approaches and algorithms have been explored, depending on model complexity and intended use. [18] presented a general methodology for identifying reduced-order models through an iterative loop. The authors tested identification cases with four different algorithms, for example, subspace Gauss-Newton least squares search (GN) or steepest descent least squares search (GRAD). The results obtained show the importance of accurate identification and optimisation algorithm selection. In [19], MATLAB's System Identification Toolbox (SIT) is used with different weighting schemes to support blade-pitch controller design. Their work highlighted that identification accuracy strongly depends on the frequency content of the reference data; only parameters influencing the frequency range present in the input data can be reliably estimated. In [20], the authors demonstrated that SO-PI with the Nelder-Mead simplex method was sufficient when identifying a reduced model for structural control design. Similarly, in [21], SO-PI was sufficient for control-oriented design with a reduced DOF model. In [22], a nonlinear least-squares Levenberg-Marquardt method was employed to identify a 3DOF model with structural control, and once again, the SO-PI remained effective due to the reduced model order. More complex identification tasks were addressed by [23] and [24], both of whom used FAST or FAST-SC for identification and validation. [24] the author used the identified model to design H-infinity multivariable loop-shaping controllers, whereas [23] derived a 4DOF spar model including full aerodynamic and hydrodynamic contributions as well as mooring-line effects. In that work, the high nonlinearity and strong coupling of the system required more advanced parameter estimation methods.

This contribution systematically discusses and analyses the weighted-sum method multi-objective parameter identification (WSM-PI) with classic multi-objective parameter identification (MO-PI) using a genetic algorithm.

The trade-offs between methods are analysed with a focus on modelling accuracy in the case of a parameter identification task for Floating Offshore Wind Turbines (FOWTs). The comparison shows the alternative approach to general single- and multi-objective inverse optimisation methods.

II. METHODOLOGY

In this work, the 5MW reference wind turbine developed by the National Renewable Energy Laboratory (NREL) is used with a spar-buoy support foundation [25]. This benchmark is a commonly used reference within the FOWT community [23], [24], [26]–[30].

A. Modelling Assumptions

In the case of spar FOWT, the dominant DOF is a translational platform surge (x-direction). In the model presented below, the tower F-A bending movement θ_t , TMD longitudinal translation x_{TMD} , and platform pitch θ_p and surge x_s are coupled to obtain a 4DOF representation of the system. Subscripts t, p, s, TMD denote parameters of the tower, pitch, surge and TMD, respectively, throughout all derivations. The modelling assumptions are as follows [31]:

- The system is approximated as a 4DOF system consisting of a platform (pitch and surge), tower and rotor/nacelle assembly with a TMD. The dynamics associated with the rotor yaw, generator, or gearbox are neglected. The mass of the tower and all nacelle elements is lumped, except the TMD mass, which is considered separately.
- The degrees of freedom considered are a platform pitch, a platform surge, a tower foreaft bending and a TMD longitudinal translation.
- The tower flexibility is represented by a linear rigid rotating beam hinged at the tower bottom [32], which is taken as an origin of any relative movement.
- Only the hydrodynamic contributions are considered, that is, hydrostatic restoring, added-mass effect and hydrodynamic damping.

B. Model Derivation Process

For the derivation of the full 4DOF spar FOWT model, the Euler-Lagrangian mechanics is applied. The Lagrangian dynamics can be expressed as:

$$\frac{d}{dt} \left(\frac{\partial L}{\partial \dot{q}_i} \right) - \left(\frac{\partial L}{\partial q_i} \right) = Q_i \quad (1)$$

where L is a Lagrangian operator defined as $L = T - V$ with $i = 1, 2, \dots, n$. T and V are the total kinetic and potential energies of the system, respectively. Q_i is a generalised force. q_i is the generalised coordinate, and for this problem, the generalised coordinates are defined as:

$$q = \{\theta_p, \theta_t, x_s, x_{TMD}\}$$

where θ denotes the angular displacement (rotation) about the y-axis, with x being a linear displacement along the x-axis.

The derivation of the individual equation elements is analysed below:

- Total kinetic energy (KE) of the system, T :

$$T = \underbrace{\frac{1}{2}I_p\dot{\theta}_p^2}_{(1)} + \underbrace{\frac{1}{2}I_t\dot{\theta}_t^2}_{(2)} + \underbrace{\frac{1}{2}m_{TMD}\dot{x}_{TMD}^2}_{(3)} + \underbrace{\frac{1}{2}(m_p + m_t)\dot{x}_s^2}_{(4)} + \underbrace{\frac{1}{2}m_t(\dot{x}_s + R_t\cos\theta_t\dot{\theta}_t)^2}_{(5)} \quad (2)$$

(1) - platform pitch rotational KE

(2) - rotational KE of the tower

(3) - TMD mass KE

(4) - platform translational KE in surge (mass in surge is a summation of the mass of the platform and tower)

(5) - TT horizontal translational KE that can be expanded to $\frac{1}{2}m_t(\dot{x}_s^2 + 2\dot{x}_sR_t\cos\theta_t\dot{\theta}_t + R_t^2\dot{\theta}_t^2)$

- Total potential energy (PE) of the system, V :

$$V = \underbrace{\frac{1}{2}k_p\theta_p^2}_{(1)} - \underbrace{m_pgR_p\cos\theta_p}_{(2)} + \underbrace{\frac{1}{2}k_t(\theta_t - \theta_p)^2}_{(3)} + \underbrace{m_tgR_t\cos\theta_t}_{(4)} + \underbrace{\frac{1}{2}k_{TMD}(x_{TMD} - R_{TMD}\sin\theta_t - x_s)^2}_{(5)} + \underbrace{\frac{1}{2}k_sx_s^2}_{(6)} + \underbrace{m_{TMD}g[R_{TMD}\cos\theta_t + (x_{TMD} - R_{TMD}\sin\theta_t)\tan\theta_t]}_{(7)} \quad (3)$$

(1) - platform pitch hydrostatic stiffness

(2) - gravitational PE of the platform

(3) - relative rotational stiffness between tower and platform

(4) - gravitational PE of the tower

(5) - PE of the TMD spring connected between the TMD mass and a point near TT

(6) - platform surge hydrostatic stiffness

(7) - TMD gravitational PE (derived from geometry)

- Dissipation - generalised force Q_i :

The damping in the model is defined via the principle of virtual work, considering relative velocities. Therefore,

the generalised non-conservative forces Q_i , that is, damping, can be expressed as:

$$\begin{cases} Q_{\theta_p} = -d_p\dot{\theta}_p + d_t(\dot{\theta}_t - \dot{\theta}_p) \\ Q_{\theta_t} = d_{TMD}R_{TMD}\cos\theta_t(-R_{TMD}\dot{\theta}_t\cos\theta_t - \dot{x}_s) \\ \quad + d_{TMD}R_{TMD}\cos\theta_t\dot{x}_{TMD} - d_t(\dot{\theta}_t - \dot{\theta}_p) \\ Q_{x_{TMD}} = -d_{TMD}R_{TMD}\cos\theta_t(-R_{TMD}\dot{\theta}_t\cos\theta_t - \dot{x}_s) \\ \quad - d_{TMD}R_{TMD}\cos\theta_t\dot{x}_{TMD} \\ Q_{x_s} = d_{TMD}R_{TMD}\cos\theta_t(-R_{TMD}\dot{\theta}_t\cos\theta_t - \dot{x}_s) \\ \quad + d_{TMD}R_{TMD}\cos\theta_t\dot{x}_{TMD} - d_s\dot{x}_s \end{cases} \quad (4)$$

The terms in Q_i come from the TMD damper acting on the relative velocity calculated from horizontal spring extension δ and viscous damping terms for pitch and surge.

- Lagrangian operator, $L = T - V$:

The Lagrangian operator can be defined as:

$$L(q_i, \dot{q}_i) = T(q_i, \dot{q}_i) - V(q_i), \quad q_i \in \{\theta_p, \theta_t, x_s, x_{TMD}\}.$$

- Hydrodynamic Effects

The hydrodynamic effects are considered as an extension to the isolated model that can be obtained from Lagrangian mechanics. In this work, the hydrodynamic effects are considered in a still water condition, that is, considering that there are no incoming waves. As the model is positioned in the still water, hydrostatic restoring is always present. If the structure is allowed to oscillate freely (e.g., due to the pitching of the platform), the hydrodynamic damping and added mass also appear. For surge DOF, the $B_{linear} = 100000N/(m/s)$ correction term for structural damping must be added, according to [33].

The demonstrated 4DOF spar FOWT model can also be linearised by considering that the platform pitch angle never exceeds 5 degrees; therefore, the small-angle approximation can be applied. By considering the generalised Lagrangian equation, presented in (1), and by substitution of KE, PE and Q from (2) to (4), the completed linear 4DOF spar model of FOWT can be summarised in the matrix form, as follows:

$$M\ddot{q} + D\dot{q} + Cq = F(t) \quad (5)$$

where matrices M, D and C represent the cumulative mass, damping and stiffness, respectively and are summarised below:

$$M = \begin{bmatrix} I_p & 0 & \dots & 0 \\ \vdots & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ 0 & \dots & 0 & m_{TMD} \end{bmatrix}$$

$$D = \begin{bmatrix} d_p + d_t & -d_t & \dots & 0 \\ \vdots & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ -d_{TMD}R_{TMD} & \dots & \dots & -d_{TMD} \end{bmatrix}$$

$$C = \begin{bmatrix} k_p + k_t + m_p R_p g - C_{hydro} & -k_t & \dots & 0 \\ \vdots & \ddots & & \vdots \\ \vdots & & \ddots & \vdots \\ 0 & \dots & \dots & -k_{TMD} \end{bmatrix}$$

C. Model Accuracy Matrices

In order to compare the performance of two parameter identification methods, the statistical matrices, that is, RMS, NRMS, and NRMSE, are used to quantify the model accuracy.

- RMS, that is, the Root Mean Square of the residuals.

RMS describes how far from the regression curve data points are located. In other words, for the system validation, it is a metric of the distance between the true data, in our case from OpenFAST, and the prediction model, that is, the derived model, being the set of equations of motion. RMS can be mathematically represented, taking TTD as an example, as follows:

$$\sqrt{\sum_{i=1}^N \text{mean}((TTD_{model,i} - TTD_{OpenFAST,i})^2)}$$

RMS has a physical unit that depends on the unit of the parameter chosen, e.g., meters for TTD. RMS of a signal represents the average amplitude of the oscillation of that signal.

- NRMS, that is Normalised Root Mean Square.

NRMS is a normalised RMS, described above. RMS is usually made dimensionless to allow for easy comparison of parameters of different scales, e.g., TTD and platform pitch. NRMS also describes how well the model captures the dynamics of the reference signal; however, it is defined as a ratio of the RMS error and the RMS of the reference signal, R_{ref} . Mathematically, it can be written as follows:

$$\sqrt{\sum_{i=1}^N \frac{\text{mean}(TTD_{model,i} - TTD_{OpenFAST,i})^2}{\text{mean}(TTD_{OpenFAST,i})^2}}$$

It is important to note that NRMS is an error relative to the typical signal magnitude, hence it is an RMS-based normalisation.

- NRMSE, that is Normalised Root Mean Squared Error.

Similarly to NRMS, NRMSE is a dimensionless quantity; it is obtained by calculation of RMS over the full range of data (time series from maximum peak to minimum peak), that is, the signal's peak-to-peak range, R_{range} . Hence, it captures the error related to the full time series of the simulation, which is different from NRMS. NRMSE can be expressed as follows:

$$\sqrt{\sum_{i=1}^N \frac{\text{mean}(TTD_{model,i} - TTD_{OpenFAST,i})^2}{\max(TTD_{OpenFAST,i}) - \min(TTD_{OpenFAST,i})}}$$

It is important to note that NRMSE is a range-based normalisation.

D. Design of WSM-PI and MO-PI

The generalised objective function, used in this work, for WSM-PI and MO-PI can mathematically be expressed as follows:

$$J = \sqrt{w_i \times \sum_{i=1}^N |\tilde{f}_i|^2}.$$

A compromise solution is selected from the Pareto set based on a trade-off criterion, that is, a knee point on the Pareto curve. The knee point solution is identified using the maximum perpendicular distance method on the Pareto Front, and it represents the maximum trade-off efficiency between objectives. The Pareto frontier, also called the Pareto front or Pareto curve, represents the range of possible solutions that are Pareto optimal. In other words, it is a graphical representation of the trade-off between contradicting objectives [34]. The location of the compromise solution is based on the Pareto-optimal policy that states that the set can be accepted as Pareto optimal if there is no alternative set of solutions that would make one of the objectives improve without negatively influencing another.

For WSM-PI, the process of weight selection can be performed by weight sweep on the Pareto Front, that is, the parameter identification is simulated for a large set of weights and the best pair is accepted as an optimal solution. Moreover, the Nelder-Mead simplex local algorithm is used with an enhancement of a multi-start at 5 different points. The multi-start method explores potential solutions in the close neighbourhood of the initial guesses. The multiplicative Gaussian perturbation of 15% random is used, around the initial guesses, to ensure the scaling is respected. At the end of the search, only the best solutions found across all start points in the weight sweep process are accepted and recorded. In multi-objective optimisation, the Pareto frontier is also utilised together with a multi-GA as a parallel process over 14 workers. The population size of 100 is used together with $\pm 50\%$ boundary perturbation around the initial guesses and a maximum generation of 5000.

III. RESULTS AND DISCUSSION

Based on the methodology described in section II-D, two approaches for parameter identification are examined: (i) weighted-sum multi-objective parameter identification (WSM-PI) that, after scalarization, can be treated as SO-PI with a local optimiser, and (ii) classical multi-objective parameter identification (MO-PI) by a genetic algorithm.

Figure 1 shows the resultant Pareto curve for the weighted-sum method. The compromise solution is found for $w_1 = 0.7$ and $w_2 = 0.3$, with w_1 representing higher importance for minimising TTD. It is visible that there are not many Pareto solution points on the plot. It is due to the selection of the number of weights set for the identification process; the greater the number of weight sets, the more data points available for the compromise curve. Due to the computational time limitations, only 11 sets of weights were selected that produce approximately 4 to 5 feasible Pareto solutions.




Fig. 1. Pareto Front for WSM-PI.

Figure 2 shows the resultant Pareto Front for the multi-GA process. Among all Pareto non-dominant solutions (marked with blue dots) plotted as normalised TTD and PtfmPitch errors, the compromise solution, that is, the knee point (marked with a red dot), is obtained. The Pareto curve has a smooth shape, and it is also well populated with many points, as the global algorithm is used.




Fig. 2. Pareto Front for MO-PI by GA.

The model accuracy matrices for the weighted-sum method and classic multi-GA, which quantify fit quality as described in section II-C, are summarised in Table I.

TABLE I
MODEL ACCURACY MATRICES FOR WSM-PI (TOP) AND MO-PI BY GA (BOTTOM).

WSM-PI	TTD	PtfmPitch	Unit
RMS	1.24	9.20	[%]
NRMS	8.72	4.67	[%]
NRMSE	1.40	1.06	[%]
MO-PI	TTD	PtfmPitch	Unit
RMS	1.96	12.42	[%]
NRMS	13.82	6.30	[%]
NRMSE	2.21	1.42	[%]

Based on the obtained data, it is evident that WSM performance is closely comparable to MO-PI by GA. Both algorithms were run using the stiff ODE solver with a function tolerance of $1e^{-5}$. The local optimiser is executed as a single process, whereas parallel computing is taken advantage of for the global algorithm. This approach significantly cuts down on the execution time; however, as a consequence, the computational effort is much higher. In comparison, the WSM-PI process takes significantly more computational time; however, the computational strain is much lower due to limitations of the local method, which is, the algorithm cannot be used with a parallel process. It is noticeable that the differences across all accuracy matrices are small. That suggests, despite the limitations of local optimisers, if the problem is designed well, the scalarization of a multi-objective problem into a single-objective problem can produce an accurate model with all real dynamics captured. To further visualise, the resultant plot of the TTD and PtfmPitch with optimal parameters found through identification with WSM and multi-GA validated against the OpenFAST benchmark is shown in Figure 3. The simulation output confirms the statistical matrices previously shown, that is, the WSM-PI performs very well in the task of parameter estimation for the proposed 4DOF spar FOWT model, with comparable results to the classic multi-GA.




Fig. 3. Comparison of simulation output, that is, TTD and PtfmPitch for WSM-PI and MO-PI against the OpenFAST benchmark.

IV. CONCLUSION

In this work, two approaches for the model parameter identification task of 4DOF spar FOWT were studied: that is, the weighted-sum method parameter identification (WSM-PI) and the classic multi-objective parameter identification (MO-PI) by a genetic algorithm. A weighted-sum scalarisation approach was introduced, where the original bi-objective problem, comprising TTD error and the PtfmPitch error, was converted into a sequence of single-objective optimisation problems by forming a combination of two errors with a set of weights indicating their importance. The Pareto curve was used to examine the trade-off with an optimal solution chosen by a knee point on the plot, using the perpendicular

distance method. For WSM, for each weight combination, the resultant scalarised optimisation problem was solved using a local, derivative-free optimiser with a multi-start strategy to mitigate sensitivity to initial conditions and reduce the risk of convergence to local minima. The set of solutions obtained across all weight combinations was subsequently filtered using non-dominated sorting to extract the Pareto-optimal subset. It is important to highlight that due to the nature of the weighted-sum method, the resulting Pareto front represents an approximation of the true Pareto. The WSM was compared with the classic multi-objective parameter identification (MO-PI) strategy based on a genetic algorithm (GA). In MO-PI, the original bi-objective optimisation problem was solved simultaneously without scalarisation, allowing the GA to explore the Pareto front directly. A population of candidate parameter sets was evolved over successive generations. Due to the nature of multi-GA being a population-based algorithm, the Pareto Front is naturally generated as a well-distributed plot. In multi-GA, the compromise solution was also found through analysing the trade-off from the Pareto Front with the optimal solution at the knee point. It can be concluded, based on the results demonstrated, that the weighted-sum multi-objective parameter identification (WSM-PI) approach provides a good approximation of the Pareto front with the accuracy of the compromise solutions outperforming the multi-GA method. While multi-GA captures the full Pareto set and can handle non-convex regions more thoroughly, the WSM approach achieves good accuracy with significantly lower computational cost and implementation complexity. Therefore, for practical purposes, WSM-PI can be used as an efficient alternative to robust multi-GA for the model parameter identification of the 4DOF spar FOWT, particularly when a reference Pareto front is sufficient for comparison or design trade-off studies.

REFERENCES

- [1] A. K. Tangirala, *Principles of system identification: theory and practice*. CRC press, 2018.
- [2] M. Kern, *Numerical methods for inverse problems*. John Wiley & Sons, 2016.
- [3] B. Chen, Y. Zhu, J. Hu, and J. C. Principe, *System parameter identification: information criteria and algorithms*. Newnes, 2013.
- [4] T. Uhl, "The inverse identification problem and its technical application," *Archive of Applied Mechanics*, vol. 77, no. 5, pp. 325–337, 2007.
- [5] R. C. Aster, B. Borchers, and C. H. Thurber, *Parameter estimation and inverse problems*. Elsevier, 2018.
- [6] P. B. Sáez and B. E. Rittmann, "Model-parameter estimation using least squares," *Water Research*, vol. 26, no. 6, pp. 789–796, 1992.
- [7] K. Deb, K. Sindhya, and J. Hakanen, "Multi-objective optimization," in *Decision sciences*. CRC Press, 2016, pp. 161–200.
- [8] I. Griva, S. G. Nash, and A. Sofer, *Linear and nonlinear optimization 2nd edition*. SIAM, 2008.
- [9] M. Schmidt, "Least squares optimization with l1-norm regularization," *CS542B Project Report*, vol. 504, no. 2005, pp. 195–221, 2005.
- [10] G. Zhu, *L-2 and L-infinity multiobjective control for linear systems*. Purdue University, 1992.
- [11] J. Mai, M. Cuntz, M. Shafii, M. Zink, D. Schäfer, S. Thober, L. Samaniego, and B. Tolson, "Multi-objective vs. single-objective calibration of a hydrologic model using single-and multi-objective screening," in *EGU General Assembly Conference Abstracts*, 2016, pp. EPSC2016–8997.
- [12] R. Zhang, J. Liu, H. Gao, and G. Mao, "Can multi-objective calibration of streamflow guarantee better hydrological model accuracy?" *Journal of Hydroinformatics*, vol. 20, no. 3, pp. 687–698, 2018.
- [13] G. Sirca Jr and H. Adeli, "System identification in structural engineering," *Scientia Iranica*, vol. 19, no. 6, pp. 1355–1364, 2012.
- [14] H. G. Natke, *Application of system identification in engineering*. Springer, 2014, vol. 296.
- [15] Y. Boutalis, M. A. Christodoulou, D. Theodoridis, and T. Kottas, "System identification and adaptive control," *Theory and Applications of the neurofuzzy and fuzzy cognitive network models*, 2014.
- [16] W. Wei, N. Schwartz, and K. Cohen, "Frequency-domain system identification and simulation of a quadrotor controller," in *AIAA Modeling and Simulation Technologies Conference*, 2014, p. 1342.
- [17] M. Annergren, C. A. Larsson, H. Hjalmarsson, X. Bombois, and B. Wahlberg, "Application-oriented input design in system identification: Optimal input design for control [applications of control]," *IEEE Control Systems Magazine*, vol. 37, no. 2, pp. 31–56, 2017.
- [18] D. Villoslada, M. Santos, and M. Tomás-Rodríguez, "General methodology for the identification of reduced dynamic models of barge-type floating wind turbines," *Energies*, vol. 14, no. 13, p. 3902, 2021.
- [19] N. Hara, S. Tsujimoto, Y. Nihei, K. Iijima, and K. Konishi, "Experimental validation of model-based blade pitch controller design for floating wind turbines: system identification approach," *Wind energy*, vol. 20, no. 7, pp. 1187–1206, 2017.
- [20] S. Piernikowska and M. T. Rodríguez, "Classic optimisation methodology as an inverse problem for parameter identification for floating offshore wind turbines," in *Haize eta Itsas Energiari Buruzko Irakaskuntza-Oharak: PID2021-123543OB-C21 eta C22 proiektuen VI. Jardunaldiako Monografia*. Servicio Editorial= Argitaipen Zerbitzua, 2025, pp. 14–19.
- [21] S. Piernikowska and M. T. Rodríguez, "Impact of inerter in vibrational control in floating offshore wind turbines," in *Irakaskuntza berrikuntza kontrol ingeniaritzan itsas energian*. Servicio de Publicaciones, 2022, pp. 47–52.
- [22] E.-M. He, Y.-Q. Hu, and Y. Zhang, "Optimization design of tuned mass damper for vibration suppression of a barge-type offshore floating wind turbine," *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, vol. 231, no. 1, pp. 302–315, 2017.
- [23] V.-N. Dinh and B. Basu, "Passive control of floating offshore wind turbine nacelle and spar vibrations by multiple tuned mass dampers," *Structural Control and Health Monitoring*, vol. 22, no. 1, pp. 152–176, 2015.
- [24] M. A. Lackner and M. A. Rotea, "Structural control of floating wind turbines," *Mechatronics*, vol. 21, no. 4, pp. 704–719, 2011.
- [25] J. Jonkman, "Definition of the floating system for phase iv of oc3," National Renewable Energy Lab.(NREL), Golden, CO (United States), Tech. Rep., 2010.
- [26] J. M. Jonkman, *Dynamics modeling and loads analysis of an offshore floating wind turbine*. University of Colorado at Boulder, 2007.
- [27] J. Jonkman, "Influence of control on the pitch damping of a floating wind turbine," in *46th AIAA aerospace sciences meeting and exhibit*, 2009, p. 1306.
- [28] M. Santos and M. Tomás-Rodríguez, "Floating offshore wind turbines: Controlling the impact of vibrations," in *7th International Conference on Systems and Control, Valencia Spain*, 2018.
- [29] M. A. Lackner and M. A. Rotea, "Passive structural control of offshore wind turbines," *Wind energy*, vol. 14, no. 3, pp. 373–388, 2011.
- [30] G. M. Stewart and M. A. Lackner, "The effect of actuator dynamics on active structural control of offshore wind turbines," *Engineering Structures*, vol. 33, no. 5, pp. 1807–1816, 2011.
- [31] G. M. Stewart, "Load reduction of floating wind turbines using tuned mass dampers," 2012.
- [32] G. Stewart and M. Lackner, "Determining optimal tuned mass damper parameters for offshore wind turbines using a genetic algorithm," in *50th AIAA aerospace sciences meeting including the new horizons forum and aerospace exposition*, 2012, p. 376.
- [33] J. Jonkman, S. Butterfield, W. Musial, and G. Scott, "Definition of a 5-mw reference wind turbine for offshore system development," National Renewable Energy Lab.(NREL), Golden, CO (United States), Tech. Rep., 2009.
- [34] G. Dumedeh, A. A. Berg, and M. Wineberg, "Pareto-optimality and a search for robustness: choosing solutions with desired properties in objective space and parameter space," *Journal of Hydroinformatics*, vol. 14, no. 2, pp. 270–285, 2012.

Multi-Objective Optimization of Individual Pitch Control for Floating Offshore Wind Turbines

Lei Ren

College of Mechanics and Engineering
Science
Hohai University
Nanjing, China
lren@ucm.es

Matilde Santos

Institute of Knowledge
Technology Complutense
University of Madrid Madrid,
Spain
msantos@ucm.es

Xin Cai

College of Mechanics and Engineering
Science
Hohai University
Nanjing, China
xcai@hhu.edu.cn

Abstract—The effective implementation of Individual Pitch Control (IPC) is crucial for mitigating structural loads and platform motions in floating offshore wind turbines (FOWTs), yet the tuning of its controller parameters presents a complex multi-objective challenge. This study proposes a systematic optimization framework to address this issue. A multi-objective optimization problem is formulated with the goal of simultaneously minimizing blade root fatigue loads and pitch actuator duty. The Non-dominated Sorting Genetic Algorithm II (NSGA-II) is employed to identify the Pareto-optimal set of proportional-integral (PI) gains for the IPC system. Time-domain simulations of a reference FOWT model demonstrate that all optimized control strategies significantly outperform conventional collective pitch control, achieving a reduction of up to 39.9% in blade root load fluctuations and improved platform stability. Among them, the balanced strategy derived from the Pareto front offers the most favorable overall trade-off, providing substantial load reduction with reasonable actuator activity. The results validate the proposed framework as an effective tool for the design of high-performance IPC systems for FOWTs.

Keywords—Floating Offshore Wind Turbine; Individual Pitch Control; Multi-Objective Optimization; NSGA-II; Load Reduction; Controller Tuning

I. INTRODUCTION

In modern wind turbine control systems, pitch control plays a critical role in optimizing power output and mitigating structural loads. Traditional collective pitch control (CPC) adjusts all blades simultaneously based on rotor speed error, typically using Proportional-Integral (PI) controllers with gain scheduling to handle system nonlinearities [1]. While CPC is effective in regulating generator speed and maintaining rated power in above-rated wind conditions, it assumes uniform aerodynamic loads across all blades—a condition rarely met in real-world environments due to wind shear, turbulence, and atmospheric inhomogeneity. This limitation leads to unbalanced rotor loads, increased fatigue, and potential structural failures, especially in large-scale turbines.

The challenges of CPC become more pronounced in floating offshore wind turbines (FOWTs), where additional complexities such as platform motions, wave-induced vibrations, and wind-wave coupling exacerbate load asymmetries and system dynamics. For instance, semi-submersible FOWTs experience significant low-frequency vibrations and IP oscillations in the blade root bending moment, which CPC cannot address effectively due to its inherent design [2]. The classic and most widely implemented IPC architecture involves separate PI controllers for the tilt and yaw moments, which are derived from the blade root bending moments through a multi-blade coordinate (MBC) transformation.

To overcome these limitations, individual pitch control (IPC) has emerged as an advanced solution. Unlike CPC, IPC independently adjusts the pitch angle of each blade based on localized load measurements, enabling targeted mitigation of asymmetric loads and platform-induced vibrations. Studies demonstrate that IPC significantly reduces periodic loads in key components such as the blades, tower, and hub. Namik et al. [3] showed through high-fidelity simulations that IPC can achieve substantial reductions of 44% in power fluctuation, 39% in platform rolling rate, and 43% in pitching rate compared to conventional controllers.

Despite its proven benefits, the performance of this standard IPC structure is highly dependent on the precise tuning of its PI controller parameters (K_p and K_i). Suboptimal gains can lead to inadequate load reduction, excessive pitch actuator usage, or even system instability. Therefore, there remains a persistent need and significant value in improving the core PI control loop of IPC. A robustly tuned and optimized set of IPC PI gains can deliver substantial performance benefits with a simple, reliable controller structure. The optimization of IPC's PI gains is inherently a multi-objective problem, aiming to simultaneously maximize load reduction and minimize pitch actuator activity. To solve such problems, the wind energy field has seen the application of various metaheuristic algorithms, including swarm intelligence-based methods like Multi-Objective Particle Swarm Optimization (MOPSO)[4] and physics-inspired algorithms like the Archimedes Optimization Algorithm (AOA) [5], the latter having been used for pitch controller tuning. Among these, the Non-dominated Sorting Genetic Algorithm II (NSGA-II) is a prominent evolutionary multi-objective algorithm frequently employed in wind energy studies for tasks ranging from wind turbine layout to aerodynamic design[6], [7]. Its selection for this work is justified by its proven capability to maintain solution diversity and generate well-distributed Pareto frontiers, which is essential for exploring the trade-offs between competing control objectives effectively. Therefore, this work focuses on the fundamental optimization of the PI controller gains (K_p and K_i) for IPC using NSGA-II, aiming to enhance load reduction performance in FOWTs.

II. METHODOLOGY

A. Reference Wind Turbine and Platform Model

The configuration of the International Energy Agency (IEA) 15MW offshore reference wind turbine with the VoltumUS-S semi-submersible platform is studied in this research [8], as shown in Fig. 1.

The IEA 15 MW offshore wind turbine, featuring three upwind blades, is installed on the VoltumUS-S semi-submersible platform. Table I provides the main specifications of the wind turbine, with SWL denoting the still water level. The wind turbine blades are treated as rigid,

while tower flexibility is taken into account. The reference platform presented in this research is a three-column, steel semisubmersible.




Fig. 1 IEA 15MW offshore reference wind turbine with the VoltturnUS-S semi-submersible platform

TABLE I. WIND TURBINE INFORMATION AND PARAMETERS

Parameters	Value
Rotor type	Upwind, 3 Blades
Rotor diameter	240 m
Hub height above SWL	150 m
Cut-in wind speed	3 m/s
Cut-out wind speed	10.59 m/s
Rated wind speed	25 m/s
Minimum rotor speed	5.0 m/s
Maximum rotor speed	7.56 m/s

B. Individual Pitch Control Design

In large three-bladed wind turbines, the non-uniform distribution of aerodynamic loads—particularly the 1P harmonic loads induced by factors such as wind shear and tower shadow effects—is a key factor leading to blade fatigue damage. To mitigate such loads, Individual Pitch Control (IPC) achieves dynamic load balancing by applying differentiated pitch commands to each blade. However, the blade dynamics in the rotating coordinate system exhibit strong coupling and periodic time-varying characteristics, making direct controller design highly complex. Therefore, the Multiblade Coordinate Transformation (MBC) [9] is employed to convert the rotating-frame dynamics into a fixed coordinate system for linearization, providing a suitable control framework for IPC.

MBC is a mathematical transformation based on the blade azimuth angles ψ_i , with its core function being to decouple periodic signals in the rotating coordinate system. Through the MBC transformation, the blade loads (bending moments) in the rotating coordinate system are converted into two components in the non-rotating coordinate system: the tilt moment $M_t(t)$ and the yaw moment $M_y(t)$. In the MBC transformation targeting the 1P harmonic, the out-of-plane (OoP) bending moments of the three blades form a vector $M(t) = [M_1(t) \ M_2(t) \ M_3(t)]^T$. This vector is input into the forward MBC transformation matrix $T(\psi)$ to compute the azimuth-independent moment components $M_t(t)$ and $M_y(t)$ in the fixed coordinate system. Their relationship is given as follows:

$$\begin{bmatrix} M_t(t) \\ M_y(t) \end{bmatrix} = T(\psi) M(t) \quad (1)$$

where, the three-element vector ψ contains the azimuth angles of each blade (with the vertical upward position of the blade defined as zero degrees). The forward transformation matrix is given by:

$$T(\psi) = \frac{2}{3} \begin{bmatrix} \cos(\psi_1) & \cos(\psi_2) & \cos(\psi_3) \\ \sin(\psi_1) & \sin(\psi_2) & \sin(\psi_3) \end{bmatrix} \quad (2)$$

Subsequently, to suppress the M_t and M_y components, the corresponding tilt pitch angle $\beta_t(t)$ and yaw pitch angle $\beta_y(t)$ are typically computed within the IPC control module through decentralized control. Then, these two pitch signals in the fixed coordinate system are converted back to the rotating coordinate system via the inverse MBC transformation to obtain the IPC components in the rotating coordinate system:

$$\begin{bmatrix} \beta_{IPC1}(t) \\ \beta_{IPC2}(t) \\ \beta_{IPC3}(t) \end{bmatrix} = T^{-1}(\psi + \psi_0) \begin{bmatrix} \beta_t(t) \\ \beta_y(t) \end{bmatrix} \quad (3)$$

The inverse transformation matrix T^{-1} is given by the formula:

$$T^{-1} = \begin{bmatrix} \cos(\psi_1 + \psi_0) & \sin(\psi_1 + \psi_0) \\ \cos(\psi_2 + \psi_0) & \sin(\psi_2 + \psi_0) \\ \cos(\psi_3 + \psi_0) & \sin(\psi_3 + \psi_0) \end{bmatrix} \quad (4)$$

The parameter ψ_0 is the azimuth offset, used to effectively reduce the residual coupling effects between the two components in the fixed coordinate system. Finally, the IPC components for each blade are superimposed with the Collective Pitch Control (CPC) signal β_{CPC} to calculate the pitch command value β_i for each blade.

C. Multi-objective Optimization Problem Formulation

The multi-objective optimization problem for IPC PI controller tuning is mathematically formulated to simultaneously minimize two conflicting performance metrics that represent the key trade-offs in wind turbine control design.

The decision variables are the proportional and integral gains of the IPC controller for the 1P load component:

$$x = [K_p \ K_i]^T \quad (5)$$

where the search space is constrained by bounds determined through prior sensitivity analysis:

$$\begin{aligned} K_p &\in [1 \times 10^{-10}, 1 \times 10^{-8}] \\ K_i &\in [1 \times 10^{-11}, 1 \times 10^{-9}] \end{aligned} \quad (6)$$

Two objective functions are defined to be minimized:

$$\begin{aligned} f_1(x) &= DEL_{rootMOoP1} \\ f_2(x) &= \sigma_{pitch_rate} \end{aligned} \quad (7)$$

The Damage Equivalent Load (DEL) of the blade root out-of-plane bending moment is calculated using rainflow counting [10] to extract load cycles from the time series data. The DEL is derived according to the Palmgren-Miner linear damage accumulation rule [11]:

$$DEL = \left(\frac{\sum_{i=1}^k (n_i \cdot S_i)}{N_{eq}} \right)^{\frac{1}{m}} \quad (8)$$

where n_i is the number of cycles at stress range S_i obtained from rainflow counting, m is the Wöhler (S-N) curve exponent and N_{eq} is the reference number of cycles. The standard deviation of the blade pitch rate σ_{pitch_rate} is minimized to quantify and reduce actuator usage and mechanical wear.

Thus, the optimization problem captures the inherent compromise between structural load mitigation and actuator preservation. Its goal is to find the Pareto-optimal controller parameters that define the best possible compromises between these conflicting demands.

D. NSGA-II Optimization Framework

The multi-objective optimization [12], [13] was performed using the NSGA-II algorithm via MATLAB *gamultiobj* function. The optimization follows an iterative process as illustrated in Fig. 2. The process began by initializing a population of 200 individuals, with each candidate solution representing a pair of PI parameters (K_p , K_i) randomly generated within the predefined bounds. For each generation, the entire population was evaluated by running OpenFAST simulations with the candidate parameters to compute the two objective functions: blade root bending moments DEL and pitch rate standard deviation. These simulations were accelerated through parallel computation. Following evaluation, the algorithm performed non-dominated sorting to rank the solutions based on Pareto dominance and calculated the crowding distance to preserve diversity across the front. To create the next generation, tournament selection with a size of 4 was applied to choose parents, which were then recombined using intermediate crossover (with a fraction of 0.8) and perturbed via adaptive feasible mutation to maintain genetic diversity. This evolutionary loop continued until a maximum of 120 generations was reached, or the optimization stalled for 30 generations, or the change in the objective functions fell below a tolerance of $5e-4$, at which point the final set of Pareto-optimal solutions was output.




Fig. 2 Flowchart of the NSGA-II optimization framework for IPC PI parameter tuning

III. RESULTS AND DISCUSSION

Following the optimization framework established in Section II, this section presents and analyzes the key outcomes. First, the Pareto front obtained from the NSGA-II optimization is examined to elucidate the fundamental trade-offs between load mitigation and actuator usage. Subsequently, a detailed performance comparison is conducted between selected optimal strategies and the baseline collective pitch controller, evaluating their effectiveness across critical metrics including blade loads, platform motion, and pitch activity.

A. Pareto Front Analysis

The Pareto front obtained from the NSGA-II optimization illustrates the inherent trade-off between the two competing objectives: blade root load reduction (DEL) and actuator preservation (σ_{pitch_rate}), as shown in Fig. 3. To facilitate a concrete analysis, three representative optimal solutions were extracted from the front using distinct selection strategies. A balanced solution was identified by selecting the design point with the minimal normalized Euclidean distance to the ideal utopia point. The two extreme solutions were chosen by individually minimizing each objective function: the load-optimal solution (minimizing DEL) and the actuator-optimal solution (minimizing σ_{pitch_rate}). The corresponding optimal PI controller gains (K_p , K_i) for these three selected solutions are summarized in Table II. A direct observation is the clear correlation between the gain magnitudes and the control objective: the load-optimal solution is characterized by the largest controller gains ($K_p=9.85 \times 10^{-9}$, $K_i=1.18 \times 10^{-10}$), which enable a fast and aggressive response to disturbances, while the actuator-optimal solution employs the smallest gains ($K_p=1.27 \times 10^{-10}$, $K_i=1.02 \times 10^{-11}$) to achieve a restrained control action. The balanced solution adopts an intermediate set of gains, reflecting its compromise position. These three solutions collectively encapsulate the key performance characteristics along the Pareto boundary and are used for the detailed comparative evaluation in the following section.




Fig. 3 Pareto front (Pitch rate vs $DEL_{rootMOoP}$)

TABLE II. SELECTED OPTIMAL PARETO SOLUTIONS

Solution type	Parameters	
	K_p	K_i
Balanced	1.95×10^{-9}	1.03×10^{-11}
MinLoad	9.85×10^{-9}	1.18×10^{-10}
SmoothPitch	1.27×10^{-10}	1.02×10^{-11}

B. Performance Comparison

Based on the 300-second time-domain simulation data, a comparative analysis between the baseline CPC and the three optimized IPC strategies reveals a distinct set of engineering trade-offs, demonstrating how distinct optimization priorities lead to measurably different operational profiles for the floating offshore wind turbine, as shown in Fig. 4 - Fig. 7.




Fig. 4 Comparison of blade pitch angles under different control strategies




Fig. 5 Blade root out-of-plane bending moment responses under different control strategies




Fig. 6 Time history of platform pitch motion under different control strategies




Fig. 7 Generator power output under different control strategies

The blade pitch activity, shown in Fig. 4, serves as the primary indicator of controller effort. The baseline CPC trajectory demonstrates moderate variability (standard deviation $\sigma = 1.985^\circ$). In contrast, the optimized strategies exhibit distinctly different characteristics. The MinLoad controller initiates the most frequent and pronounced adjustments, corresponding to its substantially higher pitch rate standard deviation ($\sigma = 2.278^\circ$). Conversely, the SmoothPitch strategy produces a visibly smoother signal, with its variability only marginally increased above the baseline ($\sigma = 2.075^\circ$), directly reflecting its design objective. The Balanced strategy generates an intermediate profile, logically positioned between the other two IPC methods.

The direct impact of these actuation patterns is observed in the blade root load histories of Fig. 5. The baseline CPC produces the highest and most fluctuating blade-root out-of-plane moments ($\sigma = 8356.0 \text{ kN}\cdot\text{m}$). The MinLoad strategy achieves the most pronounced load suppression, reducing the load standard deviation by 39.9% to 5024.9 $\text{kN}\cdot\text{m}$ —a result clearly visible in its markedly lower and less variable moment trace. The SmoothPitch strategy delivers a more moderate but still meaningful 14.4% reduction in load variability, while the Balanced approach achieves a 24.3% reduction, positioning itself between the other two IPC strategies. These load reductions are a direct consequence of each strategy's pitch activity level: higher gains (MinLoad) enable more aggressive load counteraction, whereas lower gains (SmoothPitch) favor actuator smoothness at the expense of load mitigation.

The platform pitch responses, depicted in Fig. 6, demonstrate a secondary benefit of IPC. The baseline CPC yields a mean platform pitch of 1.739° with considerable oscillation, while the optimized IPC strategies all reduce the mean pitch angle. The most significant reduction (10.3%) is achieved by the MinLoad strategy, as its active compensation of asymmetric rotor loads more effectively counters disturbing moments. The Balanced and SmoothPitch strategies offer progressively smaller but still valuable improvements (4.2% and 2.1%, respectively) in platform stabilization. Furthermore, the restrained pitch activity of the SmoothPitch strategy inherently benefits actuator longevity.

Finally, Fig. 7 confirms that all strategies maintain nearly identical generator power profiles, with standard deviations differing by less than 0.3% from the baseline ($\sigma \approx 4264\text{--}4276 \text{ kW}$). This visual and numerical consistency

validates that the multi-objective optimization successfully decoupled power quality from the load-actuation trade-off, allowing the controller gains to be tuned exclusively for structural and actuation objectives.

In summary, the results delineate a clear spectrum of solutions defined by the selected controller gains. The MinLoad strategy resides at one extreme, delivering maximum load and platform motion reduction at the cost of high actuator duty. Conversely, the SmoothPitch strategy prioritizes the minimization of pitch actuator duty, thereby enhancing component longevity, while still providing discernible improvements in load mitigation and platform stability compared to CPC. The Balanced strategy represents a Pareto-optimal compromise within this trade-off space, securing substantial performance improvements with a relatively modest increase in control effort. Overall, the findings confirm that an IPC system, when appropriately tuned, enables the operator to prioritize specific operational objectives, with each optimized configuration demonstrating superior performance to conventional collective pitch control.

IV. CONCLUSION

This study has successfully addressed the critical challenge of parameter tuning for Individual Pitch Control (IPC) in floating offshore wind turbines by formulating and solving a dual-objective optimization problem. The core of the work involved applying the NSGA-II algorithm to find Pareto-optimal sets of the PI controller gains (K_p , K_i) that explicitly balance the conflicting objectives of blade root fatigue load reduction and pitch actuator duty minimization. The key finding confirms that optimized IPC universally and significantly outperforms standard collective pitch control. All optimized strategies dramatically reduced the dynamic fluctuation of the blade root out-of-plane bending moment (standard deviation reduced by 14.4% to 39.9%) and improved platform pitch stability, directly targeting the primary sources of structural fatigue in floating systems.

Future work may focus on validating these optimized gains under a broader set of turbulent wind and irregular wave conditions and exploring online adaptive mechanisms to maintain optimal performance across the turbine's entire operational envelope.

ACKNOWLEDGMENT

This work has been partially supported by the Spanish Ministry of Science and Innovation under the projects MCI/AEI/FEDER number PID2021-123543OB-C21 and PID2024-155653OB-C21.

REFERENCES

- [1] J. G. Njiri and D. Söffker, "State-of-the-art in wind turbine control: Trends and challenges," *Renew. Sustain. Energy Rev.*, vol. 60, pp. 377–393, July 2016, DOI: 10.1016/j.rser.2016.01.110.
- [2] D. Bai, B. Wang, Y. Li, and W. Wang, "Study on load reduction and vibration control strategies for semi-submersible offshore wind turbines," *Sci. Rep.*, vol. 15, p. 1148, Jan. 2025, DOI: 10.1038/s41598-025-85476-3.
- [3] H. Namik and K. Stol, "Individual blade pitch control of floating offshore wind turbines," *Wind Energy*, vol. 13, no. 1, pp. 74–85, 2010, DOI: 10.1002/we.332.
- [4] A. Eskandari, R. Vatankhah, and E. Azadi, "Optimization of wind energy extraction for variable speed wind turbines using fuzzy backstepping sliding mode control based on multi objective PSO," *Ocean Eng.*, vol. 285, p. 115378, Oct. 2023, DOI: 10.1016/j.oceaneng.2023.115378.
- [5] S.-J. Jiang, S.-C. Chu, F.-M. Zou, J. Shan, S.-G. Zheng, and J.-S. Pan, "A parallel Archimedes optimization algorithm based on Taguchi method for application in the control of variable pitch wind turbine," *Math. Comput. Simul.*, vol. 203, pp. 306–327, Jan. 2023, DOI: 10.1016/j.matcom.2022.06.027.
- [6] G. Li and T.-C. Chen, "Multi-objective mathematical model for optimal wind turbine placement in wind farm under uncertainty," *J. Eng. Res.*, vol. 13, no. 4, pp. 3249–3259, Dec. 2025, DOI: 10.1016/j.jer.2024.09.014.
- [7] L. Xiaoqing, D. Haiying, L. Hongwei, L. Mingxue, and S. Zhiqiang, "Optimization Control of Front-End Speed Regulation (FESR) Wind Turbine Based on Improved NSGA-II," *IEEE Access*, vol. 7, pp. 45583–45593, 2019, DOI: 10.1109/ACCESS.2019.2908995.
- [8] C. Allen *et al.*, "Definition of the UMaine VoltturnUS-S reference platform developed for the IEA wind 15-megawatt offshore reference wind turbine," National Renewable Energy Lab.(NREL), Golden, CO (United States); Univ. of ..., 2020. DOI: 10.2172/1660012.
- [9] K. Selvam, S. Kanev, J. W. van Wingerden, T. van Engelen, and M. Verhaegen, "Feedback-feedforward individual pitch control for wind turbine load reduction," *Int. J. Robust Nonlinear Control*, vol. 19, no. 1, pp. 72–91, 2009, DOI: 10.1002/rnc.1324.
- [10] C. Serrano, J.-E. Sierra-Garcia, and M. Santos, "Hybrid Optimized Fuzzy Pitch Controller of a Floating Wind Turbine with Fatigue Analysis," *J. Mar. Sci. Eng.*, vol. 10, no. 11, p. 1769, Nov. 2022, DOI: 10.3390/jmse10111769.
- [11] M. T. Todinov, "Necessary and sufficient condition for additivity in the sense of the Palmgren–Miner rule," *Comput. Mater. Sci.*, vol. 21, no. 1, pp. 101–110, May 2001, DOI: 10.1016/S0927-0256(00)00221-4.
- [12] F. Alonso Zotes and M. Santos Peñas, "Multi-criteria genetic optimisation of the manoeuvres of a two-stage launcher," *Inf. Sci.*, vol. 180, no. 6, pp. 896–910, Mar. 2010, DOI: 10.1016/j.ins.2009.11.001.
- [13] L. Ren *et al.*, "Mitigation of vibrations and its optimization in a large floating wind turbine across different typhoon stages," *Ocean Eng.*, vol. 330, p. 121287, June 2025, DOI: 10.1016/j.oceaneng.2025.121287.

Comparative Study of Generated Power and Fatigue in Floating Offshore Wind Turbines Using OpenFAST

Ignacio López

Dept. of Mechanics
University of Cordoba
Cordoba, Spain
p92lovii@uco.es

Juan Garrido

Dept. of Electrical Engineering and Automation
University of Cordoba
Cordoba, Spain
juan.garrido@uco.es

Manuel Lara

Dept. of Electrical Engineering and Automation
University of Cordoba
Cordoba, Spain
manuel.lara@uco.es

Francisco Vázquez

Dept. of Electrical Engineering and Automation
University of Cordoba
Cordoba, Spain
fvazquez@uco.es

Mario L. Ruz

Dept. of Mechanics
University of Cordoba
Cordoba, Spain
mario.ruz@uco.es

Abstract—This study comparatively analyzes the energy generation and structural loads of floating offshore wind systems under varying environmental conditions. The NREL (National Renewable Energy Laboratory) 5 MW reference wind turbine was modeled on a spar-buoy and a semi-submersible foundation at two future wind farm locations. The main tool employed in this work is OpenFAST, utilized alongside TurbSim and MLife. Results show that power generation is independent of the platform type at each of the considered locations. However, the fatigue analysis reveals that the tower base lifetime DEL (Damage Equivalent Load) is higher for the turbine installed on the spar-buoy platform, particularly in the fore-aft (or pitch) direction. Finally, the work establishes a replicable methodology for future performance and fatigue analyses, providing a solid basis for further research.

Index Terms—Floating wind turbines, OpenFAST, power generation, fatigue, lifetime DEL.

I. INTRODUCTION

The European Union (EU) has established the fight against climate change as a priority, aiming for a 55 % reduction in greenhouse gas emissions by 2030 and climate neutrality by 2050. Wind energy, especially offshore wind, is fundamental for this transition, with planned capacity increases from 12 GW to, at least, 60 GW in 2030 [1]. This requires exploiting deeper waters, as current fixed-bottom turbines are limited to depths below 60 meters [2]. Therefore, the shift to floating offshore wind turbines (FOWT) is critical for accessing greater wind potential.

The floating offshore wind strategy in Spain establishes a target of 1 to 3 GW by 2030 [3]. This objective drives the development of ambitious projects in high-potential areas like the Costa del Sol [4]. Two great examples are the “Neptuno” and “La Pinta” offshore wind farm projects. The first of these wind farms, situated between Cádiz and Málaga, is projected

to have a total capacity of 1005 MW and will consist of 67 turbines, each with a capacity of 15 MW [5]. The second, located in the waters off Granada and Almería, will have 55 wind turbines, each with a capacity of 18 MW, and an installed capacity of 990 MW [6].

The success of FOWT depends on achieving efficient energy extraction and structural durability in complex marine environments. Only in this way could the levelized cost of energy (LCOE) be minimized. This mandates advanced simulation to analyze the coupled dynamic response to wind and wave loads [7]. One way to make progress in this area is through applied research, using industrial tools with data from real projects.

In order to address the need for advanced simulation and contribute to design optimization, which is key to minimizing the LCOE of FOWT, the main objectives of this work are defined as follows:

- Compare floating wind systems to analyze energy generation and structural loads.
- Utilize the open-source software tools offered by the US National Research Energy Laboratory (NREL) to model FOWT and replicate metocean conditions.
- Deliver data-driven insights and recommendations that support the improved performance, reliability, and operational efficiency of future FOWTs.

To achieve these objectives and advance the field of FOWT analysis, this research provides several key contributions to the academic and industrial communities:

- A replicable framework with code is created to automate the generation and execution of simulations with realistic wind and wave data.
- The MLife source code is fixed to optimize fatigue analyses.

- Lifetime DEL (Damage Equivalent Load) of critical wind turbine components is presented, along with various Wöhler curve slopes (m), providing the basis for a real design.

These contributions offer immediate value by not only providing specific data points but also by establishing a robust, open-source methodology that can be rapidly adopted for future FOWT projects and academic research.

The remainder of this paper is structured to systematically present the investigation and its findings. Section II reviews related literature. Section III details the methodology, including the simulation environment and data handling. Section IV presents the main comparative results on generated power and fatigue. Section V provides a discussion of the results, interpreting the key findings and relating them back to the research objectives. Finally, Section VI offers conclusions and future work proposals.

II. LITERATURE REVIEW

The objectives and methodology of this study are substantially supported by prior academic research and international standards, focusing on simulation fidelity and structural analysis for FOWTs.

The UNE-EN IEC 61400-3-2 standard [8] specifies the technical requirements for the design of floating offshore wind turbines. This standard mandate a coupled aero-hydro-elastic analysis and the definition of Design Load Cases (DLCs), among other things. Meeting its guidelines ensures the integrity of the floating system. The simulation methodology used in this work, like the effective simulation time or the environmental characterization via the long-term joint probability distribution of the site-specific parameters, is aligned with the methodological and statistical requirements set forth by this international standard.

The viability and reliability of using OpenFAST for FOWT simulations was rigorously investigated in [9]. This work analyzed the NREL 5 MW reference wind turbine under varying wind and wave conditions, with a focus on platform pitch motions. The results demonstrated OpenFAST's fidelity, aligning satisfactorily with both Computational Fluid Dynamics (CFD) methods and various experimental test data.

Various studies have explored the optimization of offshore wind turbines. Ghigo et al. [10] developed a multi-objective framework to identify platform designs that minimize material costs while ensuring stability and floatability. Similarly, Lara et al. [11] utilized an automated co-simulation environment in MATLAB/Simulink and OpenFAST to optimize adaptive individual pitch controllers (IPC) for a 15 MW turbine. Using genetic algorithms to minimize the blade damage equivalent load, they demonstrated that incorporating static inverted decoupling into the IPC significantly reduces fatigue loads without increasing actuator effort.

More recently, in [12], a study was conducted to investigate a 5 MW semi-submersible floating wind turbine, aiming to provide comprehensive analysis of fatigue loads on critical

components and platform motion under various power regulation modes. To achieve this objective, the authors employed the NREL open-source software tools and models. Their findings provide critical insights for optimizing floating turbine operation to mitigate structural wear. As future studies, it is proposed to explore the long-term behavior of FOWT, particularly focusing on lifetime DELs.

III. METHODOLOGY

This comparative study systematically models and simulates FOWT performance under site-specific ambient conditions. The main aspects of the study are discussed below.

A. Wind Turbine Model

The core component is the NREL 5 MW reference wind turbine [13]. This three-bladed, upwind turbine features variable speed and collective pitch control (pitch-to-feather). Two floating platforms compatible with this turbine were modeled in the simulations:

- Spar-buoy: OC3 Hywind system, relying on ballast for pitch restoration [14].
- Semi-submersible: OC4 DeepCwind Semi, which uses a combination of mooring, buoyancy and ballast [15].

Among foundation concepts, semi-submersible and spar-buoy technologies are the most mature with a technology readiness level (TRL) of 8-9 [16]. These platform types are represented in Fig. 1.




Fig. 1. Foundation concepts: (a) Spar-buoy, (b) Semi-submersible.

B. Data Acquisition and Manipulation

The metocean database for the La Pinta and Neptuno sites was acquired using PORTUS [17], which provides SIMAR series [18]. The SIMAR dataset consists of time series of wind and wave parameters from numerical modeling. They are simulated data, and therefore, do not come from direct measurements in nature. A 20-year time series, covering the

period from 2004 to 2024, was downloaded to match the expected design life of wind energy systems [19].

Defining the operational environmental states required calculating the long-term joint probability distribution of the following parameters:

- Mean wind speed at hub-height (U_{90})
- Significant wave height (H_s)
- Peak spectral period (T_p)

This calculation was executed in full compliance with the requirements set forth in the UNE-EN IEC 61400-3-2 standard. The discretization bins were set at 2 m/s for U_{90} , 1 m for H_s , and 1 s for T_p . The resolution of this joint probability distribution is slightly higher than the standard's strictest requirements. It was implemented to efficiently manage the demanding computational load and simulation time. Preliminary sensitivity studies, comparing both resolutions, were carried out to validate this decision, confirming that the resulting fatigue damage showed only a marginal and acceptable sub-estimation, which ensures the long-term analysis remains reliable while saving computational resources.

Additionally, for each study location, wind and wave roses were generated (see Fig. 2) to illustrate the directionality and frequency of these environmental parameters. Based on this, the assumption of co-directionality of wind and waves was adopted because preliminary site analysis indicated no significant misalignments between the two factors, a condition deemed acceptable according to the UNE-EN IEC 61400-3-2 standard.

C. TurbSim

TurbSim was used as a pre-processor to generate binary turbulent wind fields. Each set of ambient conditions defined by the long-term joint probability distribution requires a unique turbulent wind field. To program this software, the TurbSim Quick-Start Guidelines for IEC Turbulence [14] were used.

D. OpenFAST Simulation

The simulation process was automated using custom MATLAB scripts to generate and execute various simulation cases in parallel, optimizing hardware resource utilization. Each simulation lasted 3700 s (3600 s of effective data after suppressing 100 s of transients). The analysis included two main operational modes:

- Normal Operation ($V_{in} < V < V_{out}$): the turbine is actively spinning and generating power.
- Idling ($V < V_{in}$ or $V > V_{out}$): the wind turbine is “shut down” and the blades are feathered, but waves continue to induce fatigue damage.

A systematic and methodical approach was essential during the simulation process due to the significant volume of data requiring management. To maintain organization and clarity, the case study structure was formalized: for each study location, two top-level directories were established, one corresponding to each platform type. Within these primary directories, two subsequent sub-directories were created, aligning with the two designated operational modes.




Fig. 2. Environmental data for La Pinta site: (a) Wind rose showing direction and speed (m/s) distribution, and (b) Wave rose showing significant wave height (m) and direction distribution.

The main MATLAB code was designed for efficiency and to be high parametrizable, utilizing relative path definitions to easily control access and management across all directories. The primary function of this script was to automate the creation of a dedicated folder for each combination of metocean conditions defined by the joint probability distribution. Within each folder, the script used TurbSim to generate the corresponding wind field, adjusted necessary relative paths and simulation parameters according to the metocean data, and finally generated a batch file. Subsequently, a secondary script was employed to launch these batch files in parallel, significantly optimizing the processing time. This comprehensive simulation campaign involved approximately 150 hours of computation, generating a substantial dataset totaling over 850 GB.

E. MLife

MLife is a MATLAB-based post-processor, and it was used to calculate statistics of the generated power and evaluate structural fatigue using the Rainflow counting method.

The lifetime DEL, for a design life of 20 years, of the tower base and blades root, in the X, Y and Z directions, was

calculated. Among the parameters needed to be specified in the MLife input file, the ultimate load (LUlt) is the highest load that the cross section of the studied component can withstand before failure. Ideally, the LUlt would be based on a finite element analysis (FEA) of the component, or on data specified for the NREL 5MW. However, as no FEA model or data are available [22], a general approach was used for the calculations and a DEL type with zero mean load and no Goodman correction was assumed. Additionally, different Wöhler curve slopes for the tower and blades were considered, following the recommendations in [23].

To optimize storage and efficiency, output files were generated in binary format. However, the standard MLife implementation encountered difficulties managing these files, despite being a documented feature [21]. To resolve this, the MLife source code was modified during this research to ensure robust handling of large datasets. These enhancements were shared via the NREL Official Forum.

IV. RESULTS

The generated power and the structural fatigue response of the wind turbine are studied collectively to fully evaluate the system's energy performance and quantify the mechanical stress imposed on primary structural components.

A. Generated Power

The power duration curve for an average year was calculated. It is shown in Fig. 3, and jointly analyzes the energy performance of the NREL 5 MW turbine mounted on both the spar-buoy and semi-submersible platforms across the Neptuno and La Pinta sites. Operationally, the turbine achieves a high utilization rate, running for approximately 7,500 to 8,000 hours annually, with roughly 1,000 to 1,500 hours at rated power. Specifically, Neptuno yields 7,961 hours of total operation (1,135 hours at rated power), while La Pinta yields 7,589 total hours (1,450 hours at rated power).

A deeper analysis of the power duration curves allows for the extraction of two key performance parameters. First, the annual energy production (AEP) is directly quantified by calculating the area under the power duration curve. Second, using this calculated AEP value, the capacity factor (C_f) is determined using the following formula:

$$C_f = \frac{\text{AEP}}{P_{\text{rated}} \times 8760} \quad (1)$$

where P_{rated} is the rated capacity of the turbine (5 MW) and 8760 represents the total hours in a non-leap year. The resulting AEP and capacity factor values for all platform and location combinations are summarized in Table I.

B. Fatigue Analysis

The lifetime DEL, based on a 20-year design life, was determined for the tower base and blade root in the X, Y, and Z directions. The results are shown in Fig. 4. At the tower base, the moments M_x , M_y , and M_z correspond to the side-to-side ($TwrBsMxt$), fore-aft ($TwrBsMyt$), and




Fig. 3. Comparison of the generated power in both sites: (a) La Pinta's power duration curves, and (b) Neptuno's power duration curves.

TABLE I
AVERAGE ANNUAL PRODUCTION AND CAPACITY FACTOR FOR EACH PLATFORM IN THE PARKS UNDER STUDY

Platform type	Project	AEP (GWh)	C_f (%)
Spar-buoy	La Pinta	14,15	32,3
Semi-submersible	La Pinta	14,20	32,4
Spar-buoy	Neptuno	13,90	31,7
Semi-submersible	Neptuno	14,01	32,0

torsion ($TwrBsMzt$) directions, respectively. Similarly, at the blade root (for blade 1), the moments $RootMxc1$, $RootMyc1$, and $RootMzc1$ represent the edge-wise (M_x), flap-wise (M_y), and torsion (M_z) moments, respectively. This specific nomenclature, which follows the OpenFAST convention [24], enables the precise evaluation of the fatigue loads affecting both the tower and the blades.

The structural fatigue assessment utilizes the Wöhler exponent, a crucial variable defining the relationship between load cycles and material life. While typical assumptions are $m = 3$ for the steel tower and $m = 10$ for the composite blade materials, a comprehensive parametric study was conducted to account for the inherent material uncertainty, as detailed in Section III-E. Consequently, three distinct m values were programmed for each material type: $m = 3, 4, 5$ for the tower steel and $m = 8, 10, 12$ for the blade composites. This robust parametric approach ensures the validity of the fatigue analysis and provides a more realistic basis for predicting structural wear by encompassing material variability.

To facilitate a direct comparison of the lifetime DELs between the two study locations, Table II presents the relative percentage increase for each analyzed variable across the




Fig. 4. Comparison of the lifetime DEL at the tower base and blade root for the La Pinta (a,b) and Neptuno (c,d) sites.

TABLE II
RELATIVE INCREASE (IN %) OF THE LIFETIME DEL BETWEEN SITES

m	3	4	5	8	10	12
RootMxc1				0,515 0,342	0,650 0,649	0,627 0,782
RootMyc1				1,050 3,947	0,222 4,415	0,000 4,651
RootMzc1				-0,755 -0,546	0,000 -0,990	-0,901 0,000
TwrBsMxt	6,366 -2,187	6,782 -2,147	7,513 -2,023			
TwrBsMyt	4,969 3,521	4,147 4,278	3,309 4,762			
TwrBsMzt	4,908 4,819	5,584 5,941	5,983 6,276			

Note: Spar-buoy = black; Semi-submersible = blue

designated Wöhler exponent (m) values. La Pinta is defined as the reference site for this calculation. Consequently, positive percentages indicate a higher lifetime DEL at the La Pinta site, while negative percentages signify a higher load at the alternative site (Neptuno).

V. DISCUSSION

The analysis of the power duration curve demonstrates that the annual energy production exhibits two key trends.

First, the La Pinta site yields a marginally higher average AEP when compared to the Neptuno location. Second, the use of the semi-submersible platform consistently results in a slight increase in generated energy across both wind farm locations compared to the spar-buoy design. These minor differences highlight that while the semi-submersible offers a slight energetic advantage, the platforms' overall performance is highly similar, necessitating the use of structural metrics for comprehensive comparative evaluation. The C_f values provide the most intuitive understanding of these insights, and furthermore, they are aligned with the expected values described in [26].

In the graphics shown in Fig. 4, it is possible to compare each lifetime DEL only with others that have the same Wöhler exponent. The results are pretty similar for the blades, but for the tower there is a significant difference when comparing the *TwrBsMyt*. It reveals to be higher in the spar-buoy platform. Hence, the semi-submersible platform offers an advantage, as its lower lifetime DEL, associated with the pitch movement of the platform, would ultimately extend the operational life of the turbine compared to the spar-buoy design.

The findings summarized in Table II highlight a growing challenge in industry: the conventional practice of designing wind turbines by simply scaling existing geometries based on general requirements. This methodology, which often leads to overestimated turbine properties, results in unnecessary project overheads and increased LCOE. This study clearly

demonstrates that a single turbine model experiences significantly different structural solicitations depending on both the chosen floating platform and the specific geographical location. While this outcome may seem logical, industrial design practices frequently neglect this contextual variability, leading to avoidable over design costs. The observed differences between the Neptuno and La Pinta sites underscore the necessity of adopting sophisticated techniques, such as customized geometry design for each unique wind farm, to ensure optimal adaptation and enhance the accessibility of floating offshore wind energy. This topic is comprehensively studied in [25].

VI. CONCLUSIONS AND FUTURE WORK

In this paper, the NREL open-source software tools were used to study the generated power and structural fatigue in key components of the 5 MW wind turbine. It is necessary to clarify that the simulations consider only one wind turbine per farm, and consequently, wake effects are not included in the present analysis. The research plan fulfilled the proposed objectives and delivered data-driven insights.

- The generated power of the reference turbine was studied across two wind farm sites and installed on two models of floating platforms. In both wind farms, the generated power was independent of the type of platform used.
- The lifetime DEL was studied for the bending and torsional moment at the tower base and the blade root. The results were very similar for both platforms, with the exception that the lifetime DEL due to the fore-aft movement (or pitch) was greater in the spar-buoy platform.

Future work is intended to complement the current results with an economic study. Furthermore, it is of interest to repeat the simulations using different control strategies, as individual pitch control, to identify the most optimal combination of controller and platform. Also, the use of Physics Informed Neural Networks (PINNs) is being studied to improve data efficiency and achieve predictions that are both accurate and inherently physically consistent.

ACKNOWLEDGMENT

This research was funded by the Spanish Ministry of Science, Innovation and Universities (MCIU/AEI/10.13039/501100011033/FEDER, UE), grant number PID2023-149181OB-I00.

REFERENCES

- [1] European Commission, "Meeting the EU's ambitions for marine renewable energy," European Commission, Brussels, Oct. 2023. Available: <https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=COM:2020:741:FIN&qid=1605792629666..>
- [2] W. Musial, S. Butterfield, and B. Ram, "Energy from Offshore Wind: Preprint," National Renewable Energy Laboratory (NREL), 2006. Available: <http://www.osti.gov/bridge>.
- [3] MITECO, "Roadmap for offshore wind and marine energy in Spain," Ministry for Ecological Transition and Demographic Challenge, Madrid, Dec. 2021.
- [4] MITECO, "Maritime Space Management Plans," Ministry for Ecological Transition and Demographic Challenge, Feb. 2023.
- [5] S. Sánchez, "The Costa del Sol is closer to having a large offshore wind farm: it will have 67 turbines and 1,005 megawatts," *El Español*, Oct. 2023.
- [6] I. Nieto, R. Campaña, and E. Martínez, "IberBlue Wind plans its second floating wind farm off the coast of Andalusia," *IberBlue Wind*, Apr. 2023.
- [7] P. Veers, C. L. Bottasso, L. Manuel, J. Naughton, L. Pao, J. Paquette, and others, "Grand challenges in the design, manufacture, and operation of future wind turbine systems," *Wind Energy Science*, vol. 8, no. 7, pp. 1071–1131, Jul. 2023. doi: 10.5194/wes-8-1071-2023.
- [8] International Electrotechnical Commission, "Wind energy generation systems-Part 3-2: Design requirements for floating offshore wind turbines (IEC 61400-3-2:2025)," European Committee for Electrotechnical Standardization (CENELEC), 2025. Available: <https://www.cenelec.eu/>.
- [9] C. Morini, "Investigation of the Dynamic Models of OpenFAST for the Simulation of Floating Offshore Wind Turbines under Platform Motion," Politecnico Milano, 2023.
- [10] A. Ghigo, L. Cottura, R. Caradonna, G. Bracco, and G. Mattiazzo, "Platform optimization and cost analysis in a floating offshore wind farm," *Journal of Marine Science and Engineering*, vol. 8, no. 11, pp. 1–26, Nov. 2020. doi: 10.3390/jmse8110835.
- [11] M. Lara, M. L. Ruz, S. P. Mulders, F. Vázquez, and J. Garrido, "Individual pitch controller with static inverted decoupling for periodic blade load reduction on monopile offshore wind turbines," *Ocean Engineering*, vol. 334, p. 121608, Aug. 2025. doi: 10.1016/j.oceaneng.2025.121608.
- [12] X. Yuan, D. Song, S. Chen, J. Yang, M. Dong, R. Wei, *et al.*, "Deep analysis of power regulation on fatigue loads and platform motion in floating wind turbines," *Ocean Engineering*, vol. 313, Dec. 2024. doi: 10.1016/j.oceaneng.2024.119667.
- [13] J. Jonkman, S. Butterfield, W. Musial, and G. Scott, "Definition of a 5-MW Reference Wind Turbine for Offshore System Development," National Renewable Energy Laboratory (NREL), 2009. Available: <http://www.osti.gov/bridge>.
- [14] J. Jonkman, "Definition of the Floating System for Phase IV of OC3," National Renewable Energy Laboratory (NREL), May 2010. Available: <http://www.osti.gov/bridge>.
- [15] A. Robertson, J. Jonkman, M. Masciola, H. Song, A. Goupee, A. Coulling, *et al.*, "Definition of the Semisubmersible Floating System for Phase II of OC4," National Renewable Energy Laboratory, Sep. 2014. Available: www.nrel.gov/publications..
- [16] IRENA, "FLOATING OFFSHORE WIND OUTLOOK," International Renewable Energy Agency, Abu Dhabi, 2024. ISBN: 978-92-9260-612-1. Available: www.irena.org.
- [17] Puertos del Estado, "PORTUS," 2021. [Online]. Available: <https://puertos.puertos.es/#/>.
- [18] Puertos del Estado, "CONJUNTO DE DATOS SIMAR," Ministry of Transport and Sustainable Mobility, Jun. 2024.
- [19] J. F. Manwell, J. G. McGowan, and A. L. Rogers, *Wind Energy Explained: Theory, Design and Application*, 2nd ed. Wiley, pp. 43–47, 2010.
- [20] B. J. Jonkman, "TurbSim User's Guide v2.00.00," National Renewable Energy Laboratory (NREL), Oct. 2014. Available: www.nrel.gov/publications..
- [21] G. J. Hayman and M. Buhl, "MLife User's Guide," Northeast Wisconsin Technical College (NWTC), 2012. Available: <http://www.osti.gov/bridge>.
- [22] I. B. Løken and A. Kaynia, "Dynamic Response and Fatigue of Offshore Wind Turbines," Norwegian University of Science and Technology, Jun. 2017.
- [23] D. Matha, J. Jonkman, and T. Fischer, "Model Development and Loads Analysis of an Offshore Wind Turbine on a Tension Leg Platform, with a Comparison to Other Floating Turbine Concepts," University of Colorado, Boulder, Apr. 2009. Available: <http://www.osti.gov/bridge>.
- [24] J. M. Jonkman and M. L. Buhl, "FAST User's Guide," NREL, Aug. 2005. Available: <http://wind.nrel.gov/designcodes/simulators/fast/FAST.pdf>.
- [25] P. J. Rohrer, E. E. Bachynski-Polić, and J. M. Hegseth, "Gradient-based design optimization of semi-submersible floating wind turbines," *Marine Structures*, vol. 106, Jan. 2026. doi: 10.1016/j.marstruc.2025.103951.
- [26] E. Faraggiana, A. Ghigo, M. Sirigu, E. Petracca, G. Giorgi, G. Mattiazzo, *et al.*, "Floating offshore wind potential for Mediterranean countries," *Heliyon*, vol. 10, no. 13, Jul. 2024. doi: 10.1016/j.heliyon.2024.e33948.

Investigación preliminar sobre redes convolucionales temporales para la predicción de energía eólica

Mario Peñacoba Yagüe
Department of Digitalization
University of Burgos Burgos,
Spain mpenacoba@ubu.es

Jesús Enrique Sierra García
Department of Digitalization
University of Burgos Burgos,
Spain jesierra@ubu.es

Matilde Santos-Peñas
Institute of Knowledge Technology
University Complutense of Madrid
Madrid, Spain
msantos@ucm.es

Resumen— La creciente integración de energías renovables en los sistemas eléctricos exige herramientas de predicción precisas y eficientes para anticipar la variabilidad meteorológica. En este contexto, la predicción a corto plazo de potencia eólica es clave para mejorar la planificación energética, la estabilidad de la red y la operación de turbinas. Este trabajo presenta un primer enfoque basado exclusivamente en Redes Temporales Convolucionales (TCN) para el pronóstico de potencia eólica a partir de datos reales de SCADA. Se evalúa el desempeño del modelo bajo distintas configuraciones de variables meteorológicas, empleando métricas como MAE, RMSE y R^2 , así como su idoneidad para aplicaciones en tiempo real mediante indicadores de eficiencia computacional. Los resultados muestran que el TCN reproduce con alta fidelidad el comportamiento dinámico de la turbina y mantiene una velocidad de inferencia superior a 3.000 predicciones por segundo, lo que evidencia su potencial para integrarse en aplicaciones de *edge computing* y plataformas de baja latencia. Este primer enfoque constituye una base sólida para futuros desarrollos orientados a mejorar la precisión, robustez y escalabilidad de modelos de predicción eólica en entornos distribuidos.

Palabras clave—Pronóstico de Potencia Eólica, Energías Renovables, Redes Temporales Convolucionales (TCN), Hardware de Bajo Coste, Gestión Energética.

Abstract— The increasing penetration of renewable energy in power systems demands prediction tools that are both highly accurate and computationally efficient, capable of anticipating the inherent variability of meteorological resources. In this context, short-term wind power forecasting plays a critical role in enhancing energy planning, strengthening grid stability, and optimizing turbine operation. This work presents an initial approach based solely on Temporal Convolutional Networks (TCN) for wind power forecasting using real SCADA data. The model's performance is assessed under different configurations of meteorological variables, using metrics such as MAE, RMSE, and R^2 , as well as indicators of computational efficiency to evaluate its suitability for real-time applications. Results show that the TCN can reproduce the turbine's dynamic behavior with high fidelity and sustain an inference rate above 3,000 predictions per second, demonstrating its potential for deployment in edge-computing environments and low-latency platforms. Overall, this first TCN-based approach provides a solid foundation for future developments aimed at improving the accuracy, robustness, and deployability of wind power forecasting models in distributed systems.

Keywords—Wind Power Forecasting, Renewable Energy, Temporal Convolutional Networks (TCN), Low-Cost Hardware, Energy Management.

I. INTRODUCTION

La transición hacia sistemas energéticos sostenibles ha intensificado la necesidad de reducir emisiones y aumentar la participación renovable. Entre estas, la energía eólica destaca por su madurez tecnológica y contribución a la descarbonización (Behera et al., 2025), aunque su intermitencia sigue planteando desafíos para la integración en red y la operación fiable. Por ello, la predicción a corto plazo de potencia eólica es esencial tanto en parques de gran escala como en sistemas distribuidos (Liu et al., 2025). Anticipar cambios rápidos en el viento mejora la planificación, optimiza reservas, reduce costes y refuerza la estabilidad del sistema. Además, la creciente adopción de turbinas domésticas o de bajo coste requiere modelos de alta precisión y baja demanda computacional, aptos para dispositivos embebidos y entornos de *edge computing* (Serrano et al., 2022; Sierra-García & Santos, 2024).

En este marco, las Redes Temporales Convolucionales (TCN) han emergido como una alternativa eficaz para modelar series temporales, aprovechando convoluciones causales y dilatadas que capturan dependencias sin los cuellos de botella de arquitecturas secuenciales. Su paralelización y estabilidad las hacen idóneas para predicción en tiempo real y hardware con recursos limitados (Wu et al., 2022).

Este trabajo evalúa modelos TCN aplicados a datos SCADA de un aerogenerador, considerando cuatro combinaciones de variables de entrada —Curva Teórica de Potencia, velocidad y dirección del viento— para analizar su impacto en la precisión y eficiencia computacional. Se utilizan métricas de error (MAE, RMSE, R^2) y de rendimiento en tiempo real, como predicciones por segundo y tiempo de inferencia.

Los resultados muestran que las TCN logran alta precisión y más de 3.000 predicciones por segundo, demostrando su idoneidad para aplicaciones de baja latencia y su integración en plataformas de *edge computing* o hardware económico.

El artículo se estructura en: Sección 2 (datos y modelo), Sección 3 (metodología), Sección 4 (resultados), Sección 5 (discusión) y Sección 6 (conclusiones y líneas futuras).

II. ARQUITECTURA DE LA RED TCN

Las Redes Temporales Convolucionales (TCN) son arquitecturas de aprendizaje profundo diseñadas específicamente para el modelado de secuencias mediante convoluciones causales y dilatadas. A diferencia de las

arquitecturas recurrentes, las TCN evitan el procesamiento secuencial y se basan exclusivamente en operaciones convolucionales, lo que les permite capturar dependencias temporales de largo alcance manteniendo una elevada eficiencia computacional (Telicko et al., 2025). Su estructura paralela, junto con campos receptivos que crecen exponencialmente gracias a la dilatación, las convierte en una opción especialmente adecuada para tareas de predicción en tiempo real y para entornos de “edge computing”.

La arquitectura TCN implementada en este trabajo para la predicción de potencia eólica está compuesta por los siguientes elementos:

I. Capa de Entrada:

La secuencia de entrada, formada por combinaciones de Curva Teórica de Potencia (TPC), Dirección del Viento (WD) y Velocidad del Viento (WS), se introduce en el modelo como una serie temporal multivariante.

II. Bloques de Convolución Causal Dilatada:

El núcleo de la red está formado por una pila de bloques convolucionales, cada uno de los cuales incluye:

- Convoluciones causales 1D, que garantizan que las predicciones en el instante t dependan únicamente de los valores presentes y pasados.
- Convoluciones dilatadas, que amplían exponencialmente el campo receptivo y permiten al modelo incorporar información temporal de largo alcance sin necesidad de capas recurrentes profundas.
- Conexiones residuales, que estabilizan el entrenamiento y facilitan el flujo del gradiente a través de la red.
- Capas de “dropout”, aplicadas dentro de cada bloque para reducir el sobreajuste desactivando aleatoriamente filtros durante el entrenamiento.

Cada bloque convolucional emplea 64 filtros, un tamaño de kernel de 3, y factores de dilatación que aumentan en potencias de dos a lo largo de las capas apiladas (1, 2, 4, 8...). Esta configuración permite al modelo aprender patrones temporales a distintas escalas presentes en los datos SCADA.

III. Capa Totalmente Conectada:

La salida del último bloque convolucional se aplanan (“flatten”) y se introduce en una capa densa con una única unidad. Esta capa agrega las características temporales extraídas por la TCN y produce el valor final de potencia predicha.

IV. Capa de Salida:

La salida final corresponde a la potencia del aerogenerador predicha para el último instante de la secuencia de entrada.

Una representación esquemática de la arquitectura TCN utilizada en este trabajo se muestra en la Fig. 1 (Zuo et al., 2023).




Fig. 1. Esquema de la arquitectura Temporal Convolutional Network.

III. ENTRENAMIENTO DEL MODELO

Esta sección describe el conjunto de datos empleado en los experimentos, las etapas de preprocesamiento realizadas antes del entrenamiento y la estrategia seguida para preparar el modelo TCN. Todos los experimentos utilizan el mismo conjunto de datos procedente de un aerogenerador con el fin de garantizar una evaluación justa y consistente.

A. Dataset

Los datos utilizados en este estudio proceden de un sistema SCADA (“Supervisory Control and Data Acquisition”) instalado en un aerogenerador en operación. Las medidas se registran a intervalos de 10 minutos y proporcionan una descripción detallada de las condiciones ambientales y de las variables de salida de la turbina. Este conjunto de datos, obtenido de una turbina ubicada en Turquía, ha sido empleado previamente en investigaciones sobre predicción de potencia eólica mediante técnicas de “machine learning”, y se utiliza con frecuencia como referencia (“benchmark”) en la evaluación de modelos predictivos basados en datos (Buestán Andrade et al., 2024).

El conjunto de datos incluye las siguientes variables:

- Tiempo de muestreo: Instante de muestreo, registrado cada 10 minutos.
- Potencia Activa (kW): Potencia eléctrica real generada por la turbina en cada instante. Esta variable se utiliza como señal objetivo (“ground truth”) para el entrenamiento del modelo de predicción.
- Velocidad del Viento (m/s): Velocidad del viento medida a la altura del buje, que influye directamente en la energía cinética disponible para su conversión en energía eléctrica.
- Curva Teórica de Potencia (kWh): Estimación ideal de la potencia generada según el modelo del fabricante, empleada como referencia del rendimiento esperado en condiciones aerodinámicas ideales.
- Dirección del Viento (°): Dirección acimutal del viento incidente, relevante para el control de “yaw” y la eficiencia en la captura de energía.

Estas cinco señales constituyen la base para la construcción de las distintas configuraciones de entrada evaluadas en este trabajo.

B. Pre-procesado

Antes del entrenamiento, el conjunto de datos fue sometido a una serie de pasos de preprocesamiento destinados a estandarizar las variables de entrada y garantizar que el modelo recibiera una representación consistente de los datos. Con el fin de analizar de manera sistemática la influencia de diferentes combinaciones de características, se implementó una función específica para generar los cuatro escenarios evaluados en este estudio: TPC–WD, TPC–WS, WD–WS y TPC–WD–WS.

Siguiendo las prácticas habituales en la predicción de potencia eólica y estudios previos basados en este mismo conjunto de datos, todas las variables fueron normalizadas mediante estandarización. Cada característica se transformó restando su media y dividiéndola por su desviación estándar, asegurando así que todos los canales de entrada compartieran una escala comparable y facilitando la convergencia del modelo durante el entrenamiento.

Posteriormente, el conjunto de datos completo se dividió en tres subconjuntos:

- 70% para el entrenamiento del modelo,
- 20% para validación y ajuste de hiperparámetros, y
- 10% para la fase de prueba y evaluación final del rendimiento.

Esta partición garantiza que el modelo sea evaluado con muestras no utilizadas durante el entrenamiento, al tiempo que se conserva una cantidad suficiente de datos para los procesos de optimización y análisis de generalización.

IV. EXPERIMENTAL SET UP

A. Hardware

Todos los experimentos se ejecutaron en un ordenador portátil Dell Vostro 5410, seleccionado como plataforma de hardware de gama media con el fin de evaluar el rendimiento computacional del modelo TCN en condiciones realistas. El equipo está equipado con un procesador Intel Core i7 de 8.^a generación, 8 GB de memoria RAM y funciona bajo el sistema operativo Windows (Peñacoba et al., 2025). Con un precio de mercado aproximado de 700 EUR (dentro de un rango típico de 300–1000 EUR), este dispositivo representa un entorno de cómputo estándar y ampliamente accesible, que ofrece mayores recursos que un sistema empujado de bajo coste, pero sin llegar a las capacidades de estaciones de trabajo o servidores de alto rendimiento.

La elección de este hardware permite analizar la velocidad de inferencia del modelo TCN en un entorno representativo de estaciones de trabajo personales o industriales, garantizando que la evaluación sea relevante para aplicaciones reales donde las restricciones computacionales pueden condicionar la viabilidad del pronóstico en tiempo real.

B. Software

El desarrollo y entrenamiento del modelo TCN se realizaron en un entorno software basado en Python. La arquitectura se implementó utilizando TensorFlow y Keras, que proporcionan herramientas optimizadas para la construcción de modelos de aprendizaje profundo y la gestión

del proceso de entrenamiento. Las capas convolucionales, las convoluciones dilatadas y las conexiones residuales del TCN se implementaron mediante la API de alto nivel de Keras.

El manejo de datos y la normalización se llevaron a cabo utilizando Scikit-learn, y todos los experimentos se ejecutaron con Python 3.11. El uso de librerías abiertas y estándar asegura la reproducibilidad total del estudio y facilita futuras ampliaciones o comparaciones.

Para mejorar la estabilidad durante el entrenamiento, el modelo empleó el optimizador Adam, regularización mediante “dropout” y una estrategia de “early stopping” basada en la pérdida de validación. Todo el código se ejecutó en un entorno unificado para asegurar consistencia en la evaluación del rendimiento del modelo durante el entrenamiento y la inferencia.

C. Métricas

En este estudio se consideraron dos categorías de métricas: precisión de las previsiones y rendimiento computacional (Peñacoba et al, 2024).

a) Métricas de Precisión

Para evaluar la calidad predictiva del modelo, se calcularon los siguientes indicadores:

I. Error Absoluto Medio (MAE):

Refleja la magnitud media de las desviaciones entre los valores reales y los valores predichos (Ecuación 1):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i| \quad (1)$$

II. Raíz del Error Cuadrático Medio (RMSE):

Hace hincapié en los errores de mayor magnitud al calcular la raíz cuadrada de la media de los errores al cuadrado (Ecuación 2):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2)$$

III. Coeficiente de Determinación (R²):

Mide la proporción de la varianza de la señal real que es explicada por el modelo (Ecuación 3):

$$R^2 = 1 - \frac{\sum (y_i - \bar{y})^2}{(y_i - \bar{y}_i)^2} \quad (3)$$

b) Métricas del rendimiento computacional

Con el fin de analizar la idoneidad del modelo para aplicaciones en tiempo real, se midieron dos indicadores clave:

I. Predicciones por segundo:

Número de operaciones de predicción que el modelo puede realizar en un segundo, calculado a partir de la duración de cada lote (*batch*) de inferencia.

II. Tiempo de inferencia por muestra:

Tiempo medio necesario para generar una única predicción.

Dado un tiempo de inferencia T_i para un lote de tamaño fijo N_{batch} , el número de predicciones por segundo se calcula según la Ecuación 4.

$$Predictions = \frac{N_{batch}}{T_i} \quad (4)$$

El rendimiento global a lo largo de múltiples repeticiones se obtiene promediando los resultados de todos los lotes (Ecuación 5).

$$\overline{Predictions} = \frac{1}{N_{batch}} \sum_{i=1}^{N_{batch}} Predictions(i) \quad (5)$$

Estos indicadores proporcionan información detallada sobre la eficiencia computacional del modelo TCN y ofrecen una perspectiva práctica sobre su aplicabilidad en tareas de predicción de potencia eólica en tiempo real.

V. RESULTADOS

a) Exactitud de predicción en todos los escenarios de entrada

La Tabla 1 resume las métricas de precisión obtenidas para la arquitectura TCN bajo las cuatro configuraciones de variables de entrada evaluadas. Los resultados evidencian que la capacidad predictiva del modelo depende de forma notable del conjunto de características utilizado, ya que las métricas de error muestran variaciones significativas entre escenarios. No obstante, en todos los casos el TCN mantiene un rendimiento consistente y valores de error dentro de rangos considerados satisfactorios para la predicción de potencia eólica.

TABLE I. MÉTRICAS DE RENDIMIENTO DEL MODELO TCN

Escenario	MAE	RMSE	R^2
TPC-WD	0.0499	0.080	0.9608
TPC-WS	0.0605	0.0926	0.9478
WD-WS	0.0598	0.0936	0.9467
TPC-WD-WS	0.0481	0.0785	0.9626

En el escenario TPC-WD, el modelo TCN alcanza uno de sus mejores niveles de exactitud, con un MAE de 0.0499 y un RMSE de 0.0800, acompañado de un coeficiente $R^2 = 0.9608$, lo que indica una elevada capacidad para capturar patrones donde la dirección del viento desempeña un papel relevante.

Por el contrario, en los escenarios TPC-WS y WD-WS, el rendimiento disminuye ligeramente. Ambos presentan MAE cercanos a 0.06 y RMSE alrededor de 0.093, con valores de R^2 en el rango 0.946–0.948, lo que sugiere que, cuando las dependencias temporales están gobernadas principalmente por la velocidad del viento, el modelo requiere mayor complejidad para representar adecuadamente la dinámica subyacente.

Finalmente, cuando se emplea el conjunto completo de variables (TPC-WD-WS), el TCN obtiene su mejor comportamiento global. El modelo alcanza el MAE más bajo (0.0481) y un RMSE de 0.0785, junto con el mayor coeficiente de determinación ($R^2 = 0.9626$). Este resultado demuestra que, al disponer de información más completa, el TCN es capaz de integrar eficazmente múltiples fuentes de variabilidad y generar predicciones más precisas.

En conjunto, los resultados evidencian que la arquitectura TCN muestra un rendimiento sólido y estable, destacando especialmente en configuraciones donde se combinan variables complementarias o se incluyen tanto dirección como velocidad del viento, lo que refuerza su idoneidad para la predicción de series temporales con interacciones complejas entre características meteorológicas.

b) Comparación temporal: Señal real vs señal predicha

Las Figuras 3–6 muestran la comparación temporal entre la potencia real generada por la turbina y las predicciones obtenidas mediante el modelo TCN para las cuatro combinaciones de características evaluadas. En todos los escenarios, el modelo es capaz de reproducir adecuadamente el comportamiento intermitente propio de la generación eólica, incluyendo transiciones bruscas, mesetas de alta potencia y periodos de baja producción.

En el escenario TPC-WD (Fig. 3), la predicción del TCN presenta un ajuste especialmente preciso, siguiendo con gran fidelidad tanto los ascensos pronunciados como las caídas abruptas. Este comportamiento visual es coherente con las métricas de precisión, que sitúan este escenario entre los de mejor desempeño para el modelo.




Fig. 2. Comparación entre la potencia real y la potencia predicha por el modelo TCN en el escenario TPC-WD

Las configuraciones TPC-WS (Fig. 4) y WD-WS (Fig. 5) muestran una ligera pérdida de ajuste en comparación con el caso anterior. Aunque el modelo sigue capturando adecuadamente la tendencia general de la señal, se observan desviaciones puntuales en momentos de variabilidad rápida, lo cual concuerda con los valores de MAE, RMSE y R^2 obtenidos en estos dos escenarios.




Fig. 3. Comparación entre la potencia real y la potencia predicha por el modelo TCN en el escenario TPC-WS.




Fig. 4. Comparación entre la potencia real y la potencia predicha por el modelo TCN en el escenario WD-WS.

Cuando se utilizan todas las variables de entrada (TPC-WD-WS, Fig. 6), el TCN logra nuevamente un ajuste muy sólido, reduciendo de forma notable las discrepancias alrededor de los máximos y mínimos locales. La alineación entre la señal real y la predicha es especialmente evidente a lo largo de toda la serie, lo que coincide con las métricas que identifican este escenario como el de mejor rendimiento global.




Fig. 5. Comparación entre la potencia real y la potencia predicha por el modelo TCN en el escenario TPC-WD-WS.

c) Distribución del Error

Los histogramas de error mostrados en la Fig. 8 permiten analizar con mayor detalle el comportamiento del modelo TCN en cada uno de los escenarios de entrada. Estas distribuciones reflejan cómo se reparte el error instantáneo y aportan una visión complementaria a las métricas globales presentadas previamente.




Fig. 6. Distribución del error del modelo TCN en los cuatro escenarios.

En el escenario TPC-WD, el histograma presenta una distribución más concentrada en torno al error cero, lo que indica una variabilidad reducida y confirma el buen

rendimiento alcanzado por el modelo en esta configuración. La mayor parte de los errores se sitúan en rangos estrechos, lo que refuerza la coherencia con los valores bajos de MAE y RMSE.

En los casos TPC-WS y WD-WS, la dispersión del error es ligeramente mayor. Los histogramas muestran colas más pronunciadas, lo que sugiere la presencia de errores puntuales de mayor magnitud, especialmente en momentos donde la señal presenta cambios rápidos. Este comportamiento coincide con las métricas obtenidas, que reflejan un rendimiento algo inferior en estos escenarios.

Cuando se emplea el conjunto completo de características (TPC-WD-WS), la distribución del error vuelve a concentrarse, mostrando una curva más estrecha y simétrica. Este resultado confirma que el modelo se beneficia de disponer de información combinada, reduciendo la variabilidad y mejorando la consistencia del ajuste.

En conjunto, el análisis de los histogramas evidencia que la calidad de las predicciones del TCN está fuertemente influida por las variables de entrada disponibles, y que el modelo ofrece un desempeño especialmente sólido cuando los escenarios integran tanto la dirección como la velocidad del viento.

d) Velocidad de Inferencia

La última parte de la evaluación se centra en el análisis de la velocidad de inferencia del modelo. La Tabla 2 presenta el número medio de predicciones por segundo y el tiempo medio de inferencia por muestra obtenido para cada uno de los escenarios considerados.

TABLE II. EVALUACIÓN DE RENDIMIENTO

Escenario	Predicciones por segundo (media)	Tiempo medio de inferencia por muestra (s)
TPC-WD	3049.7	0.33
TPC-WS	3219.95	0.31
WD-WS	3327.78	0.3
TPC-WD-WS	3221.52	0.31

Los resultados muestran que el TCN ofrece una velocidad de inferencia muy elevada y estable en todos los escenarios, con valores comprendidos entre 3.000 y 3.330 predicciones por segundo. Esta capacidad de procesamiento permite generar estimaciones prácticamente en tiempo real incluso cuando se manejan grandes volúmenes de datos o se requiere una alta frecuencia de actualización.

El tiempo medio de inferencia por muestra, situado en el rango 0.30–0.33 segundos, confirma la eficiencia computacional del modelo, que se mantiene prácticamente constante independientemente de las características de entrada utilizadas.

Estas métricas reflejan una de las principales ventajas de las arquitecturas convolucionales temporales: su diseño totalmente convolucional permite paralelizar las operaciones, reduciendo significativamente la latencia de procesamiento y evitando las limitaciones secuenciales propias de otros enfoques basados en dependencias temporales explícitas.

Gracias a esta eficiencia, el modelo TCN se presenta como una opción especialmente adecuada para aplicaciones que

requieren pronósticos en tiempo real, toma de decisiones con baja latencia, o implementación en dispositivos de borde (“edge computing”) donde los recursos computacionales son limitados.

VI. CONCLUSIONES

Este estudio ha evaluado el rendimiento de las Temporal Convolutional Networks (TCN) para la predicción a corto plazo de potencia eólica utilizando datos reales de SCADA bajo distintas configuraciones de variables de entrada. Los resultados obtenidos demuestran que el TCN es capaz de reproducir con alta fidelidad el comportamiento dinámico de la turbina, capturando tanto transiciones bruscas como periodos de estabilidad en la generación.

El análisis cuantitativo revela que el rendimiento del modelo depende de manera notable del conjunto de características empleado. Los escenarios que integran información combinada de dirección y velocidad del viento presentan los mejores niveles de exactitud, con errores más contenidos y coeficientes de determinación superiores. En particular, el escenario TPC-WD-WS ofrece el desempeño más sólido, lo que confirma el valor de disponer de datos meteorológicos complementarios.

Los histogramas de error y las comparaciones temporales refuerzan estas conclusiones, mostrando distribuciones más concentradas y curvas predichas estrechamente alineadas con la señal real en los escenarios de mejor rendimiento. Por otro lado, la evaluación computacional pone de manifiesto una de las ventajas más relevantes del TCN: su elevada eficiencia de inferencia, alcanzando más de 3.000 predicciones por segundo con tiempos medios por muestra cercanos a 0.30 segundos. Esta capacidad sitúa al modelo como un candidato idóneo para aplicaciones que requieren pronósticos en tiempo real, decisiones con baja latencia o ejecución en entornos de “edge computing”.

En conjunto, los resultados consolidan al TCN como una arquitectura robusta, precisa y computacionalmente eficiente para la predicción de potencia eólica a corto plazo, especialmente en escenarios donde las características meteorológicas disponibles presentan interacciones complejas.

Futuros desarrollos podrían centrarse en ampliar el análisis hacia arquitecturas híbridas que combinen TCN con modelos recurrentes o mecanismos de atención para evaluar si es posible mejorar aún más la captura de dependencias temporales complejas. Asimismo, resultaría de interés estudiar la capacidad de generalización del modelo incorporando múltiples turbinas o parques completos, con el

fin de validar su robustez ante variabilidad espacial y heterogeneidad operacional.

REFERENCES

- [1] Behera, U. S., Sangwai, J. S., & Byun, H. S. (2025). A comprehensive review on the recent advances in applications of nanofluids for effective utilization of renewable energy. *Renewable and Sustainable Energy Reviews*, 207, 114901.
- [2] Liu, S., Zhang, L., Lu, J., Zhang, X., Wang, K., Gan, Z., ... & Wang, H. (2025). Advances in urban wind resource development and wind energy harvesters. *Renewable and Sustainable Energy Reviews*, 207, 114943.
- [3] Serrano, C., Sierra-Garcia, J. E., & Santos, M. (2022). Hybrid optimized fuzzy pitch controller of a floating wind turbine with fatigue analysis. *Journal of Marine Science and Engineering*, 10(11), 1769.
- [4] Sierra-Garcia, J. E., & Santos, M. (2024). Federated discrete reinforcement learning for automatic guided vehicle control. *Future Generation Computer Systems*, 150, 78-89.
- [5] Lindemann, B., Maschler, B., Sahlab, N., & Weyrich, M. (2021). A survey on anomaly detection for technical systems using LSTM networks. *Computers in Industry*, 131, 103498.
- [6] Buestán-Andrade, P. A., Santos, M., Sierra-García, J. E., & Pazmiño-Piedra, J. P. (2023, August). Comparison of LSTM, GRU and transformer neural network architecture for prediction of wind turbine variables. In *International conference on soft computing models in industrial and environmental applications* (pp. 334-343). Cham: Springer Nature Switzerland.
- [7] Wu, Z., Luo, G., Yang, Z., Guo, Y., Li, K., & Xue, Y. (2022). A comprehensive review on deep learning approaches in wind forecasting applications. *CAAI Transactions on Intelligence Technology*, 7(2), 129-143.
- [8] Telicko, J., Krumins, A., & Nikitenko, A. (2025). Development and Evaluation of Neural Network Architectures for Model Predictive Control of Building Thermal Systems. *Buildings*, 15(15), 2702.
- [9] Zuo, C., Wang, J., Liu, M., Deng, S., & Wang, Q. (2023). An ensemble framework for short-term load forecasting based on TimesNet and TCN. *Energies*, 16(14), 5330.
- [10] Peñacoba, M., Buestán, P., Sierra-García, J. E., Santos, M., & Ruano, A. (2024, October). Affordable wind power forecasting: Implementing LSTM Networks on low-cost hardware platforms for enhanced energy management. In *International Conference on Soft Computing Models in Industrial and Environmental Applications* (pp. 270-278). Cham: Springer Nature Switzerland.
- [11] Torres, J. F., Martínez-Álvarez, F., & Troncoso, A. (2022). A deep LSTM network for the Spanish electricity consumption forecasting. *Neural Computing and Applications*, 34(13), 10533-10545.
- [12] Buestán-Andrade, P. A., Peñacoba-Yagüe, M., Sierra-García, J. E., & Santos, M. (2024). Wind power forecasting with machine learning algorithms in low-cost devices. *Electronics*, 13(8), 1541.
- [13] Yagüe, M. P., García, J. E. S., & Penas, M. S. (2026). Human-intelligent trajectory optimization for robotic manipulators with hybrid PSO-PS algorithm. *Advanced Engineering Informatics*, 69, 103941.
- [14] Peñacoba, M., Bayona, E., Sierra-García, J. E., & Santos, M. (2024). Route Optimization for UVC Disinfection Robot Using Bio-Inspired Metaheuristic Techniques. *Biomimetics*, 9(12), 744.

Análisis Comparativo de las Tecnologías de Adhesión y Locomoción para un Sistema Robótico Trepador en Turbinas Eólicas

Comparative Analysis of Adhesion and Locomotion Technologies for a Climbing Robotic System on Wind Turbine

Gumersindo Fernández-García	Mario Peñacoba Yagüe	Alejandro Menéndez García	J. Enrique Sierra-García
Digitalization Department	Digitalization Department	Digitalization Department	Digitalization Department
University of Burgos Burgos,	University of Burgos	University of Burgos Burgos,	University of Burgos
Spain	Burgos, Spain	Spain	Burgos, Spain
0009-0008-5008-1634	0009-0005-6868-9371	0000-0002-7535-5303	0000-0001-6088-9954

Abstract—This work presents a feasibility analysis and a comparative study of adhesion strategies and locomotion mechanisms applicable to the design of a Climbing Robotic System (CRS) for the non-destructive testing (NDT) inspection of onshore wind turbine towers. The study evaluates three primary adhesion technologies (magnetic, suction cup-based, and propeller-assisted negative pressure) and three motion kinematics (wheels, tracks, and legs). The objective is to determine the optimal combination of adhesion and locomotion that ensures safe and efficient movement on tubular metallic surfaces and in the presence of environmental loads such as wind. A dynamic force model is employed to quantify the gripping capacity of each adhesion technology in relation to the robot's payload and the traction requirements for vertical movement. The analysis of kinematics evaluates their performance in overcoming minor obstacles (such as seams and bolts) and their stability. The results suggest that magnetic adhesion, combined with a tracked or magnetic wheel system, offers the highest climbing capacity and autonomy in the typical steel tower environment. The evaluation concludes by identifying the most robust design architecture, providing the basis for the development of a CRS adaptable to the predictive maintenance needs of the wind industry.

Keywords— Climbing Robot, Magnetic Adhesion, Suction Cup Adhesion, Negative Pressure, Locomotion Mechanisms, Non-Destructive Testing (NDT), Onshore Wind Turbine.

Resumen—Este trabajo presenta un análisis de viabilidad y un estudio comparativo de las estrategias de adhesión y los mecanismos de locomoción aplicables al diseño de un Sistema Robótico Trepador (SRT) para la inspección no destructiva (NDT) de torres de turbinas eólicas terrestres. El estudio evalúa tres tecnologías de adhesión (magnética, mediante ventosas, y por presión negativa asistida por hélice) y tres cinemáticas de movimiento (ruedas, orugas y patas). El objetivo es determinar la combinación óptima de adhesión y locomoción que garantice un desplazamiento seguro y eficiente en superficies metálicas tubulares y en presencia de cargas ambientales como viento. Se emplea un modelo de fuerzas dinámicas para cuantificar la capacidad de sujeción de cada tecnología de adhesión en

relación con la carga útil del robot y los requisitos de tracción para el movimiento vertical. El análisis de las cinemáticas evalúa su rendimiento para superar obstáculos menores (como juntas y tornillos) y su estabilidad. Los resultados sugieren que la adhesión magnética, en combinación con un sistema de orugas o ruedas magnéticas, ofrece la mayor capacidad de escalada y autonomía en el entorno típico de las torres de acero. Se concluye identificando la arquitectura de diseño más robusta, proporcionando las bases para el desarrollo de un SRT adaptable a las necesidades de mantenimiento predictivo en la industria eólica.

Palabras clave—Robot Trepador, Adhesión Magnética, Adhesión mediante Ventosas, Presión Negativa, Mecanismos de Locomoción, Inspección No Destructiva (NDT), Turbina Eólica Terrestre.

I. INTRODUCCIÓN

El sector de la energía eólica terrestre se ha consolidado como una de las principales fuentes de generación eléctrica a nivel global, gracias a su madurez tecnológica y coste competitivo. No obstante, el constante aumento en la altura y el diámetro de las turbinas ha incrementado significativamente las exigencias de mantenimiento e inspección, especialmente en las estructuras de soporte (torres), que a menudo superan los 100 metros. La inspección manual es lenta, costosa y arriesgada, especialmente por el trabajo en altura y la variabilidad del clima. Por tanto, es necesario adoptar métodos de inspección que reduzcan riesgos y permitan evaluaciones más consistentes [1].

Dado el riesgo asociado a inspeccionar estructuras de gran altura, la investigación se ha orientado hacia el desarrollo de Sistemas Robóticos Trepadores (SRT) como una solución de inspección remota y automatizada. No obstante, el rendimiento efectivo de estos sistemas complejos depende críticamente de la fiabilidad de su locomoción y adhesión a la superficie de la torre. Las características del entorno de trabajo —como la geometría tubular, la presencia de obstáculos

menores (juntas o bridas), las condiciones ambientales dinámicas (viento y precipitación), y los requisitos de autonomía y carga útil— imponen desafíos ingenieriles significativos [2].

El diseño de un SRT viable requiere que se resuelva un compromiso fundamental: asegurar la fuerza de sujeción necesaria para resistir las fuerzas externas sin comprometer la capacidad de tracción y la eficiencia energética del sistema. Por lo tanto, se hace indispensable un análisis riguroso de las diversas tecnologías de adhesión y cinemáticas de movimiento disponibles para identificar la combinación más robusta y eficaz [3, 4].

En este contexto, la investigación se ha centrado en explorar diversas soluciones robóticas. Las arquitecturas de los Sistemas Robóticos Trepadores (SRT) se distinguen principalmente por su mecanismo de adhesión, que determina la viabilidad de la escalada en estructuras verticales. Estudios previos han demostrado la eficacia de la adhesión magnética para torres ferromagnéticas, ofreciendo alta capacidad de carga y fiabilidad [5, 6]. Por otro lado, la adhesión por vacío/ventosas ha sido explorada por su versatilidad en diferentes materiales, aunque con limitaciones en la velocidad y eficiencia energética [7]. Recientemente, se han propuesto métodos menos convencionales, como la adhesión por presión negativa asistida por hélice, buscando mejorar la velocidad y la adaptabilidad [8]. Sin embargo, la elección del mecanismo de adhesión debe considerarse junto con la cinemática de locomoción (ruedas, orugas o patas) para optimizar el rendimiento y la capacidad de superar obstáculos. Uno de los estudios más avanzados propone el uso de un anillo mediante orugas para subir de forma controlada todo el tronco de la turbina eólica [9]. A pesar de estos avances, aún no existe un estudio que compare de forma simultánea la viabilidad de las principales tecnologías de adhesión y los mecanismos de locomoción disponibles en el contexto específico de las torres eólicas terrestres.

Este estudio analiza precisamente esa brecha al realizar un análisis de viabilidad y un estudio comparativo de las tres principales tecnologías de adhesión y las tres cinemáticas de movimiento mencionadas, empleando un modelo de fuerzas dinámicas. La metodología propuesta integra la evaluación de los criterios de sujeción (fuerza normal) y tracción (fuerza tangencial) para determinar la arquitectura de SRT más eficiente y robusta, estableciendo así una base sólida para el diseño preliminar y la posterior optimización del desempeño en escenarios operativos realistas de la industria eólica.

El artículo se organiza en las siguientes secciones principales. La sección II presenta los fundamentos teóricos de las tecnologías de adhesión y locomoción. La sección III describe la metodología de análisis y el modelo de fuerzas dinámicas. La sección IV analiza los resultados obtenidos del estudio comparativo y define la arquitectura de diseño óptima. Finalmente, la sección V expone las conclusiones y sugiere líneas de investigación futuras.

II. FUNDAMENTOS TEÓRICOS DE LAS TECNOLOGÍAS DE ADHESIÓN Y LOCOMOCIÓN

La adhesión magnética es la técnica más utilizada para la inspección de estructuras metálicas ferromagnéticas, como las torres de turbinas eólicas terrestres. Este método ofrece una alta capacidad de carga y fiabilidad sin consumir energía

eléctrica una vez que el campo magnético está establecido (en el caso de imanes permanentes).

La fuerza de sujeción (F_N) generada por un imán (permanente o electroimán) sobre una superficie ferromagnética plana se rige por la ley de la fuerza de Lorentz, simplificada por la ecuación de Maxwell para la fuerza normal de atracción magnética (cuando la separación es mínima y el material es ideal):

$$F_N = \frac{B^2 \cdot A}{2 \cdot \mu_0} \quad (1)$$

Donde F_N es la fuerza de sujeción normal en N, B es la densidad de flujo magnético en la superficie de contacto en T, A es el área de contacto efectiva del imán en m^2 y μ_0 es la permeabilidad del vacío ($4 \cdot \pi \cdot 10^{-7}$) H/m.

En la práctica, la fuerza es inversamente proporcional a la distancia entre el imán y la superficie, lo que hace que la calidad de la superficie y el revestimiento (pintura o corrosión) sean factores críticos [10, 11].

En la ecuación (2) se muestra la fuerza magnética en un entrehierro (gap) de un electroimán cilíndrico o de núcleo de herradura, expresada en términos de las propiedades eléctricas y geométricas de la bobina.

$$F_N = \frac{(N \cdot I)^2 \cdot \mu_0 \cdot A}{2 \cdot g^2} \quad (2)$$

En dicha ecuación, N hace referencia al número de vueltas de la bobina, I es la corriente que pasa por la bobina en A, siendo por tanto $N \cdot I$ la fuerza magnetomotriz en A. g es la distancia del entrehierro (gap) entre el electroimán y la superficie en m y μ_0 es la permeabilidad del vacío en H/m.

En la Fig. 1 podemos ver el concepto del electroimán compuesto por un núcleo de material ferromagnético, como hierro, alrededor del cual se enrolla un alambre conductor por el que circula la corriente eléctrica.




Figura 1. Concepto de electroimán.

La adhesión por vacío, o mediante ventosas, es una técnica de sujeción muy versátil, ya que es independiente del material de la pared (siempre que la superficie sea lisa y no porosa). La fuerza de sujeción se genera creando una presión negativa entre la ventosa y la superficie.

La fuerza de sujeción generada por una ventosa es el resultado de la ecuación (3):

$$F_N = \Delta P \cdot A_v = (P_{atm} - P_{int}) \cdot A_v \quad (3)$$

Donde A_v es el área de sellado efectivo de la ventosa en m^2 y P_{int} es la presión absoluta dentro de la ventosa en Pa.

Aunque la fuerza de adhesión se determina por ΔP y el área, la viabilidad operacional del SRT requiere evaluar la potencia consumida por la bomba de vacío para generar y mantener el caudal de aire necesario. La potencia requerida para mantener el caudal contra el gradiente de presión es directamente proporcional al producto de ambos, y está inversamente relacionada con la eficiencia o velocidad del sistema, lo que puede resumirse en una relación que afecta la fuerza efectiva del sistema en términos de potencia (4).

$$P = \frac{\Delta P \cdot Q}{V} \quad (4)$$

Donde P es la potencia de la bomba en W, ΔP es el gradiente de presión, Q es el caudal y V es la eficiencia del sistema.

El principal desafío de este sistema es la necesidad de un sellado hermético (lo que hace que la rugosidad de la superficie o las juntas sean obstáculos críticos) y el consumo continuo de energía de la bomba de vacío para mantener la presión negativa [12].



Figura 2. Robot con ventosas.

La adhesión por presión negativa asistida por hélice, también conocida como adhesión por flujo de aire dinámico, utiliza un propulsor (hélice) contenido en un conducto sellado parcialmente (shroud) para generar una fuerza de sujeción aerodinámica activa. El sistema crea una región de baja presión entre el conducto y la pared sin requerir el contacto total o un sello de goma perfecto, diferenciándose de las ventosas pasivas.

La fuerza se obtiene directamente de la diferencia de presión creada por el flujo de aire y el área del conducto efectivo como se puede observar en (5):

$$F_N \propto \Delta P \cdot A_e \quad (5)$$

Donde ΔP es generado por la velocidad del aire impulsado por la hélice y A_e es el área del conductor efectivo. Esta técnica es más tolerante a la rugosidad que las ventosas, pero requiere un consumo energético significativamente mayor para mantener el régimen de giro constante y la succión dinámica. Esta fuerza debe ser mayor que el peso del robot más las fuerzas de arrastre del viento para garantizar la sujeción [13, 14].



Figura 3. Robot con hélices.

III. METODOLOGÍA DE ANÁLISIS Y MÉTODO DE FUERZAS DINÁMICAS

Modelo de equilibrio de fuerzas.

El análisis se basa en un diagrama de cuerpo libre considerando el peor caso de operación, correspondiente a una ráfaga máxima de viento. El sistema de adhesión debe cumplir simultáneamente tres condiciones físicas fundamentales para garantizar la operación segura del robot sobre la superficie vertical de la torre.

En primer lugar, la fuerza de adhesión (F_{adh}) debe ser suficiente para evitar el desprendimiento provocado por la fuerza del viento (F_{viento}^{Max}):

$$F_{adh} \geq F_{viento}^{Max} \quad (6)$$

En segundo lugar, para evitar el deslizamiento descendente del robot debido a su peso, la fuerza de fricción estática generada por la adhesión debe superar el peso del sistema, incluyendo un factor de seguridad (ecuación 7).

$$F_{adh} \cdot \mu_{est} \geq P \cdot FS \quad (7)$$

Donde P es el peso en N, μ_{est} es el coeficiente de fricción estática, y FS es un factor de seguridad adimensional. Finalmente, durante el ascenso, la fuerza de tracción disponible debe ser suficiente para compensar el peso del robot y las pérdidas debidas a la fricción dinámica:

$$F_{trac} \geq (P + F_{adh} \cdot \mu_{din}) \cdot FS \quad (8)$$

Donde μ_{est} representa el coeficiente de fricción dinámica. La Fig. 4 muestra el diagrama general de fuerzas que actúan sobre el robot. Dependiendo del estado de operación, actúa la fricción estática (robot detenido) o la fricción dinámica (robot en movimiento), pero no ambas simultáneamente.




Figura 4. Diagrama de fuerzas esquemático.

Efecto de la curvatura de la torre.

Por otro lado, la curvatura de la torre introduce una reducción en la fuerza de adhesión efectiva disponible, especialmente en tecnologías magnéticas y de vacío, debido a la aparición de un entrehierro no uniforme. Este efecto se modela mediante un factor de corrección dependiente del radio de curvatura de la torre, que penaliza la fuerza de adhesión nominal del sistema [15].

En la tabla 1 se resumen los parámetros de cálculo y suposiciones para un STR tipo.

TABLA 1. PARÁMETROS DE CÁLCULO Y SUPOSICIONES

Parámetro	Símbolo	Valor Numérico
Masa del Robot	m	15 kg
Peso del Robot	W	147,15 N
Velocidad Máx. del Viento	$V_{w,m\acute{a}x}$	19,44 m/s
Radio de Curvatura de la Torre	R_{torre}	2 m
Área Frontal Expuesta	A_{exp}	0,4 m ²
Coefficiente de Fricción	μ	0,6
Factor de Seguridad Mínimo	FS	1,5

IV. ENTORNO DE SIMULACIÓN Y VALIDACIÓN

Para complementar el modelo matemático y validar las físicas de interacción antes de la construcción de un prototipo físico, se ha seleccionado el entorno de simulación Webots. Este software de código abierto permite simular con alta fidelidad las propiedades físicas del entorno, tales como la gravedad, la fricción, la densidad del aire (para simular el viento) y las colisiones dinámicas.

Dentro de las librerías de robots disponibles en Webots, se ha identificado por ejemplo el modelo Mantis (robot hexápodo) como una plataforma base adecuada para las pruebas de cinemática con patas. La arquitectura de este modelo permite la modificación de sus efectores finales, posibilitando la sustitución de las patas estándar por sistemas de adhesión activos, como ventosas o módulos magnéticos, para testear la capacidad de escalada sobre la geometría curva de la turbina.

La Figura 5 muestra una imagen del entorno de simulación con un ejemplo de turbina eólica y el robot trepador en el suelo.




Figura 5. Entorno de simulación.

El simulador permite monitorizar en tiempo real el equilibrio de fuerzas que actúan sobre el robot, validando si la configuración elegida soporta las cargas vectoriales críticas mostradas en la Figura 4.

Más allá de la validación estática, el entorno de simulación permite someter al modelo a escenarios dinámicos estocásticos que replican las condiciones hostiles de operación real. Esto incluye la inyección de fuerzas de perturbación aleatorias que simulan ráfagas de viento variables y la interacción con irregularidades superficiales, permitiendo evaluar la respuesta de los algoritmos de control de estabilidad. Esta etapa de validación pre-prototipado es crítica para ajustar los coeficientes de fricción y las estrategias de modulación de la adhesión, asegurando que el diseño final no solo cumpla teóricamente con el Factor de Seguridad, sino que garantice la robustez operativa necesaria para evitar el deslizamiento o despegue ante cambios bruscos en el vector de carga ambiental.

V. ANÁLISIS DE RESULTADOS Y ARQUITECTURA DE DISEÑO ÓPTIMA

Esta sección presenta los resultados obtenidos del Modelo de Fuerzas Dinámicas desarrollado en la Sección III, contrastando la viabilidad y la eficiencia operacional de las diferentes combinaciones de adhesión y locomoción para el SRT en las torres eólicas terrestres.

El análisis de sujeción considera la peor ráfaga de viento prevista como (19.44 m/s), la fuerza de separación de 111.41 N y $F_{Adh,req}$ de 167.12 N ($FS_A \geq 1.5$).

TABLA 2. RESULTADOS DEL ANÁLISIS DE ADHESIÓN

Tecnología de Adhesión	$F_{Adh,max}$ (Estimada)	FSA (Adhesión)
Magnética (Imanes)	200N a 300N	1,2-1,8
Vacío (Ventosas)	150N a 250N	0,9-1,5
Presión negativa (Hélice)	350N a 450N	2,1-2,7

La adhesión magnética y la presión negativa asistida por hélice demostraron ser las únicas capaces de alcanzar consistentemente el FS_A mínimo requerido, resistiendo las cargas de viento de 70 km/h . Sin embargo, la adhesión por ventosas (asumiendo un tamaño limitado por la curvatura de $R_{torre} = 2 \text{ m}$ y pérdidas por fugas) mostró un rendimiento marginal ($FS_A < 1.5$) en este escenario de ráfaga extrema.

La condición de tracción es el requisito más estricto del diseño, exigiendo un $F_{Adh,req}$ de 367.88 N ($FS_T \geq 1.5$). Este requisito depende directamente del peso del robot ($W = 147.15 \text{ N}$).

Impacto de la fricción: para lograr $FS_T \geq 1.5$, la fuerza de fricción disponible debe ser 367.88 N . Esto implica que la tecnología de adhesión debe ser capaz de generar un $F_N = 367.88 \text{ N}$ (independientemente del viento) para garantizar la escalada sin deslizamiento. Podemos observar cómo solamente el caso de la hélice sería capaz de soportar estas cargas con las condiciones que le hemos dado, pero teniendo en cuenta que el consumo se dispara. El método de los imanes no serviría para este caso por una diferencia de unos 68 N , pero se pueden incluir varias modificaciones para que si sea viable:

- Cambiar la masa del robot.
- Aumentar el tamaño del imán.
- Trabajar en días con menos viento.

Para la locomoción, la elección depende de la estabilidad, la complejidad mecánica y la capacidad para superar las juntas de la torre (obstáculos de $\approx 1 \text{ cm}$).

- Ruedas: ofrecen la mayor velocidad y eficiencia energética en superficies lisas. Sin embargo, su capacidad para superar obstáculos es la más limitada, siendo inestable en las juntas horizontales.
- Patas: proporcionan la mayor versatilidad para superar obstáculos discretos y grandes. No obstante, su complejidad mecánica y la baja velocidad de desplazamiento las hacen inviables para la inspección rápida de torres de más de 100 m de altura.
- Orugas (Tracks): presentan el mejor equilibrio. Y distribuyen la fuerza de contacto en un área mayor, proporcionando estabilidad y una capacidad de

transición robusta sobre las juntas y bridas, manteniendo una velocidad de desplazamiento aceptable.

El análisis comparativo de todas las variables hace que la arquitectura de diseño más robusta y con mayor viabilidad operacional para la inspección de turbinas eólicas terrestres es la combinación de un Sistema de Adhesión Magnética Controlada con un Mecanismo de Locomoción por Orugas. Esta decisión ha sido tomada en base a los cálculos realizados, haciendo hincapié en los requisitos técnicos necesarios y en la optimización de los recursos como la potencia o la estabilidad frente a obstáculos.

La Fig. 6 presenta un robot móvil de tipo oruga de diseño compacto y robusto, adecuado para tareas de inspección o escalada en grandes estructuras [17]. El equipo se complementa con un control remoto, es un sistema teledirigido para tareas en entornos peligrosos o de difícil acceso (parecido al propuesto en este artículo).




Figura 6. Idea Visual del Robot Propuesto.

VI. CONCLUSIONES

El estudio concluye que, desde una perspectiva ingenieril, la creación y el despliegue de un Sistema Robótico Trepador (SRT) para la inspección de turbinas eólicas terrestres es viable. La Adhesión Magnética Controlada combinada con la Locomoción por Orugas emerge como la arquitectura de diseño más acertada. Esta combinación ofrece un balance crucial: la sujeción magnética garantiza la autonomía de la misión (consumo energético mínimo o nulo en modo de adhesión) y la estabilidad de las orugas asegura la fiabilidad operacional sobre las superficies curvas y las juntas de las torres.

En conjunto, los resultados indican que esta tecnología es viable y puede mejorar la seguridad y eficiencia del mantenimiento.

Este estudio proporciona una base inicial para desarrollar prototipos funcionales de SRTs. Las líneas de investigación futuras deben centrarse en la implementación y validación de la arquitectura seleccionada. Esto incluye el diseño detallado y la construcción del prototipo del robot de orugas magnéticas. Además, se requiere la investigación de algoritmos de control que permitan al robot adaptarse automáticamente a las variaciones en la fuerza de adhesión causadas por la curvatura de la torre y las juntas y optimizar las rutas de inspección para minimizar el tiempo y el consumo energético en operación real.

Como siguiente paso, será necesario integrar sensores NDT avanzados (como ultrasonidos) para que el SRT pueda

no solo localizar, sino también cuantificar los defectos estructurales con alta precisión.

REFERENCIAS

- [1] Pfaffel, S., Faulstich, S., & Rohrig, K. (2017). Performance and reliability of wind turbines: A review. *energies*, 10(11), 1904.
- [2] Prahlad, H., Pelrine, R., Stanford, S., Marlow, J., & Kornbluh, R. (2008, May). Electroadhesive robots—wall climbing robots enabled by a novel, robust, and electrically controllable adhesion technology. In 2008 IEEE international conference on robotics and automation (pp. 3028-3033). IEEE.
- [3] Fang, Y., Wang, S., Bi, Q., Cui, D., & Yan, C. (2022). Design and technical development of wall-climbing robots: A review. *Journal of Bionic Engineering*, 19(4), 877-901.
- [4] Fang, Y., Wang, S., Bi, Q., Cui, D., & Yan, C. (2022). Design and technical development of wall-climbing robots: A review. *Journal of Bionic Engineering*, 19(4), 877-901.
- [5] Sahbel, A., Abbas, A., & Sattar, T. (2019, February). System design and implementation of wall climbing robot for wind turbine blade inspection. In 2019 International Conference on Innovative Trends in Computer Engineering (ITCE) (pp. 242-247). IEEE.
- [6] Sattar, T. P., Leon Rodriguez, H., & Bridge, B. (2009). Climbing ring robot for inspection of offshore wind turbines. *Industrial Robot: An International Journal*, 36(4), 326-330.
- [7] Hao, W., Wang, L., Dong, X., Zhu, C., & Zhang, S. (2025, October). Structural design and validation of a vacuum-adhesion wall-climbing robot for wind turbine towers. In *Journal of Physics: Conference Series* (Vol. 3133, No. 1, p. 012005). IOP Publishing.
- [8] Ryu, J., Kim, S., Park, S., Lee, D., Jo, J., & Shim, D. (2024). Design and Analysis of Propeller-Based Wall-Climbing Robot. *International Journal of Internet, Broadcasting and Communication*, 181-193.
- [9] Franko, J., Du, S., Kallweit, S., Duelberg, E., & Engemann, H. (2020). Design of a multi-robot system for wind turbine maintenance. *Energies*, 13(10), 2552.
- [10] Chen, J., Wang, S., & Xie, H. (2020). Design and Modeling of a Permanent Magnetic Adhesion Mechanism for Wall-Climbing Robots. *IEEE Transactions on Industrial Electronics*, 67(11), 9390-9399.
- [11] Lee, G., Kim, J., & Lee, J. (2018). Magnetic wheel design optimization for wall-climbing robots based on magnetic force analysis. *Journal of Field Robotics*, 35(7), 1032-1045.
- [12] Li, X. D., Zhao, F. K., Meng, D. M., & Zhang, J. L. (2023). Design and force analysis of a novel propeller-driven wall-climbing robot. *Journal of Field Robotics*, 40(1), 127-142.
- [13] Zhang, Y., Du, F., & Li, Y. (2019). A bio-inspired multi-rotor wall-climbing robot using ducted fans for vertical surface attachment. *IEEE/ASME Transactions on Mechatronics*, 24(3), 1184-1194.
- [14] Berdugo, O., & Pérez, J. (2011). Diseño y construcción de un prototipo turbina eólica de eje vertical para generación a baja potencia. Universidad Industrial de Santander.
- [15] Shenzhen Huayang Technology Co., Ltd. (s.f.). Wall Climbing Robots Magnetic Robot Stair. Alibaba. <https://spanish.alibaba.com/product-detail/Wall-Climbing-Robots-Magnetic-Robot-Stair-1601151019418.html>
- [16] Noohi, E., Mahdavi, S. S., Baghani, A., & Ahmadabadi, M. N. (2010). Wheel-based climbing robot: Modeling and control. *Advanced Robotics*, 24(8-9), 1313-1343.
- [17] Zhang, Y., Dodd, T., Atallah, K., & Lyne, I. (2010, August). Design and optimization of magnetic wheel for wall and ceiling climbing robot. In 2010 IEEE International Conference on Mechatronics and Automation (pp. 1393-1398). IEEE.

Modelo basado en datos para la detección y clasificación de fallos en aerogeneradores marinos

Data-Driven Framework for Fault Detection and Classification in Offshore Wind Turbines

Bassel Weiss

Departamento de Arquitectura de
Computadores y Control Automático,
Universidad Complutense de Madrid
Madrid, Spain

Email: bweiss@ucm.es

Segundo Esteban San Román

Departamento de Arquitectura de
Computadores y Control Automático,
Universidad Complutense de Madrid
Madrid, Spain

ORCID: 0000-0002-4071-2147

Email: sesteban@ucm.es

Matilde Santos

Instituto de Tecnología del
Conocimiento Universidad
Complutense de Madrid (UCM)
Madrid, España

ORCID: 0000-0003-1993-8368

Email: msantos@ucm.es

Abstract— Offshore wind energy has become a cornerstone of the global transition toward renewable energy. However, ensuring the reliable operation of offshore wind turbines (OWTs) remains challenging due to harsh marine conditions, high maintenance costs, and complex logistics. Unexpected failures can lead to prolonged downtime, costly repairs, and significant energy losses. This paper presents a unified data-driven framework for early anomaly detection and fault classification in OWTs. The proposed approach combines a physics-informed Wind Power Index (WPI) for performance normalization with machine-learning techniques—specifically a k -nearest neighbors (k -NN) classifier and a Support Vector Machine (SVM)—to detect and categorize turbine faults. The framework is validated using SCADA data from an offshore wind farm, demonstrating improved early fault detection compared to conventional power-curve threshold methods. The proposed method provides interpretable diagnostics and can be applied across different turbines, contributing to more reliable and cost-effective offshore wind farm operations.

Key Words: Offshore wind energy, offshore wind turbines, anomaly detection, fault classification, SCADA data, Wind Power Index, k -nearest neighbors, support vector machines.

Resumen— La energía eólica marina se ha convertido en una piedra angular de la transición global hacia la energía renovable. Sin embargo, garantizar la operación fiable de los aerogeneradores marinos (OWT) sigue siendo un reto debido a las duras condiciones marinas, los altos costes de mantenimiento y la compleja logística. Las fallas inesperadas pueden provocar inactividad prolongada, reparaciones costosas y pérdidas significativas de energía. Este artículo desarrolla un marco unificado y basado en datos para la detección temprana de anomalías y clasificación de fallos en OWT. El enfoque combina un Índice de Potencia Eólica (WPI) informado por la física para la normalización del rendimiento con técnicas de aprendizaje automático – concretamente un clasificador de k vecinos más cercanos (k -NN) y una Máquina de Vectores de Soporte (SVM) – para detectar y categorizar fallos en turbinas. El marco está validado con datos SCADA de un parque eólico marino, demostrando una mejor detección temprana de fallos en comparación con los umbrales convencionales de curva de potencia. El método propuesto ofrece diagnósticos interpretables y se puede aplicar a distintas turbinas, contribuyendo a operaciones de parques eólicos marinos más fiables y rentables.

Palabras clave: Energía eólica, aerogeneradores marinos, detección de anomalías, clasificación de fallos, datos SCADA, Índice de Potencia Eólica, k vecinos más cercanos, máquinas de vectores de soporte.

I. INTRODUCCIÓN

Mitigar el cambio climático requiere una ampliación masiva de las fuentes de energía renovable [1]. La Agencia Internacional de la Energía (AIE) proyecta que la capacidad de generación renovable debe triplicarse para 2030 para mantener al alcance el objetivo de calentamiento de 1,5 °C [3]. La expansión de las renovables no solo reduce las emisiones de carbono [4] y disminuye los riesgos relacionados con el clima [5], sino que también contribuye al crecimiento económico [6].

La energía eólica se ha convertido en un pilar central de esta transición, con una capacidad eólica global que alcanzó aproximadamente 1,14 TW en 2024 [1][2]. La energía eólica marina, en particular, está creciendo rápidamente; por ejemplo, el primer parque eólico marino del mar Mediterráneo comenzó a operar en 2022 [7], ofreciendo un enorme potencial energético en zonas marítimas de alto viento.

Sin embargo, las turbinas eólicas marinas (offshore wind turbine, OWT) se enfrentan a condiciones ambientales duras que provocan un aumento de las tasas de fallo y una logística de mantenimiento complicada. Los fuertes vientos y olas pueden acelerar la degradación de los componentes [3]. Los gastos de operación y mantenimiento (O&M) constituyen una parte significativa de los costes de los parques eólicos marinos [8], agravados por el tiempo de inactividad [9].

Por tanto, la monitorización efectiva de las condiciones y las estrategias de mantenimiento predictivo son fundamentales para garantizar la fiabilidad de las turbinas y minimizar los tiempos de inactividad no planificados [10]. Estudios recientes demuestran que el mantenimiento predictivo basado en datos puede ser rentable para las granjas offshore [11][12], y mejorar la fiabilidad de las turbinas se ha convertido en un foco clave de la industria (por ejemplo, el programa NREL Wind Reliability [13]).

Las turbinas modernas están equipadas con sistemas SCADA que registran cientos de parámetros (potencia, velocidad del viento, temperaturas, etc.) en intervalos de

tiempo fijos. Estos datos han permitido una variedad de enfoques para detectar anomalías y fallos incipientes en el funcionamiento de turbinas [11]. En términos generales, los métodos existentes se dividen en tres categorías: (i) técnicas basadas en modelos físicos de rendimiento o curvas de potencia esperada para señalar desviaciones, (ii) métodos de aprendizaje automático (ML) basados en datos que aprenden patrones de comportamiento normales a partir de datos históricos, y (iii) enfoques híbridos que combinan modelos físicos con análisis de datos [11]. Por ejemplo, los modelos de Proceso Gaussiano se han utilizado para aprender la curva de potencia de una turbina y detectar desviaciones respecto al rendimiento esperado, mientras que los autocodificadores basados en redes neuronales pueden reconstruir datos de sensores de alta dimensión e identificar valores atípicos[8][9]. Estas técnicas han logrado resultados prometedores, pero muchos estudios se limitan a turbinas individuales o conjuntos de datos terrestres, y carecen de validación en múltiples sitios o para distintos tipos de turbinas [11]. Como resultado, sigue existiendo la necesidad de marcos generalizados de detección de fallos que puedan adaptarse a diferentes turbinas y condiciones de funcionamiento.

En este artículo se presenta un marco unificado basado en datos para la detección temprana de fallos en parques eólicos marinos que aborda estos desafíos. Nuestro enfoque aprovecha tanto el conocimiento del dominio como el aprendizaje automático para mejorar la consistencia y precisión en la detección de anomalías. El marco se evalúa con datos reales de parques eólicos marinos, demostrando la detección temprana de fallos (antes de pérdidas significativas de energía) y bajas tasas de falsos positivos, ofreciendo así una herramienta práctica para el mantenimiento proactivo de OWT.

La estructura del artículo es la siguiente. En la sección II se describe la metodología aplicada para la detección de anomalías, especificando el cálculo del índice de potencia y la aplicación de la técnica k-NN y la clasificación del tipo de anomalía mediante SVM. En la sección III se presenta un caso de estudio con datos reales. En la sección IV se discuten los datos obtenidos para las OWT del parque Alpha-Ventus. El trabajo termina con las conclusiones y líneas futuras de investigación.

II. METODOLOGÍA

La arquitectura general de detección de anomalías se ilustra en la Fig. 1. El proceso comienza con el preprocesamiento y normalización de datos SCADA, seguido de la extracción de características y la detección de anomalías en dos etapas. Primero, se calcula el Índice de Potencia Eólica (WPI) para cada punto de datos para medir la desviación de rendimiento. A continuación, un clasificador SVM evalúa las anomalías señaladas por WPI para determinar cuáles son fallos verdaderos frente a falsas alarmas o ruido. Esta sección describe cada fase en detalle.

El primer paso es la adquisición y preprocesamiento de datos. Para ello se recogen y limpian los datos SCADA de alta frecuencia (velocidad del viento, potencia, etc.) de cada turbina (gestionando lecturas faltantes o erróneas de sensores). Posteriormente se extraen las características específicas relevantes, siendo la más importante el cálculo del Índice de Potencia Eólica (WPI), que normaliza el rendimiento energético por la entrada de viento.

Cada nueva observación se compara con datos históricos normales y se detecta si es o no una anomalía. Un SVM entrenado clasifica entonces cada anomalía como un fallo probable o valor normal, basándose en umbrales de decisión, para filtrar falsas alarmas. El sistema genera alertas para fallos, permitiendo a los operadores tomar medidas de mantenimiento preventivas.

A. Índice de Potencia Eólica (WPI):

El Índice de Potencia Eólica es una métrica normalizada que captura la desviación de la potencia de salida de una turbina respecto al rendimiento esperado bajo las condiciones actuales. El concepto de WPI es linealizar la curva estándar de potencia eólica expresando tanto la potencia como la velocidad del viento en formas normalizadas adimensionales [14]. En la práctica, la potencia de salida y la velocidad del viento de la turbina se normalizan (por ejemplo, la potencia por la potencia nominal y la velocidad del viento por un rango de referencia de la velocidad del viento).

Anomaly-detection pipeline (SCADA → Preprocessing → WPI → SVM)




Fig. 1. Metodología para la detección de anomalías en turbinas eólicas marinas.

Es decir, el índice WPI en un momento dado se define como la diferencia entre la potencia normalizada y la velocidad normalizada del viento:

$$WPI_i = EP_n - \min(WS_n, 1) \quad (1)$$

Donde:

$$WS_n = \max((v - v_{cut_{in}})^2 / (v_{rated} - v_{cut_{in}})^2, 0) \quad (2)$$

$$EP_n = \max(EP / P_{rated}, 0) \quad (3)$$

WS_n y EP_n son la velocidad y potencia normalizadas del viento, respectivamente. $WPI \approx 0$ significa rendimiento esperado, $WPI > 0$ sugiere error en el sensor de viento, y $WPI < 0$ indica un rendimiento bajo la potencia.

Cuando ocurre una falla o anomalía, la potencia real se desvía de esta relación ideal, haciendo que WPI se desvíe de cero. Por ejemplo, un fallo en el ángulo de paso de palas o en la orientación de la turbina podría reducir la potencia de salida para una velocidad de viento dada, produciendo un WPI negativo, mientras que un sesgo del sensor (midiendo incorrectamente la velocidad del viento) podría producir un WPI positivo o errático [14].

Además se han establecido unos valores estadísticos de confianza para el WPI: si el WPI queda fuera de un rango normal (determinado por $\pm 2\sigma$ alrededor de cero, según los datos), el punto se etiqueta como anomalía. Esto convierte a

WPI en un indicador simple pero eficaz—cercano a cero durante el funcionamiento normal, de valor alto durante fallos—comparable entre turbinas de diferentes tamaños y diferentes tipos, como se muestra en la Fig. 2.




Fig. 2: Márgenes de confianza del índice WPI.




Fig. 3: Ajuste de modelos, (a) Potencia Normalizada; (b) Residuos.

La Fig. 3 ilustra el ajuste del índice WPI: la curva de potencia de una turbina se normaliza y se representa frente a la velocidad del viento, mostrando que el agrupamiento de datos normales de funcionamiento se concentra alrededor de $WPI = 0$, mientras que una condición de fallo se manifiesta como un claro valor atípico ($WPI \ll 0$) indicando anomalía de potencia.

La Fig. 4 muestra la potencia normalizada de una turbina frente a la velocidad del viento. La línea roja representa el rendimiento ideal ($WPI = 0$). Los puntos de operación normal (verde) se encuentran cerca de esta línea, lo que da un WPI cercano a cero. En cambio, una condición de fallo hace que los puntos anómalos (naranjas) se desvíen significativamente por debajo de la recta ideal, resultando en un WPI negativo. Esta visualización demuestra cómo WPI aísla las desviaciones del rendimiento esperado: los puntos fuera de la banda definida (región sombreada que indica $\pm$ rango normal de 2σ) se identifican fácilmente como posibles anomalías [14].




Fig. 4. Índice de Potencia Eólica (WPI) para el rendimiento de turbinas.

B. Detección de anomalías con k -vecinos más cercanos (k -NN):

Para capturar desviaciones más allá de la métrica univariante WPI se utiliza como detector de anomalías la técnica k -vecinos más cercanos (k -NN). Los datos históricos SCADA del funcionamiento normal de la turbina sirven como conjunto de referencia. Cada nueva observación se representa como un vector de características (por ejemplo, velocidad del viento, potencia, WPI, y lecturas seleccionadas de sensores). El algoritmo calcula la distancia desde este punto hasta todas las muestras de referencia e identifica a sus k vecinos más cercanos. Si la distancia media entre vecinos supera un umbral—definido a partir de la distribución de distancia de entrenamiento para controlar la tasa de falsas alarmas—la muestra se marca como anómala.

Este enfoque no paramétrico no hace suposiciones de distribución y, por tanto, captura una amplia gama de tipos de fallo. Las anomalías multivariantes (por ejemplo, cambios combinados de temperatura, velocidad del rotor y potencia) que pueden no ser evidentes con el WPI aparecen como puntos aislados en el espacio de características. Para mantener la robustez, el conjunto de referencia se actualiza periódicamente para que las derivas graduales en el comportamiento normal no provoquen falsas alarmas.

Un tamaño moderado de vecindad ($k = 5$) proporcionó un equilibrio efectivo entre sensibilidad y rechazo de ruido, consistente con la práctica típica de detección de anomalías no supervisadas [15].

C. Clasificación de fallos por Máquina de Vectores de Soporte (SVM):

La etapa final del marco es un clasificador de Máquina de Vectores de Soporte (SVM) que interpreta y filtra las anomalías detectadas por las etapas anteriores. No todos los valores atípicos señalados por WPI corresponden a un fallo real. Algunos datos anómalos pueden estar causados por fluctuaciones transitorias o ruidos de sensores. La SVM está entrenada para distinguir estos casos usando ejemplos etiquetados.

Para ello se ha recogido un conjunto de datos de entrenamiento compuesto por vectores de características etiquetados como "fallo" o "normal"; los casos de fallo pueden provenir de eventos históricos de fallo (por ejemplo, fallos conocidos de componentes o eventos anormales) y anomalías identificadas con alta confianza por el índice WPI, mientras que los casos normales son muestras de funcionamiento correcto conocidas. El conjunto de características que alimenta a la SVM puede incluir el WPI, los valores del sensor y si es conveniente, otras características temporales (como medias móviles o tendencias).

Se ha aplicado una SVM de función núcleo de base radial (RBF), que puede capturar límites no lineales entre clases. Durante el entrenamiento, la SVM encuentra un hiperplano óptimo en el espacio de características que separa instancias de fallo de las normales con margen máximo. Tras el entrenamiento, cada nuevo candidato a anomalía se procesa con la SVM, que proporciona una clasificación: fallo (anomalía verdadera) o correcto (falsa alarma). De este modo, la SVM reduce los falsos positivos aprendiendo los patrones que representan fallos genuinos [16].

Por ejemplo, un patrón de anomalía caracterizado por cambios simultáneos en múltiples características (como una caída de potencia acompañada de cambios en vibración y temperatura) podría ser reconocido por el SVM como un fallo real, mientras que una anomalía de sólo un sensor (por ejemplo, un pico aislado en la lectura de la velocidad del viento) podría clasificarse como un error del sensor (falsa alarma). La SVM también permite diferenciar entre diferentes tipos de fallo si se etiquetan correspondientemente. En general, este paso de aprendizaje supervisado mejora significativamente la precisión en la cadena de detección de anomalías, asegurando que el personal de O&M solo reciba alertas para eventos significativos [14].

III. CASO DE ESTUDIO Y DATOS

Para evaluar el marco propuesto se ha aplicado a datos reales de SCADA del parque eólico marino Alpha Ventus [17] en Alemania, mostrado en la Fig. 5.

Alpha Ventus consta de doce OWT de 5 MW (seis turbinas Adwen M5000-116 y seis Senvion 5M), instaladas en el Mar del Norte. El sistema SCADA registra un conjunto completo de parámetros a intervalos de 10 minutos (y frecuencias más altas para ciertos canales) como parte del proyecto RAVE. El conjunto de datos abarca desde 2010 hasta la actualidad, comprendiendo más de una década de datos operativos (~30 TB). Las variables clave medidas incluyen la velocidad del viento, la dirección del viento, la temperatura del aire, la humedad, la potencia eléctrica, la velocidad del rotor, el ángulo de paso de las palas y la orientación de las góndolas, entre otras.




Fig. 5 Vista del parque eólico marino Alpha Ventus [17]

Este extenso conjunto de datos proporciona una base realista para desarrollar y probar el marco de detección de anomalías, cubriendo una amplia gama de condiciones operativas y múltiples incidentes de fallos a lo largo de los años.

Para los experimentos se ha utilizado un subconjunto de señales SCADA críticas: velocidad del viento, dirección del viento, potencia eléctrica, velocidad del rotor, paso de las palas y ángulo de guiñada. Estas variables están directamente relacionadas con la aerodinámica y el control de las turbinas, lo que las convierte en útiles para detectar desviaciones de rendimiento.

Se han dividido en un periodo de entrenamiento y otro de prueba. El conjunto de entrenamiento (datos históricos) se utilizó para establecer perfiles de comportamiento normal y entrenar el clasificador SVM. El conjunto de pruebas incluía periodos que contenían fallos o anomalías conocidas (como casos de hielo en las palas, desalineación de guiñada y fallos en sensores). Todos los datos se limpiaron para eliminar lecturas poco plausibles (por ejemplo, velocidades negativas del viento) y se normalizaron según requería el cálculo WPI.

La metodología propuesta se desarrolla de la siguiente manera. Los datos SCADA entrantes se normalizan y procesan para calcular el índice WPI en tiempo real para cada turbina. Cada nuevo punto de datos se somete a un análisis k-NN utilizando la base de datos de puntos normales históricos (se utiliza una estructura eficiente basada en árboles). Si se marca como anómalo, el punto es evaluado inmediatamente por la SVM para confirmar si corresponde a un fallo. Si el SVM emite una clasificación de fallo, se activa una alarma para esa turbina en esa marca temporal. El sistema también comprueba si varias turbinas presentan alarmas de forma simultánea. Las anomalías coincidentes se comparan para diferenciar eventos anómalos de todo el parque eólico de fallos específicos de algunas turbinas.

Esta metodología puede desplegarse en línea, proporcionando una monitorización casi en tiempo real de las condiciones del parque eólico.

IV. RESULTADOS Y DISCUSIÓN

El sistema de detección de anomalías propuesto fue probado primero mediante la simulación de software OpenFast [18] antes de obtener acceso a varios meses de datos del parque eólico marino Alpha Ventus, que incluían múltiples eventos de fallo conocidos.

A. Rendimiento de la detección de anomalías en el parque marino

La Fig. 6 presenta un ejemplo de matriz de confusión de los resultados del clasificador SVM en el conjunto de datos de prueba, resumiendo el rendimiento de la clasificación. La matriz compara las etiquetas previstas (Normal vs Fallo) con el estado real de la turbina verificada por los registros de mantenimiento.

El eje horizontal representa la etiqueta predicha (Normal o Fallo) por el sistema de detección, mientras que el eje vertical representa la condición real. Las celdas diagonales (azules) muestran el número de predicciones correctas: Normal Verdadero (abajo a la derecha), y Falla Verdadera (arriba a la izquierda). Las celdas fuera de la diagonal (rojo/naranja) indican errores: Falsas Alarmas (celda superior derecha, el sistema marcó un fallo donde no había) y Detecciones Fallidas (celda inferior izquierda, el sistema no detectó un fallo real).

Como se muestra en la Fig. 6, la mayoría de los casos de fallo verdadero fueron correctamente identificados por el sistema (alto recuento de positivos verdaderos en la celda de fallo/fallo), mientras que la mayoría de los puntos de funcionamiento normales fueron ignorados correctamente. Un pequeño número de casos fueron mal clasificados – algunos falsos negativos (fallos pasados por alto) y algunos falsos positivos (falsas alarmas) – pero estos fueron limitados.

Cuantitativamente, el enfoque alcanzó una tasa de detección de anomalías de aproximadamente el 58,5% y una tasa de falsas alarmas del 2,6%. Esto supone una mejora notable respecto a un método tradicional de umbral de desviación de curva de potencia, que en nuestras pruebas detectó solo los fallos más extremos y tuvo dificultades para equilibrar sensibilidad y especificidad. Normalizando el rendimiento con WPI y aplicando la clasificación, el sistema híbrido puede detectar anomalías con más precisión.




Fig. 6 Matriz de confusión de los resultados de clasificación de anomalías con SVM (en datos de prueba).

B. Rendimiento de la detección de anomalías para algunas turbinas eólicas específicas

Las turbinas 4–6 en Alpha Ventus se encuentran en la fila central de la cuadrícula del parque eólico (Fig. 5). En consecuencia, las estelas de las turbinas de la fila delantera reducen la velocidad del viento y aumentan la turbulencia. Esto se confirma con los datos SCADA. Por ejemplo, la Turbina 5 (aguas abajo de la Turbina 2) presenta frecuentes grandes correcciones del error de guiñada y una potencia de salida a veces errática. Presenta muchos valores atípicos de baja potencia (especialmente con vientos bajos) y un corte brusco con vientos altos. La turbina 4 muestra una curva de potencia ampliamente dispersa entre vientos moderados y altos, mientras que la turbina 6 (también a favor del viento

pero desplazada) se mantiene relativamente estable con menos valores atípicos en vientos medios. Por tanto, WT4–6 tienen un rendimiento sistemático inferior a sus curvas ideales bajo viento del noroeste.

Analizando los datos, el modelo k-NN identificó efectivamente una "variabilidad significativa en la salida" para las turbinas 4–6 debido a las estelas. De igual modo, la Máquina de Vectores Soporte (SVM) aprendió una frontera de decisión suave alrededor de la curva nominal potencia-viento de la turbina. Los puntos que representan la potencia reducida por la estela caen por debajo de este límite y se clasifican como anomalías. Así, ambos modelos interpretan consistentemente las desviaciones de bajo consumo de WT4–6 como anomalías.

A partir de estos resultados, se utilizó el índice (WPI) normalizado y una SVM para identificar con mayor precisión las desviaciones debidas a las estelas. WT4, en particular, mostró valores de WPI persistentemente más bajos que las turbinas impares (por ejemplo, WT5), lo que se correlaciona con paradas reales, desencadenando intervenciones de mantenimiento (Fig. 7).




Fig. 7: De arriba a abajo, Velocidad del viento normalizada, potencia normalizada, índice WPI, y clasificación de anomalías para WT4.

La inclusión de WPI permitió al modelo SVM separar fallas específicas de turbinas causadas por variaciones ambientales, confirmando su eficacia para detectar fallos debidos a la estela.

C. Escalabilidad y generalización:

Una ventaja notable de la normalización WPI es que proporciona una escala de rendimiento independiente de la turbina. Se ha aplicado el mismo modelo de detección (umbrales de distancia k-NN y parámetros SVM) para turbinas de distinto tipo e incluso a un conjunto de datos más pequeño de un segundo parque eólico marino (con turbinas de diferente marca y modelo). Solo se requirió un ajuste mínimo y la metodología mantuvo un buen rendimiento, lo que sugiere que el enfoque generaliza bien.

Esto contrasta con otros modelos tradicionales que deben ser reentrenados para cada turbina. Los requisitos computacionales del sistema son modestos: el cálculo WPI y las comprobaciones de distancia k-NN son ligeros, y la clasificación SVM es rápida, lo que hace posible el despliegue en tiempo real para decenas de turbinas en hardware de monitorización estándar. Para un nuevo parque eólico, el modelo requeriría inicialmente un periodo de recopilación de datos para establecer la WPI base y entrenar al SVM. Después de eso, puede ejecutarse de forma continua, actualizando su conjunto de datos según sea necesario.

D. Limitaciones:

Cabe señalar que la eficacia del clasificador SVM depende de la disponibilidad de ejemplos representativos de fallos para el entrenamiento. En la práctica, los datos conocidos de fallos pueden ser limitados. En este estudio se ha ampliado el conjunto de entrenamiento con una combinación de fallos históricos y datos simulados de fallos (a partir de simulaciones de turbinas con el software de alta fidelidad OpenFast), para asegurar que la SVM detectara variedad de anomalías.

Otra limitación es que k-NN puede ser sensible a la elección de características y a la presencia de datos ruidosos; un preprocesamiento y normalización cuidadosos (como el WPI) mitigan esto pero no eliminan todos los problemas.

V. CONCLUSIONES

En este trabajo se presenta un marco basado en datos para la detección y clasificación de fallos en aerogeneradores marinos, combinando un índice de rendimiento informado por la física con técnicas de aprendizaje automático. El enfoque integra un Índice de Potencia Eólica normalizado, WPI, con modelos de detección de anomalías basados en ML y la clasificación usando SVM. Esta combinación da lugar a un sistema de monitorización de fallos que es transparente, adaptable y preciso.

Es importante destacar que el enfoque funciona bien para diferentes turbinas e incluso a diferentes parques eólicos, destacando su potencial para la monitorización en entornos heterogéneos. Esto aborda una limitación clave de muchos métodos existentes, que a menudo carecen de mecanismos de generalización entre tipos de turbinas.

Estas mejoras refuerzan la viabilidad económica de la energía eólica marina, convirtiéndola en un componente más fiable del mix de energías renovables.

La capacidad de sistemas de detección de fallos basados en datos para aerogeneradores marinos puede sin embargo reforzarse. Integrar sensores IoT permitirá una mejor supervisión automatizada y en tiempo real del estado de las turbinas. También se podrían explorar modelos de aprendizaje profundo más avanzados (p. ej., autocodificadores o redes LSTM) para aprender automáticamente las representaciones de características y, potencialmente, mejorar la detección de patrones de fallos complejos. Sin embargo, estos modelos suelen sacrificar la interpretabilidad, una fortaleza del enfoque actual.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación de España en el marco de los proyectos MCI/AEI/FEDER número PID2021-123543OB-C21 y PID2024-155653OB-C21.

REFERENCIAS

- [1] Intergovernmental Panel on Climate Change (IPCC), Climate Change 2022 – Mitigation of Climate Change: Working Group III Contribution to the Sixth Assessment Report of the IPCC, “Energy Systems,” Cambridge Univ. Press, 2023, pp. 613–746.
- [2] J. Liu, X. Liu, and Y. Wang, “How does renewable energy consumption affect carbon emission intensity? Temporal-spatial impact analysis in China,” *Energy*, vol. 284, Art. 128690, Dec. 2023.
- [3] S. Zhao et al., “Impacts of renewable energy on climate risk: A global perspective for energy transition in a climate adaptation framework,” *Applied Energy*, vol. 362, Art. 122994, May 2024.
- [4] M. K. Zribi and M. B. Amar, “The Importance of Renewable Energy in Economic Growth: Evidence from a Panel of Emerging Countries,” *Romanian Economic Journal*, vol. 18, no. 59, pp. 125–142, Mar. 2016.
- [5] Global Wind Energy Council (GWEC), Global Wind Report 2025, Apr. 2025, p. 5. [Online]. Available: <https://gwec.net/global-wind-report-2025>
- [6] International Energy Agency (IEA), “Tripling renewable power capacity by 2030 is vital to keep the 1.5 °C goal within reach,” Jul. 21, 2023. [Online]. Available: <https://www.iea.org/news/tripling-renewable-power-capacity-by-2030-is-vital-to-keep-the-1-5-c-goal-within-reach>
- [7] Port of Taranto, “Port of Taranto welcomes the first offshore wind farm in the Mediterranean,” Apr. 22, 2022. [Online]. Available: <https://www.port.taranto.it/en/news/port-of-taranto-offshore-wind-farm>
- [8] U.S. Department of Energy, An Operations and Maintenance Roadmap for U.S. Offshore Wind, May 2024. [Online]. Available: <https://www.energy.gov/sites/default/files/2024-05/operations-maintenance-roadmap-us-offshore-wind.pdf>
- [9] ABPmer, “Floating offshore wind and the importance of weather downtime,” Blog post, Aug. 30, 2024. [Online]. Available: <https://www.abpmer.co.uk/blog/floating-offshore-wind-and-the-importance-of-weather-downtime/>
- [10] R. D. Frederiksen, G. Bocewicz, G. Radzki, Z. Banaszak, and P. Nielsen, “Cost-Effectiveness of Predictive Maintenance for Offshore Wind Farms: A Case Study,” *Energies*, vol. 17, no. 13, p. 3147, 2024.
- [11] R. Pandit, D. Astolfi, J. Hong, D. Infield, and M. Santos, “SCADA data for wind turbine data-driven condition/performance monitoring: A review on state-of-the-art, challenges and future trends,” *Wind Engineering*, vol. 47, pp. 422–441, 2022.
- [12] H. Holttinen, IEA Wind TCP Annual Report 2023 – Executive Summary, IEA Wind, 2023. [Online]. Available: https://orbit.dtu.dk/files/390116670/IEA_Wind_TCP_Annual_Report_2023_ExecutiveSummary_251124_k1.pdf
- [13] National Renewable Energy Laboratory (NREL), “Wind Power Reliability Research,” NREL webpage, accessed 2025. [Online]. Available: <https://www.nrel.gov/wind/reliability> “Treatment episode data set: discharges (TEDS-D): concatenated, 2006 to 2009.” U.S. Department of Health and Human Services, Substance Abuse and Mental Health Services Administration, Office of Applied Studies, August, 2013, DOI:10.3886/ICPSR30122.v2
- [14] B. Weiss, S. Esteban, and M. Santos, “Offshore Wind Turbines Anomalies Detection Based on a New Normalized Power Index,” *Comput. Model. Eng. Sci.*, vol. 144, no. 3, pp. 3387–3418, 2025, doi:10.32604/cmes.2025.070070.
- [15] B. Weiss, S. Esteban, and M. Santos, “Data analysis and anomaly detection in a wind farm with k-Nearest Neighbors,” in *Proc. The 25th International Conference on Intelligent Data Engineering and Automated Learning (IDEAL)*, 2024, pp. 1–12.
- [16] B. Weiss, S. Esteban, and M. Santos, “Detecting Yaw Anomalies in Offshore Wind Turbines using Wind Multiple Features,” in *Proc. 20th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO)*, 2025, pp. 1–9.
- [17] RAVE. Research at Alpha Ventus. RAVE-offshore.de. 2025. Available from: <https://rave-offshore.de/en/start.html> [Accessed 2025 May].
- [18] OpenFAST (Version 3.5.0) [Computer software] (2024). National Renewable Energy Laboratory. <https://github.com/OpenFAST/openfast> [Accessed 2025 May].

Hacia la optimización de la energía eólica urbana: análisis preliminar mediante Dinámica de Fluidos Computacional

Towards the Optimization of Urban Wind Energy: Preliminary Analysis Using Computational Fluid Dynamics

1st S. Ocaña-Muñoz

Dpto. Estructura de la Materia, Física
Térmica y Electrónica
Universidad Complutense de Madrid
Madrid, España
Email: socana01@ucm.es

2nd J. Contreras-Martínez

Dpto. Estructura de la Materia, Física
Térmica y Electrónica
Universidad Complutense de Madrid
Madrid, España
Email: jcontr01@ucm.es

Abstract— Climate change and the growing global energy demand are driving the transition toward sustainable systems based on renewable energy sources. Wind energy, although consolidated as a mature technology, faces limitations for deployment in urban environments due to turbulence and spatial constraints. In this context, small-scale wind technology, particularly Vertical Axis Wind Turbines (VAWTs), emerges as a viable alternative for out grid or distributed generation in cities. However, the complexity of urban wind resources requires advanced tools for accurate characterization. This work proposes the use of Computational Fluid Dynamics (CFD) to analyze wind behavior in urban environments and evaluate the performance of the EOLI-MiniWindTurbine under high turbulence conditions. Preliminary results indicate that the design is robust against variations in turbulence intensity, reinforcing its potential for urban applications. Further simulations will consider different wind incidence angles and turbulence levels, contributing to the optimization of wind technologies for complex urban environments.

Keywords—*Computational Fluid Dynamics, Urban wind resource, Low-power wind energy, Numerical modeling, Renewable energy*

Resumen – El cambio climático y la creciente demanda energética global impulsan la transición hacia sistemas sostenibles basados en energías renovables. La energía eólica, consolidada como tecnología madura, presenta limitaciones para su implantación en entornos urbanos debido a la turbulencia y restricciones espaciales. En este contexto, la tecnología minieólica, especialmente los aerogeneradores de eje vertical (VAWT), surge como alternativa viable para generación aislada o distribuida en ciudades. Sin embargo, la complejidad del recurso eólico urbano exige herramientas avanzadas para su caracterización. Este trabajo propone el uso de Dinámica de Fluidos Computacional (CFD) para analizar el comportamiento del viento en entornos urbanos y evaluar el rendimiento de la turbina EOLI-MiniWindTurbine bajo condiciones de alta turbulencia. Los resultados preliminares indican que el diseño es robusto frente a variaciones en la intensidad turbulenta, lo que refuerza su potencial para

aplicaciones urbanas. Se prevé ampliar el estudio mediante simulaciones adicionales que consideren diferentes ángulos de incidencia y niveles de turbulencia, contribuyendo a la optimización de tecnologías eólicas para entornos urbanos complejos.

Keywords — *Dinámica de fluidos computacional, Recurso eólico urbano, Energía eólica de baja potencia, Modelado numérico, Energía renovable*

I. INTRODUCCIÓN

El cambio climático se ha consolidado como uno de los principales desafíos globales del siglo XXI. Según Naciones Unidas, el sector energético es responsable de la mayor parte de las emisiones globales de gases de efecto invernadero, lo que sitúa a la producción y al consumo de energía en el centro de las estrategias de descarbonización. En este contexto, la ONU subraya la necesidad de acelerar la transición hacia sistemas energéticos sostenibles, basados en la mejora de la eficiencia energética y en la sustitución progresiva de los combustibles fósiles por fuentes de energía renovables [1].

La demanda energética mundial continúa creciendo de forma sostenida como consecuencia del crecimiento demográfico, el desarrollo económico y del desarrollo tecnológico de sectores clave como la industria, el transporte y los servicios. Este incremento se refleja especialmente en el consumo eléctrico global, que mantiene una tendencia ascendente a largo plazo. No obstante, a pesar del avance de las tecnologías renovables, el sistema energético mundial sigue presentando una fuerte dependencia de los combustibles fósiles: en torno al 80 % de la energía primaria consumida a nivel global procede todavía de fuentes no renovables, siendo el carbón, el petróleo y el gas natural los principales contribuyentes al mix energético mundial [2].

En las últimas décadas, tecnologías como la energía solar, la hidráulica y la eólica han experimentado un incremento significativo de su capacidad instalada a escala global, acompañado de una reducción progresiva de costes. En particular, la energía eólica se ha consolidado como una de las tecnologías renovables más desarrolladas desde el punto de

vista industrial, destacando por su bajo impacto ambiental durante la fase de operación y su contribución creciente a la generación eléctrica mundial [2].

El sector de energía eólica, como generación eléctrica a gran escala, se ha desarrollado a finales del siglo XX y a lo largo de todo el siglo XXI. Como se puede ver en la Fig. 1, en la cual se ve que se ha producido un aumento exponencial en la potencia total instalada.

Además del incremento exponencial de capacidad instalada, la Fig. 1 pone de manifiesto la evolución tecnológica del sector. A medida que la potencia unitaria de los aerogeneradores aumenta (pasando de máquinas de menos de 1 MW en los años 90 a prototipos comerciales de 13–20 MW en la actualidad) también lo hace su tamaño, con alturas de buje cercanas o superiores a los 150–200 m. Esta tendencia responde a la necesidad de llegar a capas atmosféricas con mayor velocidad media y menor turbulencia, lo que incrementa el rendimiento energético por turbina. Por otro lado, la curva azul muestra que la tasa de crecimiento del sector, aunque irregular, ha mantenido valores positivos durante casi todo el periodo, alcanzando un máximo en 2009 (31 %) y estabilizándose posteriormente. En conjunto, la figura refleja un doble proceso: expansión acelerada del tamaño de los aerogeneradores y una maduración tecnológica que ha permitido aumentar significativamente la potencia específica de cada aerogenerador.

Aun siendo una tecnología madura y con un alto grado de implantación, posee algunas limitaciones que pueden dificultar su implantación. Los aerogeneradores presentan problemas con respecto a las turbulencias, como una reducción de su producción y daños estructurales a las turbinas, lo que limita su ámbito de implantación, dejando fuera todas aquellas localizaciones que presenten una turbulencia elevada [3].

Además, este tipo de turbinas dedicadas a la gran generación, poseen actualmente unas dimensiones, como las mostradas en la Fig. 1, que les permite aprovechar vientos en altura (80–150 m) con baja carga turbulenta, lo que impide su implantación en las cercanías de zonas urbanas, debido a sus afecciones radio eléctricas e impactos visuales y acústicos. Así mismo, estas máquinas están destinadas al aprovechamiento de vientos en altura, con promedios superiores a los 5 m/s y constantes, preferentemente, lo que excluye todas aquellas zonas que no cumplan estas condiciones. [3]

La presencia de edificios, calles estrechas y elementos urbanos introduce discontinuidades en el flujo, generando estelas, remolinos y aceleraciones locales que dificultan la explotación eficiente del viento mediante tecnologías eólicas convencionales.

Como señalan informes de la ONU: la expansión de la generación renovable debe adaptarse a las características específicas de los distintos entornos de implantación [1]. En este sentido, el desarrollo de grandes infraestructuras eólicas en zonas urbanizadas presenta ciertas limitaciones, lo que ha impulsado el interés por soluciones de pequeña escala. La minieólica, y en particular los aerogeneradores de eje vertical surgen como solución a la necesidad de utilizar las energías renovables como fuente principal de energía para las ciudades y centros urbanos.




Fig. 1 Capacidad total instalada entre 1990 y 2025. [2]

Sin embargo, la viabilidad de estas soluciones depende de una caracterización precisa del viento en entornos complejos y altamente turbulentos, lo que hace necesario el empleo de herramientas avanzadas de análisis y simulación para evaluar su rendimiento real [2], así como el desarrollo de tecnologías específicas para estos regímenes de viento.

Por las problemáticas existentes ya expuestas, las turbinas eólicas convencionales de eje horizontal (Conventional Horizontal Axis Wind Turbines (HAWTs)) son ineficientes para su instalación como fuente de energía en centros urbanos. Sin embargo, los avances en los aerogeneradores de baja potencia tanto de eje horizontal (HAWTs) o vertical (Small Vertical Axis Wind Turbines (VAWTs)) han demostrado una creciente eficiencia para utilizarlas en áreas residenciales o en terrenos urbanizados a baja altura y con vientos de alta carga turbulenta. [2] Este avance ha sido posible gracias, entre otros, al desarrollo de nuevos alternadores que permiten aprovechar regímenes de giro bajo y nuevos conceptos aerodinámicos para el aprovechamiento de vientos [4].

Por todo lo descrito anteriormente, es necesario estudiar el comportamiento de estas máquinas y verificar sus rendimientos para los vientos turbulentos propios de los entornos urbanos asegurando la viabilidad de su futura implantación.

En esta investigación, proponemos el uso de herramientas de Dinámica de Fluidos Computacional (CFD) como metodología principal para el análisis del viento en entornos urbanos complejos. Mediante estas herramientas se estudia el comportamiento del flujo alrededor de edificaciones y se evalúa la viabilidad de los aerogeneradores de baja potencia, concretamente en este estudio se evalúa EOLI-MiniWindTurbine.

II. FUNDAMENTO TEÓRICO

Para el correcto entendimiento de estas tecnologías de producción eólica de baja potencia dentro de entornos urbanos, es necesario detallar las características del viento en estas ubicaciones. El viento en la atmósfera difiere horizontal y verticalmente debido a la rotación terrestre, la topografía y los objetos de la superficie, formándose así la capa límite atmosférica (Atmospheric Boundary Layer (ABL)). Esta capa está fundamentalmente afectada por la fuerza gravitacional terrestre, la fricción de la superficie, la radiación solar y la turbulencia. Para obtener datos de velocidad de viento en la ABL se suele utilizar un método logarítmico que define la velocidad media a una determinada altura z : [2]

$$v_z = \frac{u^*}{k_1} \cdot \ln \left(\frac{z - z_d}{z_0} \right) \quad (1)$$

$$v_z = v_h \cdot \left(\frac{z}{h} \right)^\alpha \quad (2)$$

Donde k_1 es 0,4; z_d es la altura del plano cero, por ejemplo, la altura a la cual la obstrucción de objetos en la superficie hace el viento más o menos 0, v_h es la velocidad del viento a una altura h y α normalmente está entre 0,25 y 0,4 en ciudades densamente pobladas [5]. El método logarítmico solo es aplicable para las alturas medidas de 20 a 100 m por encima del nivel del suelo. [2]

Para entender la complejidad del recurso eólico urbano, es necesario comprender el concepto de turbulencia inducida por entornos urbanos: “se trata de un movimiento irregular, tridimensional y no predecible del flujo, caracterizado por fluctuaciones rápidas de velocidad alrededor de un valor medio, resultado de la interacción entre el viento medio y los obstáculos del entorno urbano” [6].

Las características de la circulación del aire alrededor de los edificios están definidas por la manera en la que interactúan los edificios con las condiciones climáticas alrededor. En la Fig. 2 aparecen los tres tipos principales de circulación de aire alrededor de edificios individuales.

En la Fig. 2 se ve claramente representada la relación entre la geometría del edificio y la dirección del viento, con el flujo en entornos urbanos. En el caso (a), el flujo lateral genera unas líneas de corriente prácticamente paralelas a las superficies del edificio, modificando mínimamente su trayectoria, lo que conlleva una baja intensidad turbulenta en las paredes laterales, al contrario de lo que sucede en las paredes frontales donde existirá una alta carga turbulenta. Por el contrario, en los casos (b) y (c), con incidencia frontal del viento en las superficies de mayor dimensión, se produce una aparición de remolinos intensos en sotavento, incrementándose significativamente la turbulencia en estas zonas más amplias que en el escenario (a). Estas características explican la elevada variabilidad del recurso eólico urbano y justifican la necesidad de herramientas CFD para identificar zonas localmente aceleradas o con patrones de flujo favorables para la implantación de sistemas de minieólica [2].

Dado el comportamiento complejo y turbulento del viento en entornos urbanos, surge la necesidad de desarrollar tecnologías capaces de aprovechar eficazmente este recurso irregular y localmente acelerado. Para ello, la minieólica se constituye como una alternativa viable para la generación distribuida en ciudades.

Las turbinas eólicas convencionales tienen un diámetro de rotor típico de entre 50 y 100 metros, produciendo una potencia de entre 1 y 3 MW. Los aerogeneradores de baja potencia, por otro lado, suelen tener un diámetro de entre 3 y 10 metros y una potencia de 1,4-20 kW. La Tabla I muestra una relación entre el diámetro del rotor y la potencia que es capaz de generar cada turbina [7], lo que permite definir los usos a los que está enfocada.

En las localizaciones alejadas de la red eléctrica, los aerogeneradores de pequeña escala pueden actuar como una fuente de energía útil, tanto de manera aislada como conectados a redes existentes. Las diferencias de diseño, rendimientos, producciones esperadas y costes asociados a cada tecnología propuesta hacen necesario estudiar y comprender los diferentes tipos de aerogeneradores de pequeña escala disponibles en la actualidad [7].




Fig. 2 Circulación característica del flujo de viento alrededor de edificios individuales: (a) flujo lateral alrededor del edificio, baja intensidad turbulenta; (b) interacción del viento con un edificio alto bajo incidencia frontal (perpendicular), que genera una elevada turbulencia; (c) interacción del viento con un edificio bajo, caracterizada por una mayor turbulencia predominantemente bidimensional. [2]

Tabla I. Comparación entre diámetro del rotor y potencia nominal para aerogeneradores de eje horizontal.

Categoría	Diámetro del rotor (m)	Potencia nominal (kW)
Micro	0.5 a 1.25	0.004 a 0.25
Mini	1.25 a 3.00	0.25 a 1.4
Uso doméstico	3 a 10	1.4 a 16
Comercial (pequeña escala)	10 a 20	25 a 100
Comercial (mediana escala)	20 a 50	100 a 1000
Comercial (gran escala)	50 a 100	1000 a 3000

Los aerogeneradores de pequeña escala se pueden clasificar en función de dos categorías. Basándonos en su eje de rotación: turbinas de eje vertical, las cuales no tienen un mecanismo de orientación ni capacidad de autoarranque, el generador se localiza en el suelo y su altura es muy baja facilitando el mantenimiento siendo su eficiencia ideal mayor al 70%; y las turbinas de eje horizontal, con capacidad de autoarranque y un mecanismo de orientación, cuyas producciones dependen mucho de la dirección del viento, siendo su altura mayor que las de eje vertical y su eficiencia ideal de entre 50 y 60 % [7].

En conclusión, las turbinas de eje vertical (VAWT) presentan mejor comportamiento en entornos turbulentos y no requieren mecanismos de orientación, lo que las hace adecuadas para áreas urbanas o con cambios rápidos de dirección del viento. Por el contrario, las turbinas de eje horizontal (HAWT) ofrecen mayores eficiencias y mejor rendimiento a altas velocidades, siendo más adecuadas para emplazamientos abiertos con recurso eólico estable.

III. MÉTODO EXPERIMENTAL

Dada la complejidad del comportamiento del viento en zonas urbanas y el aprovechamiento de ese recurso eólico urbano, se han desarrollado una serie de herramientas, capaces de modelar las condiciones del viento y del terreno, para lograr aprovechar dicho recurso. En este contexto es donde la Dinámica de Fluidos Computacional (Computational Fluid Dynamics (CFD)) se establece como una herramienta contrastada para el diseño y evaluación de los aerogeneradores de baja potencia, así como para el estudio del comportamiento del recurso eólico dentro de estos entornos. En este estudio, concretamente, nos centraremos en un aerogenerador de eje vertical: EOLI-MiniWindTurbine. [8]

Las herramientas CFD emplean métodos numéricos y algoritmos para simular y predecir el comportamiento de un fluido y sus propiedades, tales como su velocidad, presión y densidad. Modela problemas de flujo complejos que son irresolubles analíticamente. Para ello, resuelve las ecuaciones de Navier-Stokes. Estas, son un conjunto de ecuaciones diferenciales parciales acopladas que describen la relación

entre la aceleración del fluido, los gradientes de presión, los esfuerzos viscosos y las fuerzas externas.

El procedimiento de simulación comprende la definición de la geometría y de los modelos físicos relevantes, la discretización del dominio mediante una malla (refinada en las zonas de mayor gradiente del flujo) y la imposición de condiciones de contorno representativas del problema real. A partir de ello, el solucionador numérico itera hasta alcanzar la convergencia, obteniéndose campos de flujo que pueden ser analizados mediante técnicas de postprocesado [8].

Para la simulación de flujos turbulentos (como el viento urbano), las ecuaciones de Navier-Stokes deben ser modificadas mediante un modelo de turbulencia. El modelo empleado en este estudio es el RANS (Reynolds-Averaged Navier-Stokes), que promedia las fluctuaciones turbulentas en el tiempo, reduciendo significativamente la demanda computacional. Dentro del RANS, se emplea el modelo $k-\varepsilon$ de bajo número de Reynolds (*low-Re k-ε*), para resolver de forma explícita la región próxima a la pared sin recurrir a funciones de pared, lo que lo hace adecuado para flujos con fuertes gradientes de velocidad y elevada turbulencia a baja altura, característicos de entornos urbanos. Para estudios más detallados, se utiliza LES (Large Eddy Simulation) que resuelve las grandes estructuras de turbulencia y modela solo las pequeñas [8].

Para un fluido viscoso, las ecuaciones que predominan y que el CFD debe resolver son:

$$\frac{\partial \rho}{\partial t} + \nabla \cdot (\rho V) = 0 \quad (3)$$

$$\frac{\partial (\rho u)}{\partial t} + \nabla \cdot (\rho u V) = -\frac{\partial p}{\partial x} + \frac{\partial \tau_{xx}}{\partial x} + \frac{\partial \tau_{yx}}{\partial y} + \frac{\partial \tau_{zx}}{\partial z} + \rho f_x \quad (4)$$

$$\frac{\partial (\rho v)}{\partial t} + \nabla \cdot (\rho v V) = -\frac{\partial p}{\partial y} + \frac{\partial \tau_{xy}}{\partial x} + \frac{\partial \tau_{yy}}{\partial y} + \frac{\partial \tau_{zy}}{\partial z} + \rho f_y \quad (5)$$

$$\frac{\partial (\rho w)}{\partial t} + \nabla \cdot (\rho w V) = -\frac{\partial p}{\partial z} + \frac{\partial \tau_{xz}}{\partial x} + \frac{\partial \tau_{yz}}{\partial y} + \frac{\partial \tau_{zz}}{\partial z} + \rho f_z \quad (6)$$

$$\begin{aligned} \frac{\partial}{\partial t} \left[\rho \left(e + \frac{V^2}{2} \right) \right] + \nabla \cdot \left[\rho \left(e + \frac{V^2}{2} \right) V \right] = \\ \rho \dot{q} + \frac{\partial}{\partial x} \left(k \frac{\partial T}{\partial x} \right) + \frac{\partial}{\partial y} \left(k \frac{\partial T}{\partial y} \right) + \frac{\partial}{\partial z} \left(k \frac{\partial T}{\partial z} \right) \\ - \frac{\partial (up)}{\partial x} - \frac{\partial (vp)}{\partial y} - \frac{\partial (wp)}{\partial z} + \frac{\partial (u\tau_{xx})}{\partial x} + \frac{\partial (u\tau_{yx})}{\partial y} + \\ \frac{\partial (u\tau_{zx})}{\partial z} + \frac{\partial (v\tau_{xy})}{\partial x} + \frac{\partial (v\tau_{yy})}{\partial y} + \frac{\partial (v\tau_{zy})}{\partial z} + \end{aligned}$$

$$\frac{\partial (w\tau_{xz})}{\partial x} + \frac{\partial (w\tau_{yz})}{\partial y} + \frac{\partial (w\tau_{zz})}{\partial z} + \rho f \cdot V \quad (7)$$

Siendo (3) la ecuación de continuidad, (4), (5) y (6), las ecuaciones de conservación del momento (para la componente “x”, “y” y “z”, respectivamente) y (7) la ecuación de la energía, constituyendo todas ellas las denominadas Ecuaciones de Navier-Stokes. [9]

Para este estudio vamos a utilizar una licencia educativa de Autodesk CFD, un software de dinámica de fluidos computacional desarrollado por Autodesk. Esto permite la simulación numérica de fluidos complejos [10].

Se utilizará un modelo 3D de la máquina EOLI-MiniWindTurbine, presentado en la Fig 3, el cual será cargado en la herramienta CFD. Sobre él se simularán diferentes cargas turbulentas y condiciones de viento para analizar el comportamiento de esta máquina en distintos escenarios. La Fig. 4 muestra una imagen del aerogenerador instalado en un entorno real de ensayo, junto al detalle de su parte interna y externa.




Fig. 3 Modelo 3D del aerogenerador EOLI-MiniWindTurbine.



Fig. 4 Imagen real del aerogenerador EOLI-MiniWindTurbine y su detalle interior y exterior.

IV. RESULTADOS

La incorporación del modelo tridimensional de la turbina EOLI-MiniWindTurbine en el software Autodesk CFD permite analizar su comportamiento aerodinámico bajo diferentes condiciones de flujo, ajustando parámetros clave del entorno como velocidad del viento, intensidad de turbulencia y ángulo de incidencia.

Para la resolución numérica del modelo se ha empleado el esquema ADV5 junto con el modelo de turbulencia Low Re $k-\varepsilon$, ampliamente utilizado en estudios de aerodinámica por su equilibrio entre precisión y coste computacional. Este análisis constituye la base para futuras simulaciones que incluirán variaciones en el ángulo de incidencia y configuraciones

urbanas más complejas, con el objetivo de optimizar el diseño y validar su comportamiento en escenarios reales.

En estudios previos [11], la simulación se realizó considerando una intensidad de turbulencia baja (0,05) bajo incidencia de viento normal, representativa de entornos abiertos. En esta fase, se ha incrementado dicho parámetro hasta 0,4 con incidencia de viento normal, para reproducir condiciones más realistas en entornos urbanos y evaluar su impacto en el torque y la distribución del flujo alrededor del rotor. La Fig. 5 muestra los campos de velocidad obtenidos para intensidades de turbulencia de 0,05 (Fig. 5a) y 0,4 (Fig. 5b), evidenciando diferencias en la redistribución del flujo alrededor del rotor y en las aceleraciones locales.




Fig. 5 Velocidades de viento con intensidad de turbulencia 0,05 (a) y con intensidad de turbulencia 0,4 (b).

A partir de estos resultados, se ampliará el estudio mediante simulaciones adicionales en las que se variará el ángulo de incidencia del viento, además de la intensidad de turbulencia, con el objetivo de cuantificar de forma más completa el impacto de la turbulencia y de las condiciones de entrada en el comportamiento del rotor. Asimismo, se prevé incorporar configuraciones urbanas más complejas para reproducir de manera más fiel el entorno urbano en el que se instalaría el futuro aerogenerador, además de optimizar el diseño y continuar validando el comportamiento del aerogenerador en escenarios representativos.

V. CONCLUSIONES

Los resultados obtenidos en esta fase sugieren que el diseño aerodinámico de la turbina EOLI-MiniWindTurbine presenta un comportamiento robusto frente a variaciones en la intensidad de turbulencia, lo que refuerza su potencial para aplicaciones en entornos urbanos caracterizados por flujos altamente irregulares. La metodología basada en Dinámica de Fluidos Computacional (CFD) ha demostrado ser una herramienta eficaz para la caracterización del recurso eólico urbano y la evaluación del rendimiento de aerogeneradores de baja potencia.

No obstante, el estudio se encuentra en desarrollo y requiere la realización de simulaciones adicionales que consideren diferentes ángulos de incidencia, regímenes de viento y configuraciones urbanas más complejas. Estas etapas permitirán consolidar los resultados preliminares y avanzar hacia la optimización del diseño, contribuyendo a la integración de tecnologías minieólicas en estrategias de generación distribuida en ciudades sostenibles.

REFERENCIAS

[1] United Nations Statistics Division, International Energy Agency, International Renewable Energy Agency & World Bank. (2025). The Energy Progress Report 2025. United Nations.

[2] Liu, S., Zhang, L., Lu, J., Zhang, X., Wang, K., Gan, Z., Liu, X., Jing, Z., Cui, X., & Wang, H. (2025). Advances in urban wind resource development and wind energy harvesters. *Renewable And Sustainable Energy Reviews*, 207, 114943. DOI:10.1016/j.rser.2024.114943

[3] Liu, S., Zhang, L., Lu, J., Zhang, X., Wang, K., Gan, Z., et al. (2025). Urban wind resource development and wind energy harvesters. *Renewable and Sustainable Energy Reviews*, 207, 114943.

[4] Msuya, R. A., Kichonge, B., & Nditi, G. (2017). Design of a small-scale wind generator for low wind speed environment. *Tanzania Journal of Science*, 43(1), 60–72. DOI:10.4314/tjs.v43i1.5

[5] Stull, R. B. (1988). An Introduction to Boundary Layer Meteorology. DOI:10.1007/978-94-009-3027-8

[6] Rotach, M. W. (1999). On the influence of the urban roughness sublayer on turbulence and dispersion. *Atmospheric Environment*, 33(24-25), 4001-4008. DOI:10.1016/s1352-2310(99)00141-7

[7] Tummala, A., Velamati, R. K., Sinha, D. K., Indrāja, V., & Krishna, V. H. (2015). A review on small scale wind turbines. *Renewable And Sustainable Energy Reviews*, 56, 1351-1371. DOI:10.1016/j.rser.2015.12.027

[8] Fazlizan, A., Muzammil, W. K., & Al-Khawlani, N. A. (2025). A Review of Computational Fluid Dynamics Techniques and Methodologies in Vertical Axis Wind Turbine Development. *Computer Modeling In Engineering & Sciences*, 144(2), 1371-1437. DOI:10.32604/cmescs.2025.067854

[9] Anderson, J. D. (1995). Computational fluid dynamics: the basics with applications. <http://www.loc.gov/catdir/description/mh022/94021237.html>

[10] Hu, Y., Xu, F., & Gao, Z. (2022). A Comparative Study of the Simulation Accuracy and Efficiency for the Urban Wind Environment Based on CFD Plug-Ins Integrated into Architectural Design Platforms. *Buildings*, 12(9), 1487. DOI:10.3390/buildings12091487

[11] Jairo, M. O. (2025). Estudio computacional de dinámica de fluidos (CFD) para aerogeneradores de eje vertical y baja potencia. <https://docta.ucm.es/entities/publication/bc669e89-3a22-4374-8edf-1da662dd662e>

Sistema Neuro-difuso para Capturar el Comportamiento de una Turbina Eólica Marina en la Región de Carga Parcial

Neuro-fuzzy System to Capture the Behavior of an Offshore Wind Turbine in the Partial Load Region

Eduardo Muñoz- Palomeque
Department of Communication and
Control Systems
National University of Distance Education
Madrid, Spain
0000-0001-8994-3459

Matilde Santos
Institute of Knowledge Technology
Complutense University of Madrid
Madrid, Spain
0000-0003-1993-8368

Enrique Sierra-García
Digitalization Department
University of Burgos
Burgos, Spain
0000-0001-6088-9954

Abstract—This work evaluates, through simulation, the capability of an Adaptive Neuro-Fuzzy Inference System (ANFIS) to reproduce the dynamic behaviour of a Floating Offshore Wind Turbine (FOWT) during Maximum Power Point Tracking (MPPT). The reference controller employed is based on a Proportional–Integral–Derivative (PID) regulator. The ANFIS model, designed to learn nonlinear relationships from data, is trained using operational information from the turbine in order to emulate the control actions involved in the maximum power extraction process, without requiring a detailed mathematical formulation of the system. The performance of the proposed model is assessed by comparing the generated power with that obtained from the PID controller. Error metrics are also used to quantify the accuracy of the power estimation. The results show that ANFIS can effectively learn the behavior of a complex floating wind system and reproduce its response with an adequate level of fidelity, reflected in a mean absolute percentage error of approximately 7%.

Keywords—ANFIS, MPPT, PID, Soft computing, Wind Turbine

Resumen—Este trabajo evalúa, mediante simulación, la capacidad de un Sistema Neuro-difuso Adaptativo (ANFIS) para reproducir el comportamiento dinámico de una Turbina Eólica Marina Flotante (FOWT) durante el Seguimiento del Punto de Máxima Potencia (MPPT). El controlador de referencia empleado se fundamenta en un regulador Proporcional–Integral–Derivativo (PID). El modelo ANFIS, diseñado para aprender relaciones no lineales a partir de datos, se entrena con información operativa de la turbina con el fin de emular las acciones de control asociadas al proceso de extracción máxima de potencia, evitando la necesidad de una formulación matemática detallada del sistema. El desempeño del modelo propuesto se evalúa comparando la potencia generada con la obtenida mediante el controlador PID. Además, se emplean métricas de error para cuantificar la precisión de la estimación de potencia. Los resultados muestran que el ANFIS puede aprender con eficacia el comportamiento de un sistema eólico flotante complejo y reproducir su respuesta con un nivel de fidelidad adecuado, reflejado en un error porcentual absoluto medio de alrededor del 7%.

Palabras clave—ANFIS, MPPT, PID, Soft Computing, Turbina eólica

I. INTRODUCCIÓN

En las últimas décadas, la transición hacia fuentes de energía renovable representa uno de los desafíos a nivel global. En este contexto, la energía eólica marina se ha posicionado como una alternativa particularmente prometedora, al ser los vientos en mar abierto notablemente más intensos y constantes que en tierra firme [1]. Los desarrollos tecnológicos recientes han permitido el surgimiento de aerogeneradores flotantes como alternativa viable para aprovechar el vasto potencial energético en aguas profundas, aunque todavía deben superar barreras tecnológicas y de coste relacionadas con las cimentaciones y la cadena de suministro [2].

El rendimiento óptimo de estos sistemas complejos depende críticamente de la efectividad de sus estrategias de control, siendo el seguimiento del punto de máxima potencia (MPPT) una función esencial para maximizar la eficiencia en la conversión de energía. Las técnicas convencionales de MPPT, basadas principalmente en controladores PID que regulan la velocidad de rotación del rotor, han demostrado simplicidad y un desempeño inicialmente adecuado, que se ve dificultado por el manejo de las fluctuaciones del viento [3]. El ambiente marino dinámico introduce también desafíos significativos que incluyen el movimiento de las plataformas, variaciones bruscas en los patrones del viento y los efectos combinados de corrientes y oleaje, factores que comprometen la efectividad de los enfoques de control tradicionales [4].

La complejidad de estos sistemas ha motivado la exploración de paradigmas de control más avanzados [5]. Los sistemas de control inteligente se presentan como una solución prometedora, ofreciendo ventajas sustanciales en términos de adaptabilidad y robustez frente a condiciones operativas cambiantes y por manejar eficientemente las no linealidades propias de los sistemas flotantes [6]. Investigaciones recientes han documentado aplicaciones exitosas de estas tecnologías en diversos aspectos de la operación de aerogeneradores, desde la predicción de recursos hasta el control y diagnóstico temprano de fallos [7-9].

Entre las arquitecturas de control inteligente, los sistemas neuro-difusos (ANFIS) han demostrado un potencial notable al integrar la capacidad de aprendizaje de las redes neuronales con el razonamiento basado en reglas de la lógica difusa [10].

Estudios recientes han confirmado que estos sistemas pueden superar consistentemente el desempeño de controladores tradicionales en aerogeneradores convencionales [11]. Por ejemplo, en [12] los autores desarrollan un controlador ANFIS para extraer la máxima potencia de un aerogenerador de 2MW a través del ajuste de la velocidad del rotor, demostrando una mejora en comparación con el controlador PI tradicional en un amplio rango de velocidades de viento. En [13] se implementa un estimador ANFIS para predecir la velocidad del viento y un controlador con redes neuronales para rastrear la potencia máxima, demostrando en simulaciones un error menor en velocidad y potencia frente a otros métodos como Q-learning y PI. Complementariamente, en [14] se optimiza los hiperparámetros del controlador ANFIS de una turbina eólica usando Bayesian Optimization para mejorar la precisión y reducir el coste computacional. Los resultados muestran un aumento en la producción de energía y una reducción del 15% en el error cuadrático medio respecto a métodos tradicionales.

En este marco de aplicación, el presente trabajo estudia la capacidad de un modelo ANFIS para emular el comportamiento del control MPPT de un aerogenerador flotante a partir del aprendizaje de patrones obtenidos de un conjunto de datos de operación del sistema previamente medidos. El modelo ANFIS se valida en condiciones dinámicas características del ambiente marino.

La metodología propuesta integra una fase de entrenamiento supervisado del sistema neuro-difuso utilizando datos generados por un controlador convencional debidamente validado, estableciendo así una base sólida para posterior optimización del desempeño en escenarios operativos realistas.

Este artículo se organiza en las siguientes secciones principales. La sección II presenta los fundamentos teóricos necesarios para comprender el sistema eólico. La sección III describe el diseño del controlador neuro-difuso. La sección IV analiza los resultados obtenidos durante la validación del sistema. Finalmente, la sección V expone las conclusiones y sugiere líneas de investigación futuras.

II. CONCEPTOS FUNDAMENTALES EN TURBINAS EÓLICAS

Las turbinas eólicas en general, y entre ellas los modelos de turbinas marinas, son sistemas complejos que integran principios aerodinámicos, mecánicos, eléctricos y de control, diseñados específicamente para operar en ambientes donde sea posible la extracción de energía del viento.

Una turbina eólica transforma la energía cinética del viento en energía mecánica a través de sus palas, y posteriormente en energía eléctrica mediante un generador acoplado al eje de transmisión. La potencia extraída del viento está determinada por la ecuación:

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

donde R es el radio de la turbina, V_w es la velocidad del viento, ρ es la densidad del aire, y C_p es el coeficiente de potencia, que está en función del tip speed ratio (TSR o λ) y del ángulo de las palas β .

Por otra parte, las turbinas eólicas marinas (OWT) comparten su estructura fundamental con aerogeneradores terrestres, distinguiéndose principalmente en su sistema de soporte. De forma general, una OWT está compuesta por:

- Rotor: conjunto de palas y el buje, encargado de la captura energética.
- Góndola: aloja el tren de potencia, el generador, frenos y el sistema de orientación (yaw).
- Torre: soporte estructural que conecta la góndola con la cimentación.
- Cimentación o plataforma flotante, dependiendo de la profundidad del sitio.
- Sistema de control y electrónica de potencia, para garantizar estabilidad operativa y calidad de energía.

Haciendo énfasis en los tipos de sistemas de soporte, estos pueden clasificarse dependiendo de la profundidad del sitio de instalación en dos grupos:

Los de cimentación fija (hasta 50–60 m), son:

- *Monopile*: la opción más utilizada en aguas poco profundas.
- *Jacket*: empleadas en profundidades intermedias.
- *Gravity-based*: estructuras masivas apoyadas por peso.

Las plataformas flotantes (más de 60 m de profundidad), diseñadas para ubicarse en aguas profundas, donde el potencial eólico es mayor. Se clasifican en:

- *Spar-buoy*: estabilidad por lastre en profundidad.
- *Semi-submersible*: flotación distribuida en varias columnas.
- *Tension-leg platform (TLP)*: cables pretensados para restringir movimiento vertical.

Las turbinas flotantes introducen grados adicionales de libertad en el sistema, ya que la interacción entre el viento, las olas y la plataforma genera movimientos en traslación y rotación que afectan directamente la aerodinámica del rotor y las señales de control.

Además de esta dinámica y la complejidad añadida en los sistemas offshore, la intensidad del viento juega un papel importante en la tarea de control del aerogenerador. En función de la velocidad con la que impacta en viento sobre la turbina, y por tanto los efectos aerodinámicos ocasionados, se distinguen diferentes zonas de operación del sistema eólico.

La primera región, hasta una velocidad de corte mínima, el viento no genera la suficiente fuerza para hacer girar la turbina, por lo que el sistema se mantiene en reposo. A partir de la velocidad de corte mínima, hasta una velocidad nominal, el aerogenerador captura la energía del viento siguiendo el punto de máxima potencia (MPPT). En esta zona, el aerogenerador opera con normalidad, siendo controlada su velocidad de rotación para aprovechar la extracción de la máxima energía del viento a diferentes velocidades de operación.

Por último, cuando la velocidad del viento supera la velocidad nominal, el sistema de control de ángulo de las palas entra en marcha. El objetivo de esta región es mantener la potencia de salida estable en su nivel nominal, regulando el ángulo pitch, y en consecuencia, influyendo sobre la velocidad angular del generador para mantener en funcionamiento el sistema alrededor de su capacidad nominal.

III. MODELO NEURO-DIFUSO EN MPPT

El modelo ANFIS desarrollado en este trabajo tiene como objetivo reproducir la acción de control de un esquema MPPT convencional aplicado a turbinas eólicas marinas flotantes. Para ello, se utiliza como referencia un controlador basado en Direct Speed Control (DSC) complementado con un regulador PID, cuya estructura se encuentra descrita en [15]. Este controlador determina la velocidad objetivo del generador ω_{g_ref} , garantizando el funcionamiento en la región de máxima potencia mediante la ecuación:

$$\omega_{g_ref} = GB \cdot \sqrt{\frac{T_r}{K_{opt}}} \quad (2)$$

El parámetro K_{opt} (3), asociado a la operación óptima del rotor, se define en función del coeficiente de potencia máximo C_{p_opt} y de la razón de velocidad específica óptima λ_{opt} .

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

La estimación del torque aerodinámico del rotor se obtiene considerando los efectos inerciales del sistema rotor–generador:

$$T_r = T_{em} \cdot GB + \frac{\dot{\omega}_g (J_r + GB^2 J_g)}{GB} \quad (4)$$

donde J_r y J_g representan los momentos de inercia del rotor y el generador; GB es la relación de engranajes; T_{em} el torque electromagnético aplicado; y $\dot{\omega}_g$ la aceleración angular del generador.

Para que el ANFIS aprenda la relación entrada–salida del comportamiento de control de referencia, se generó un conjunto de datos provenientes de simulaciones dinámicas en la región MPPT. El dataset incluye la velocidad del viento incidente, la velocidad del generador y el torque electromagnético resultante.

Las simulaciones consideran velocidades de viento entre 8.5 y 11 m/s y el movimiento de la plataforma debido al oleaje, asegurando condiciones marinas realistas durante el proceso de aprendizaje supervisado.

El modelo ANFIS utiliza una arquitectura tipo Sugeno con dos entradas y una salida, donde aprende estos patrones de comportamiento del sistema en respuesta a condiciones ambientales aleatorias. Estas características permiten al ANFIS capturar la naturaleza no lineal del proceso MPPT con la información disponible en el entrenamiento y mantener interpretabilidad gracias a la estructura explícita de reglas difusas entrenadas con datos.

El modelo entrenado opera reproduciendo un comportamiento basado en datos medidos de un sistema, que en este caso de estudio es la decisión de control del método de referencia sin necesidad de una formulación analítica completa del sistema. Esto habilita una mayor flexibilidad frente a cambios ambientales intensos, la posibilidad de recálculo o reentrenamiento continuo ante degradación del rendimiento y la disminución del tiempo requerido para modelado de dinámicas acopladas en FOWT.

Así, el modelo ANFIS implementado en esta etapa se orienta exclusivamente a la replicación del comportamiento del controlador convencional basado en DSC–PID. El

objetivo principal consiste en evaluar la viabilidad preliminar del uso de técnicas neuro-difusas en el control MPPT para turbinas eólicas marinas flotantes, sin pretender aún superar el desempeño del esquema tradicional. Este enfoque de emulación proporciona una base sólida para, en trabajos futuros, incorporar optimización automática, capacidad adaptativa en tiempo real o la integración directa con modelos aerohidrodinámicos más complejos, avanzando hacia un controlador inteligente con mayor autonomía y robustez.

La estructura de esta arquitectura neuro-difusa se basa en dos variables de entrada: la velocidad del viento y la velocidad del generador; y una única variable de salida, correspondiente al par electromagnético necesario para regular la velocidad angular y asegurar la extracción de potencia máxima en el aerogenerador.

Para el proceso de fuzzificación, se emplean siete funciones de pertenencia de tipo gaussiano asociadas a cada una de las entradas, seleccionadas por su suavidad y su capacidad para representar transiciones graduales entre estados operativos. Con base en el esquema de particionado en cuadrícula (grid partitioning), se generan 49 reglas difusas, las cuales establecen la relación entre los valores de entrada y la salida deseada del controlador.

El modelo se entrena mediante un algoritmo híbrido que combina el método de retropropagación del error y mínimos cuadrados para la actualización de los parámetros del sistema inferencial, asegurando una convergencia rápida y estable. Este procedimiento permite optimizar tanto la estructura de reglas como la superficie de respuesta del controlador neuro-difuso.

El entrenamiento se ejecutó durante 50 épocas, tomando como criterio de finalización la ausencia de reducción significativa del error cuadrático medio (RMSE) entre iteraciones.

La operación de defuzzificación se realiza calculando el valor promedio ponderado de las salidas obtenidas por las reglas activadas, garantizando una salida continua y suave ante variaciones en las condiciones de operación.

La superficie de control resultante, altamente no lineal y con geometría irregular, refleja la capacidad del modelo para caracterizar interacciones complejas entre velocidad del viento y velocidad del rotor, respondiendo de manera adecuada ante variabilidades en el entorno de operación. (Fig. 1).




Figura 1. Superficie ANFIS de relación entradas-salida.

IV. RESULTADOS

Para validar el desempeño del modelo ANFIS, se comparó su capacidad para replicar el comportamiento del sistema regulado con un controlador convencional DSC-PID durante la operación en la región de máxima potencia (MPPT). Las pruebas se realizaron considerando escenarios realistas de operación marina, en los que se combinan variaciones aleatorias del viento, con velocidades de hasta 11 m/s, y movimientos de la plataforma debido a oleaje, con desviaciones máximas de 2.4 m respecto al nivel medio del mar (Fig. 2 y Fig. 3).




Figura 2. Velocidad de viento aleatoria.




Figura 3. Altura de las olas.

La comparación de la potencia generada evidencia que el ANFIS logra un seguimiento cercano al obtenido con los datos de referencia, replicando de manera consistente la extracción de energía máxima (Fig. 4). Las desviaciones observadas se concentran principalmente en momentos de cambios bruscos de velocidad del viento, donde la dinámica del sistema se vuelve más compleja. Sin embargo, el sistema neuro-difuso logra manejar estas dinámicas con un alto grado de eficiencia. Estas diferencias se reflejan en las métricas de error: el error porcentual absoluto medio (MAPE) se ubicó alrededor del 7%, mientras que el error relativo medio (MRE) alcanzó 8.3%, indicando un rendimiento satisfactorio incluso en un entorno altamente aleatorio.

Otras métricas estadísticas para análisis del desempeño del modelo aplicado en el sistema eólico se registran con estadísticos de error de potencia, alcanzando los siguientes valores: RMSE = 0.313 MW; y MAE = 0.255 MW. Estos resultados confirman la obtención de errores bajos en la señal de potencia equivalente con el uso del sistema neuro-difuso, confirmando su capacidad para reproducir con alta confiabilidad el comportamiento de referencia. Además, los indicadores de potencia promedio y coeficiente de potencia, en la Tabla 1, muestran que el modelo neuro-difuso mantiene

un desempeño cercano al del controlador tradicional, garantizando eficiencia energética.




Figura 4. Potencia de salida con el modelo neuro-difuso y la referencia.

TABLA 1. MÉTRICAS DE POTENCIA Y EFICIENCIA

Métrica	Respuesta ANFIS	Respuesta DSC-PID
Potencia promedio (MW)	3.59	3.75
Cp promedio	0.453	0.456

El histograma de la señal de error de potencia (Fig. 5) muestra que la mayoría de las desviaciones se concentran cerca de cero, con pocas ocurrencias de errores mayores. Esto indica estabilidad en la emulación del controlador y confirma que las pequeñas diferencias no comprometen la capacidad de seguimiento del modelo. De manera similar, el coeficiente de potencia (Fig. 6) evidencia que el ANFIS mantiene un alto nivel de eficiencia, con desviaciones localizadas y de baja magnitud respecto a la referencia.




Figura 5. Distribución del error de potencia.




Figura 6. Coeficiente de potencia con el modelo neuro-difuso y la referencia.

El análisis de variables individuales revela particularidades del comportamiento del ANFIS. La velocidad del generador (Fig. 7) sigue de cerca la referencia, aunque se observan disminuciones durante incrementos repentinos de viento, lo que refleja la sensibilidad del modelo frente a cambios dinámicos en las entradas. Por su parte, el torque electromagnético (Fig. 8) muestra pequeñas oscilaciones adicionales respecto al controlador clásico, causadas por la capacidad del ANFIS para responder de manera más flexible a perturbaciones externas y efectos inerciales. Estas oscilaciones, aunque mínimas a escala de operación del sistema eólico, pueden generar un leve aumento del error acumulado en periodos prolongados. Además, la limitada información de patrones que relacionan las variables de interés ocasiona una disminución de la precisión del sistema, que, sin embargo, mantiene un comportamiento robusto al seguir las tendencias y recuperarse en el tiempo.




Figura 7. Velocidad angular del generador con el modelo neuro-difuso y la referencia.

En términos generales, el ANFIS reproduce el comportamiento de los datos de MPPT del controlador DSC-PID con una diferencia inferior al 10% en la energía capturada, demostrando que es una herramienta confiable para emular la acción de control en entornos con viento y oleaje altamente variables. La capacidad del modelo para identificar patrones complejos entre las variables de entrada y generar respuestas coherentes valida su factibilidad como controlador basado en aprendizaje, dejando abierta la posibilidad de futuras mejoras necesarias, como incorporación de más datos, optimización de parámetros o integración con modelos aero-hidro-dinámicos más completos.




Figura 8. Torque electromagnético con el modelo neuro-difuso y la referencia.

V. CONCLUSIONES

Los resultados obtenidos de este estudio señalan que la estrategia basada en ANFIS constituye una alternativa eficaz para reproducir el comportamiento de control MPPT en turbinas eólicas flotantes, alcanzando niveles de rendimiento buenos, que se aproximan a los datos de referencia de un

controlador tradicional. El enfoque neuro-difuso demostró capacidad para interpretar las relaciones no lineales propias de la conversión de energía en un aerogenerador sometido a condiciones ambientales cambiantes, generando una respuesta rápida y acorde a la dinámica del entorno y con algunas desviaciones respecto a la potencia objetivo.

El análisis de indicadores como RMSE, MAE y errores porcentuales confirma que el modelo ofrece un seguimiento adecuado de la dinámica del sistema, manteniendo la eficiencia en la captura de energía incluso cuando la plataforma sufre perturbaciones provocadas por el viento y el oleaje. Esto respalda el potencial de los sistemas basados en aprendizaje para operar en entornos donde las técnicas de control clásicas se enfrentan a restricciones asociadas a no linealidades y modelado complejo.

Un aspecto notable del ANFIS es su capacidad para funcionar con un conocimiento limitado del sistema físico, apoyándose directamente en datos operativos para generar una política de control comparable a la solución convencional. Sin embargo, se identifican oportunidades de mejora que permitirían aumentar aún más su precisión y robustez, como el uso de bases de datos más amplias que abarquen un mayor número de escenarios y variaciones del viento, así como el desarrollo de mecanismos de aprendizaje continuo al incorporarse como controlador en la operación normal de un aerogenerador.

De esta manera, el trabajo presentado sirve como punto de partida para avanzar hacia estrategias de control inteligente neuro-difusas, capaces de adaptarse dinámicamente a la complejidad de las turbinas eólicas flotantes, abriendo una línea de investigación orientada a su futura implementación en operación real.

AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por el Ministerio de Ciencia e Innovación de España, con los proyectos MCI/AEI/FEDER PID2021-123543OB-C21 y PID2024-155653OB-C21.

REFERENCIAS

- [1] IRENA (2019), Future of wind: Deployment, investment, technology, grid integration and socio-economic aspects. International Renewable Energy Agency, Abu Dhabi.
- [2] Global Wind Energy Council. "Global Offshore Wind Report 2023." Brussels, Belgium: GWEC, 2023.
- [3] M. A. Ahmad, G. Yoganathan, M. I. Mohd Rashid, M. R. Hao, M. H. Suid and M. Z. Mohd Tumari, "Improved Smoothed Functional Algorithms- Optimized PID Controller for Efficient Speed Regulation of Wind Turbines," in IEEE Transactions on Industry Applications, vol. 61, no. 5, pp. 7546-7560, Sept.-Oct. 2025, doi: 10.1109/TIA.2025.3550137.
- [4] Salic, T., Charpentier, J. F., Benbouzid, M., & Le Boulluec, M. (2019). Control Strategies for Floating Offshore Wind Turbine: Challenges and Trends. *Electronics*, 8(10), 1185. DOI: 10.3390/electronics8101185
- [5] Muñoz-Palomeque, E., Sierra-García, J. E., & Santos, M. (2024). Intelligent control techniques for maximum power point tracking in wind turbines. *Revista Iberoamericana de Automática e Informática Industrial*, 21(3), 193-204.
- [6] Muñoz-Palomeque, E., Sierra-García, J.E., and Santos, M. (2025). Enhancing offshore wind turbines performance with hybrid control strategies using neural networks and conventional controllers. *Journal of Computational Design and Engineering*, 12(3), 80-97, DOI: 10.1093/jcde/qwae103

- [7] Vidal, Y. (2023). Artificial Intelligence for Wind Turbine Condition Monitoring. *Energies*, 16(4), 1632. DOI: 10.3390/en16041632
- [8] Tang M., Zhao Q., Wu H., Wang Z., Meng C. and Wang Y. (2021). Review and Perspectives of Machine Learning Methods for Wind Turbine Fault Diagnosis. *Front. Energy Res.* 9:751066. doi: 10.3389/fenrg.2021.751066
- [9] Sierra-García, J. E., & Santos, M. (2020). Exploring reward strategies for wind turbine pitch control by reinforcement learning. *Applied Sciences*, 10(21), 7462.
- [10] Kumar, K., Das, M. & Karn, A.K. ANFIS robust control application and analysis for load frequency control with nonlinearity. *Journal of Electrical Systems and Inf Technol* 11, 65 (2024). DOI: 10.1186/s43067-024-00175-9
- [11] Ishaque, M., Laghari, J. A., Bhayo, M. A., Chandio, S., & Mahariq, I. (2024). Hybrid ANFIS-PI-Based Robust Control of Wind Turbine Power Generation System. *International Transactions on Electrical Energy Systems*, 2024(1), 2389751. DOI: 10.1155/2024/2389751
- [12] Chhipa, A. A., Kumar, V., Joshi, R. R., Chakrabarti, P., Jasinski, M., Burgio, A., Leonowicz, Z., Jasinska, E., Soni, R., & Chakrabarti, T. (2021). Adaptive Neuro-Fuzzy Inference System-Based Maximum Power Tracking Controller for Variable Speed WECS. *Energies*, 14(19), 6275. DOI: 10.3390/en14196275
- [13] Phan, N.M.L., Tung, D.N., Thanh, T.N. et al. (2023). ANFIS Wind Speed Estimator-Based Output Feedback Near-Optimal MPPT Control for PMSG Wind Turbine. *J Control Autom Electr Syst* 34, 588–598. DOI: 10.1007/s40313-022-00980-5
- [14] Khademhamedani, B., Izadi, M., & Delavar, H. (2025). Optimized ANFIS-Based Control of Variable-Speed Wind Turbines Using Bayesian Optimization for Enhanced Efficiency and Adaptability. *Journal of Soft Computing & Decision Support Systems*, 12(1).
- [15] Muñoz-Palomeque, E., Sierra-García, J. E., and Santos, M. (2024). Enhancing offshore wind turbines performance with hybrid control strategies using neural networks and conventional controllers,” *Journal of Computational Design and Engineering*, vol. 12, no. 3, pp. 80–97. doi:10.1093/jcde/qwae103.

Energías renovables en la Península Ibérica: análisis integral del potencial y oportunidades

Renewable Energy in the Iberian Peninsula: analysis of Potential and Opportunities

L. Rodríguez- Bethencourt

Dpto. Estructura de la Materia, Física Térmica y Electrónica
Universidad Complutense de Madrid
Madrid, España
Email: luciar20@ucm.es

J. Contreras- Martínez

Dpto. Estructura de la Materia, Física Térmica y Electrónica
Universidad Complutense de Madrid
Madrid, España
Email: jcontr01@ucm.es

Abstract—The adaptation of countries to renewable energy sources requires a detailed study of the availability and variability of natural resources over time and across territory. This study analyzes the wind and solar potential of the Iberian Peninsula based on geospatial climate data from the ERA5 reanalysis, collected over the period 2000–2025. Meteorological variables related to radiation, atmospheric conditions, and wind—key determinants of the potential of the selected resources—are used to identify optimal zones of renewable potential while taking into account social, environmental, and territorial factors. In this way, relevant patterns are identified that highlight areas favorable for the implementation of renewable installations. Thus, this study constitutes a complementary tool to support the renewable transition, aiming to achieve a sustainable energy model for the Iberian Peninsula.

Resumen—La adaptación de los países a las fuentes renovables requiere el estudio detallado de la disponibilidad y variabilidad de los recursos naturales en el tiempo y territorio. Este estudio analiza el potencial eólico y solar en la Península Ibérica basado en datos climáticos geoespaciales del reanálisis ERA5, recogidos en el periodo 2000-2025. Se utilizan variables meteorológicas relacionadas con radiación, condiciones atmosféricas y viento, determinantes del potencial de los recursos escogidos, buscando identificar zonas óptimas de potencial renovable teniendo en cuenta factores sociales, ambientales y territoriales. De esta forma, se detectarán patrones relevantes que muestren áreas favorables para la implementación de instalaciones renovables. Así, este estudio constituye una herramienta complementaria a la transición renovable con el fin de obtener un modelo energético sostenible en la Península Ibérica.

Index Terms—Energía Renovable, Recursos Renovables, Potencial Energético, Transición Energética, Análisis Geoespacial.

I. INTRODUCCIÓN

La evolución de las sociedades modernas ha estado estrechamente vinculada al desarrollo de los recursos energéticos. Históricamente, se ha observado una relación directa entre el desarrollo socioeconómico y el consumo de energía, lo que pone de manifiesto el papel fundamental que esta desempeña en el progreso de un país [1]. El incremento sostenido de la demanda energética ha impulsado la aparición de nuevas políticas orientadas a garantizar la sostenibilidad y la seguridad del suministro. Desde la Revolución Industrial, el sistema energético global ha dependido fundamentalmente

de los combustibles fósiles, responsables de aproximadamente el 75 % de los gases de efecto invernadero presentes en la atmósfera [2]. Esta situación ha impulsado una transición estructural hacia formas de energía limpias e ilimitadas, como las energías renovables [3].

En este contexto, debido a sus condiciones naturales favorables y a la flexibilidad de su sistema eléctrico, España constituye un caso significativo dentro de este proceso, posicionándose como referente global en plantas solares en capacidad eólica instalada [4]. En consecuencia, su elevado potencial renovable sitúa al país como un ejemplo relevante dentro del proceso de transición energética [4], [5], [6].

Todo ello está directamente relacionado con el potencial energético natural del territorio. Pero debido a que la disponibilidad de los recursos renovables no es homogénea y su variabilidad es muy sensible a las condiciones a corta escala, resulta fundamental estudiar y entender la distribución de vientos, radiación y otros factores climáticos para localizar las zonas óptimas donde aprovechar estas energías de forma eficiente [7]. Esto evidencia la importancia de analizar detalladamente el potencial eólico y solar (mayores productores de energía renovable en España) en el territorio de interés, más concretamente, la Península Ibérica, haciendo necesario un estudio detallado en el que identificar las zonas de mayor aprovechamiento mediante el análisis de variables ambientales y su integración con factores poblacionales, territoriales y sociales.

La razón principal del proyecto se centra en el ámbito de las energías renovables, particularmente en su integración óptima en el territorio. El estudio consiste en evaluar las variables meteorológicas más influyentes en el rendimiento de las tecnologías renovables de mayor implantación y demanda en la Península Ibérica, concretamente la energía eólica y la solar, basando esta elección en su papel estratégico dentro de la transición energética de España y Portugal. Ambas tecnologías representan el mayor porcentaje de generación renovable en la región y presentan un crecimiento sostenido, dependiendo de forma directa de variables atmosféricas y territoriales, lo que hace imprescindible un análisis

meteorológico y espacial detallado del recurso.

Mediante un análisis geoespacial detallado de estas variables, se busca optimizar el aprovechamiento de los recursos, detectar posibles situaciones de riesgo en el contexto actual y en escenarios futuros, y mejorar la planificación energética. De este modo, se pretende identificar zonas con elevado potencial energético que cumplan criterios de viabilidad territorial, ambiental y social, integrando las capas de información meteorológica con datos relativos a densidad de población, distribución eléctrica, restricciones ambientales y patrones de consumo energético.

II. OBJETIVO

El objetivo de este estudio es desarrollar una herramienta georeferenciada que permita identificar zonas potencialmente viables para la instalación de fuentes de generación renovables: eólica, solar o combinación de ambas; tanto desde un punto de vista técnico centrado en los recursos naturales disponibles y las infraestructuras eléctricas ya existentes necesarias para la distribución y desde una visión medioambiental y social que permita minimizar los impactos climáticos y maximizar los beneficios sociales.

Para ello será necesario generar la base de datos adecuada así como definir los distintos análisis a realizar y sus correspondientes algoritmos de manera individual a cada capa y para los análisis entrelazados entre capas.

III. METODOLOGÍA

Los datos utilizados proceden del conjunto ERA5 Reanalysis on Single Levels, disponible en Copernicus Climate Data Store [8]. Estos datos permiten reconstruir la evolución temporal y espacial de la atmósfera mediante la integración de observaciones y modelos numéricos, ofreciendo un conjunto de datos locales de alta calidad. Su procedencia es un reanálisis climático global desarrollado por el Centro Europeo de Predicción a Medio Plazo (ECMWF), que combina observaciones reales con un modelo numérico atmosférico mediante técnicas avanzadas de asimilación de datos, generando una reconstrucción coherente del estado de la atmósfera. Esta fuente de datos proporciona valores horarios de las variables, correspondientes al estado atmosférico puntual en cada hora.

Mediante el código de descarga proporcionado por la propia plataforma, adaptado a los intereses del estudio, se obtuvieron las distintas variables de interés, detalladas en la Tabla I, para el periodo 2000–2025, con resolución temporal horaria. Estas variables permiten evaluar de forma georeferenciada el potencial eólico y solar, así como representarlas junto a un conjunto de variables climáticas incluidas en los mismos archivos lo que permitirá extraer patrones de influencia y fluctuaciones.

El área de estudio definida para este estudio es la Península Ibérica, delimitada por las coordenadas geográficas en el sistema de referencia geodésico WGS84 (EPSG:4326); además, se usa el estándar temporal UTC (Coordinated Universal Time): Norte 44°, Sur 36°, Oeste 10° y Este 4°, zona acotada que se muestra en la Figura 1.



Figura 1. Mapa de la Península Ibérica obtenido de Google Earth Pro, centrado en las coordenadas 40°08'10.23" N, 2°29'54.00" O, con elevación 1000 m y altura de ojo 1176.30 km. Fecha de las imágenes: 1/1/2021.

Para el análisis geoespacial, se hará uso del software QGIS [9], un Sistema de Información Geográfica (SIG) de código abierto desarrollado por Gary Sherman, actualmente bajo la coordinación del QGIS Project Steering Committee (PSC) y distribuido de forma gratuita bajo la licencia GNU General Public License (GPL). QGIS permite la manipulación, análisis y visualización de datos georeferenciados. De esta forma, se utilizará para la representación de la distribución espacial de distintas variables en distintos intervalos de tiempo y se generarán mapas en los que identificar patrones influyentes en los recursos.

Estos sistemas SIG son herramientas fundamentales para el tratamiento de grandes volúmenes de datos georeferenciados. Integran información asociada a un sistema de coordenadas basándose en bases de datos espaciales por lo que localiza correctamente la superficie sobre la cual se está trabajando. De esta forma, los SIG son una forma fácil de análisis y visualización de datos temporales relacionándolos con su distribución espacial.

El funcionamiento de estos sistemas se basa en la organización de capas, donde cada una representa un conjunto de variables siguiendo su referencia espacial asociada. Además, permite superponer otras capas combinando datos y relacionándolos. Con estos métodos es posible identificar zonas de interés, patrones espaciales o dependencia entre variables, resultando útil en estudios energéticos [10].

Por lo tanto, en este contexto, QGIS supone una herramienta adecuada para este estudio, permitiendo reproyectar datos ráster en el espacio con el fin de hacer su análisis espacial

Tabla I
VARIABLES ERA5 UTILIZADAS EN EL ESTUDIO ENERGÉTICO

Categoría	Variable ERA5
Atmosféricas clave	total_column_water_vapour (kg/m ²) boundary_layer_height (m) high_vegetation_cover low_vegetation_cover friction_velocity (m/s) geopotential (m ² /s ²) total_cloud_cover
Recurso eólico	100m_u_component_of_wind (m/s) 100m_v_component_of_wind (m/s) 10m_u_component_of_wind (m/s) 10m_v_component_of_wind (m/s)
Recurso solar	surface_solar_radiation_downwards (J/m ²) surface_net_solar_radiation (J/m ²) surface_solar_radiation_downward_clear_sky (J/m ²) clear_sky_direct_solar_radiation_at_surface (J/m ²) total_sky_direct_solar_radiation_at_surface (J/m ²)
Condiciones térmicas	2m_temperature (K) surface_pressure (Pa)

Nota: Las variables sin unidades entre paréntesis son adimensionales.

y temporal, generando mapas temáticos de las variables climáticas de interés (Tabla I).

A su vez, mediante códigos desarrollados en Python y Matlab, se analizarán correlaciones entre variables, cambios temporales a corto plazo (diaria, mensual) y largo plazo (anual, decadal), así como posibles episodios adversos puntuales o periódicos que completen el desarrollo óptimo del recurso. Una vez identificadas las zonas de mayor potencial energético, se completará el estudio con información de densidad de población, distribución eléctrica y restricciones ambientales para evaluar la capacidad de producción energética y las distintas zonas geográficas que presenten viabilidad a proyectos renovables bajo todos los aspectos presentes y analizados en el estudio.

Este tipo de estudio permite combinar las necesidades técnicas de abastecimiento, distribución y eficiencia de las redes, con una capa de profundidad que vela por los intereses sociales y la biodiversidad desde un punto de vista regenerativo y de mínimo impacto, pudiendo localizar emplazamientos que maximicen las eficiencias energéticas adoptando soluciones de mini redes aisladas, redes interconectadas o implantación de políticas de producción distribuida eficientes, minimizando los impactos ambientales y maximizando los impactos sociales.

Ya han sido descargadas las series temporales desde el año 2000 hasta el 2025 y se está procediendo a realizar los primeros análisis utilizando el software QGIS. En la Figura 2, se muestra el mapa obtenido para la variable correspondiente a la velocidad de viento promedio horaria para el día 14 de enero a 10 metros de altura, pudiendo determinar zonas de vientos fuertes o débiles recurrentes a lo largo de la serie

temporal específica. Mientras que, en la Figura 3, se representa la distribución espacial de la radiación solar para ese mismo día.




Figura 2. Variable del viento medio (m/s) a 10 m (10m_u_component_of_wind) (Tabla I) para el día 14 de enero de 2000.

IV. TRABAJO FUTURO

Para la correcta finalización de este estudio, existen diferentes problemáticas que han de ser abordadas, de modo que se puedan realizar análisis de largo plazo utilizando completas las series disponibles.

Primeramente, los archivos NetCDF descargados son excesivamente grandes para un portátil convencional debido a su alta resolución espacial (0.25°), la cantidad de datos horarios y la amplia extensión geográfica. Para solventar esta limitación se ha propuesto la utilización de ordenadores de mayor capacidad.

Por otro lado, la reducción del peso de los archivos mediante Python, seleccionando solo la información mínima necesaria y convirtiéndola a formatos más ligeros como GeoTIFF, está siendo también abordada. Estas técnicas permitirán que cualquier persona pueda replicar el análisis, incluso sin recursos computacionales profesionales.

Asimismo, es necesario el desarrollo de unos algoritmos muy depurados que permitan la correcta extracción de información multicapa, debido al gran volumen de datos a tratar.

Por último, para la estimación de patrones temporales recurrentes o distintos patrones de correlación relevantes entre una misma variable o entre dos o más de ellas, será necesario implementar herramientas iterativas de autoaprendizaje que permitan resolver y valorar los escenarios más prometedores y las zonas de interés para una expansión renovable en la zona de estudio.




Figura 3. Distribución de la radiación solar en superficie (J/m^2) (surface_solar_radiation_downwards) para el día 14 de enero de 2000.

V. CONCLUSIONES

Este estudio resulta de gran importancia social y energética, desarrollando una herramienta que contribuye a la evaluación del potencial eólico y solar en la Península Ibérica con el fin de optimizar las localizaciones para instalaciones renovables. Permitirá identificar localizaciones para instalaciones renovables eficientes energéticamente y que minimicen el impacto ambiental maximizando el impacto social de estas tecnologías. Mediante su difusión y utilización se buscará mejorar la planificación territorial en relación con las variables climáticas, previniendo riesgos asociados a episodios meteorológicos adversos y poder planificar una generación distribuida o aislada adecuada a las necesidades territoriales concretas.

REFERENCIAS

- [1] F. Castro-Rodríguez y D. Miles-Touya, "Impact of Spanish renewable support scheme reforms on the revenues of photovoltaic power plants," *Utilities Policy*, vol. 80, 2023. DOI: 10.1016/j.jup.2022.101476.
- [2] Our World in Data, *Global primary energy consumption (1800–2024)*, 2025. dirección: <https://ourworldindata.org/grapher/global-primary-energy>.
- [3] J. L. Holechek, H. M. E. Geli, M. N. Sawalhah y R. Valdez, "A Global Assessment: Can Renewable Energy Replace Fossil Fuels by 2050?" *Sustainability*, vol. 14, n.º 8, 2022. DOI: 10.3390/su14084792.
- [4] F. G. Montoya, M. J. Aguilera y F. Manzano-Agugliaro, "Renewable energy production in Spain: A review," *Renewable and Sustainable Energy Reviews*, 2014. DOI: 10.1016/j.rser.2014.01.091.
- [5] Red Eléctrica, *Electricity generation from renewable energies in Spain grows by 10.3 % in 2024*, 2025. dirección: <https://www.ree.es/...>
- [6] R. Gómez-Calvet, J. M. Martínez-Duart y S. Serrano Calle, "Present state and perspectives of variable renewable energies in Spain," *European Physical Journal Plus*, vol. 133, n.º 3, 2018. DOI: 10.1140/epjp/i2018-11960-9.
- [7] A. Jiménez-Garrote, G. Sánchez-Hernández, M. López-Cuesta, I. M. Galván, R. Aler y D. Pozo-Vázquez, "A novel method for modeling renewable power production using ERA5: Spanish wind energy," *Sustainable Energy Technologies and Assessments*, vol. 81, 2025. DOI: 10.1016/j.seta.2025.104397.
- [8] Copernicus Climate Data Store, *ERA5 hourly data on single levels from 1940 to present*, 2025. dirección: <https://cds.climate.copernicus.eu/>.
- [9] QGIS Development Team, *QGIS Geographic Information System*, Open Source Geospatial Foundation Project, 2025. dirección: <https://qgis.org>.
- [10] V. Olaya, *Sistemas de Información Geográfica*. CreateSpace Independent Publishing Platform, 2014, Capítulo: Introducción y fundamentos de los SIG. dirección: https://volaya.github.io/libro-sig/chapters/Introduccion_fundamentos.html.

Evaluación Numérica de Esfuerzos en Palas de Turbinas Offshore mediante Dinámica de Fluidos Computacional: Estudio Preliminar

Numerical Evaluation of Stresses in Offshore Turbine Blades using Computational Fluid Dynamics: A Preliminary Study

1st S. Corral-Andrés

*Dept. of Structure of Matter,
Thermal Physics and Electronics
Faculty of Physics, University Complutense of Madrid
Madrid, Spain
secorral@ucm.es*

2nd J. Contreras-Martínez

*Dept. of Structure of Matter,
Thermal Physics and Electronics
Faculty of Physics, University Complutense of Madrid
Madrid, Spain
jcontr01@ucm.es*

Abstract—This ongoing research aims to determine the operating conditions for offshore wind turbine blades. First, the necessity of this study is established through a historical review of energy, followed by an explanation of the CFD tools employed and their underlying mechanisms. Finally, initial progress is reported, confirming the validity of the experimental method.

Index Terms—Floating Wind Turbine, Fluids Simulation, Finite Elements, Wind Blades, Navier-Stokes.

Resumen—Esta investigación en curso tiene como objetivo determinar en que condiciones deben operar las palas de un aerogenerador *offshore*. Primero se presenta la necesidad de este estudio a través de un resumen de la historia de la energía, para posteriormente explicar que herramientas CFD empleamos y como funcionan. Por último, se reportan avances iniciales que confirman la validez del método experimental.

Index Terms—Aerogenerador flotante, Simulación de Fluidos, Elementos finitos, Palas Eólicas, Navier-Stokes.

I. INTRODUCCIÓN

Todos los seres vivos de este planeta necesitamos de energía para vivir. Desde la que obtenemos a través de la comida para llevar a cabo nuestras funciones vitales [1], hasta toda la cantidad extra que consumimos debido a los avances tecnológicos de nuestra sociedad actual.

La forma de vida de las personas siempre ha estado directamente relacionada con lo métodos de producción energética del momento: El fuego, la tracción animal [1] y los primeros molinos de viento y agua, que sentaron las bases de la energía eólica e hidráulica actuales [2] y definieron durante años la estructura económica, fundamentalmente agrícola, de todos los pueblos pre-industriales.

Todo esto cambiaría a partir de 1769 con la invención de la máquina de vapor por James Watt; este invento fue el impulsor

de la primera revolución industrial (1760-1840) la cual tuvo como consecuencia un desarrollo económico sin precedentes. El consumo del carbón se disparó, pues este era el combustible que empleaban las máquinas de vapor, y con ello apareció la primera dependencia del ser humano con una fuente no renovable de energía [3].

En busca de unas máquinas mas eficientes que las de vapor surgieron los motores de combustión interna de *Otto* y *Diesel*, los protagonistas de la denominada segunda revolución industrial (1870-1914) y los que provocaron una nueva dependencia a los combustibles derivados del petróleo [3]. Durante ambos periodos, debido a todos los avances tecnológicos y médicos la natalidad aumentó exponencialmente, y con ello el número de habitantes, que a su vez derivó en un mayor consumo energético. A partir de ambas etapas históricas, y observando la Fig. 1, se puede deducir una relación entre el desarrollo económico y social con la energía consumida: a mayor sea el primer término, el otro crece consecuentemente [4].

Sin embargo, en los años 90, la comunidad científica registró que la actividad humana estaba alterando el clima en el primer informe del IPCC [6], y con ello surgió una conciencia social alrededor de este tema que acabó cristalizando en la firma del protocolo de Kyoto de 1997 [7], el cual establecía objetivos vinculantes que forzaban a los países firmantes a invertir en tecnologías bajas en carbono.

En la Fig. 2 se ilustra la capacidad acumulada de generación eléctrica renovable para España: se observa que del año 2000 hasta el 2013 la capacidad eólica creció de forma exponencial con el objetivo de cumplir los números planteados en el país nipón. La energía eólica (*onshore*) se convirtió en uno de los pilares fundamentales del sistema eléctrico español. En el




Fig. 1: Consumo mundial de energía primaria por fuente. Fuente: *Our world in data* [5].

año 2024 esta fue la tecnología con un mayor porcentaje de generación (23,3 %) en el *mix* energético español [9], convirtiéndose en uno de los países líderes de generación eólica. Sin embargo, si nos fijamos en la Fig. 1, se observa que la energía proveniente del viento (y renovables en general) a nivel mundial es muy pequeña con respecto a las fuentes no renovables, por lo que aún existe mucho margen de mejora.

Por otro lado, el crecimiento de la energía solar fotovoltaica en España vio su auge a partir de 2018 debido a cambios favorables en la legislación vigente, siendo a día de hoy la tecnología con más potencia instalada (32250 MW) en nuestro país [9].

En los inicios de los años 2000, las tecnologías eólicas terrestres estaban ya lo suficientemente desarrolladas como para que la construcción de un parque fuera rentable. En el caso de Europa, la instalación fue tal, que para el año 2007 el 70 % de la energía producida de origen eólico provenía de parques europeos [2]. A día de hoy la eólica *onshore* ya ha alcanzado completamente su madurez, superando el hito de 1 TW global acumulado. No obstante, según indica el GWEC [10], su expansión futura enfrenta barreras crecientes debido a la saturación de emplazamientos de óptimo recurso y conexión a la red. Un claro indicador de ello es que en 2024, en Alemania, el 37 % de la nueva capacidad instalada provino de la sustitución de turbinas viejas por nuevas (*repowering*). En cambio, la industria proyecta que las instalaciones anuales de eólica *offshore* se cuadrupliquen para el año 2030. Las tasas de crecimiento anual compuestas estimadas son del 27 % para la marina frente a solo un 6,6 % para la terrestre [10].

Las tecnologías eólicas de mar son generalmente más caras que sus contrapartes terrestres. Tanto la instalación como la operación de estos parques son sensiblemente más complicadas debido a los desafíos que plantea el entorno. El ejemplo más representativo es el coste de los cimientos, que son un 350 % más caros que sus homólogos de tierra [11]. Debido a estas dificultades es imperativo realizar simulaciones para optimizar el diseño de las diferentes partes de la turbina (como las palas) y asegurar el funcionamiento de estas a largo plazo.

A pesar de su alto CAPEX (*capital expenditures*) y OPEX (*operational expenditures*) [12], el precio de instalación se ha

reducido considerablemente, al igual que el coste nivelado de la energía (LCOE), que pasó a ser de 0,188 USD/kWh en 2010 a 0,075 en 2021. Esto se produce gracias al desarrollo tecnológico, que ha permitido desplegar turbinas más grandes con una capacidad de producción mayor [11]. Además, los emplazamientos marinos ofrecen grandes ventajas con respecto al recurso eólico. La velocidad media del viento (U) anual es generalmente más alta, lo que beneficia considerablemente a la potencia producida ($P \propto U^3$). A parte, el perfil del viento es más homogéneo a lo largo de la coordenada vertical gracias a la pequeña longitud de rugosidad que presenta la superficie marina [13].

Este trabajo se enmarca dentro de un proyecto mayor, financiado por el Ministerio de Ciencia, Innovación y Universidades y la Unión Europea, denominado: “Estabilización, mantenimiento y auto-regulación inteligente de una plataforma marina de energía multi-recurso mediante control del aerogenerador (SEA-STAR1)”. La motivación de este artículo es la de validar el método experimental que se empleará posteriormente para determinar las condiciones de operación de la plataforma marina.

II. OBJETIVOS DEL PROYECTO

El propósito de esta investigación es analizar el comportamiento aerodinámico y la respuesta estructural para una pala que forma parte de una turbina eólica flotante, a través del uso de herramientas de simulación computacional de fluidos (CFD según sus siglas en inglés).

Para el correcto desarrollo de la investigación, se definen los siguientes objetivos específicos:

- Determinación de cargas aerodinámicas.
- Análisis de esfuerzos estructurales.
- Evaluación del acoplo de vibraciones.
- Identificación de los límites de operación.

III. METODOLOGÍA EXPERIMENTAL

Este trabajo se basa en los resultados obtenidos mediante herramientas CFD, concretamente empleamos *Autodesk CFD 2026* bajo licencia educativa.

El comportamiento de cualquier fluido está determinado por tres principios físicos fundamentales: la segunda ley de Newton, la conservación de la masa, y de la energía. Estas leyes físicas se pueden escribir como ecuaciones diferenciales parciales o integrales, formando así las conocidas ecuaciones de Navier-Stokes. Tal y como detalla Anderson [14], la dinámica computacional de fluidos es “el arte” de reemplazar las integrales o derivadas parciales (según el caso) con formas algebraicas discretizadas. A cambio, las ecuaciones se resuelven para obtener valores numéricos del campo de flujo en puntos discretos del tiempo y/o del espacio.

A. Ecuaciones Gobernantes

En este subapartado se presentan las tres ecuaciones que rigen el comportamiento físico de un flujo tridimensional, no estacionario, compresible y viscoso. Además, estas se encuentran en forma de ecuaciones diferenciales parciales,




Fig. 2: Capacidad acumulada de generación renovable en España del año 2000 hasta 2023. Fuente: Elaborado a partir de datos del IRENA [8].

concretamente en su versión conservativa, las cuales son la más convenientes para la aplicación de técnicas CFD [14]:

1) *Ecuación de continuidad*: Representa el principio de conservación de la masa;

$$\frac{\partial \rho}{\partial t} + \nabla \cdot (\rho \mathbf{V}) = 0 \quad (1)$$

2) *Ecuación de momento*: Se obtiene a partir de aplicar la segunda ley de Newton al flujo;

$$\frac{\partial(\rho \mathbf{V})}{\partial t} + \nabla \cdot (\rho \mathbf{V} \mathbf{V}) = -\nabla p + \nabla \cdot \boldsymbol{\tau} + \rho \mathbf{f} \quad (2)$$

Aquí $\mathbf{V} \mathbf{V}$ se refiere al producto diádico del vector velocidad y $\boldsymbol{\tau}$ sería el tensor de tensiones viscosas. Esta ecuación posteriormente se ramifica en tres diferentes, una para cada eje del espacio.

3) *Ecuación de la energía*: Es en esencia la primera ley de la termodinámica, la conservación de la energía;

$$\begin{aligned} \frac{\partial}{\partial t} \left[\rho \left(e + \frac{V^2}{2} \right) \right] + \nabla \cdot \left[\rho \left(e + \frac{V^2}{2} \right) \mathbf{V} \right] \\ = \rho \dot{q} + \nabla \cdot (k \nabla T) \\ - \nabla \cdot (p \mathbf{V}) + \nabla \cdot (\boldsymbol{\tau} \cdot \mathbf{V}) + \rho \mathbf{f} \cdot \mathbf{V} \end{aligned} \quad (3)$$

Las tres anteriores forman un sistema acoplado de ecuaciones diferenciales parciales no lineales muy difícil de resolver analíticamente.

En el caso de *Autodesk CFD 2026*, estas no son las únicas ecuaciones que resuelve, sino que dependiendo de las condiciones de la simulación se tienen en cuenta diferentes expresiones matemáticas, las cuales no incluimos por temas de espacio, que se pueden consultar en [15].

B. Método de discretización y de resolución numérica

Para poder resolver el sistema de ecuaciones anterior debemos de sustituir los términos en derivadas parciales por formas algebraicas. Este es el significado de discretizar. Al resolver ecuaciones algebraicas no vamos a obtener una solución general, como si lo haríamos resolviendo las ecuaciones diferenciales (obtendríamos funciones dependientes de las coordenadas espaciales, por lo que conoceríamos el valor de la función en infinitos puntos), sino que obtendremos valores numéricos para un punto concreto del espacio [14].

Existen varias técnicas para lograr lo anterior, entre las más popular se encuentran: método de las diferencias finitas (FDM), de los volúmenes finitos (FVM) y el de elementos finitos (FEM).

En nuestro caso nos centraremos en el método de elementos finitos. En este, las variables dependientes del flujo (velocidades y presión) se aproximan por funciones polinómicas sobre un pequeño área o volumen denominada elemento. Esta representación se sustituye en el sistema de ecuaciones diferenciales. Posteriormente se calcula la integral ponderada de dichas ecuaciones sobre el elemento, eligiendo una función de peso que sea idéntica a la función polinómica de las variables. El resultado es un sistema de ecuaciones algebraicas para las variables dependientes en puntos discretos de cada elemento [16].

Uno de los motivos por el que se utiliza este método es debido a su flexibilidad para modelar cualquier forma geométrica. Además, el FEM arroja buenos resultados tanto para flujos turbulentos de alta velocidad como para flujos compresibles [17].

El método explicado se utiliza para discretizar los términos difusivos y las fuentes de las ecuaciones gobernantes. Sin embargo, los términos advectivos se tratan con esquemas *upwind* para garantizar la estabilidad numérica. En esta simulación se emplea el esquema ADV-5, que es una modificación del método




Fig. 3: Comparativa de la distribución del coeficiente de presión (C_p) para los cuatro índices de turbulencia (IT). La escala de colores a la derecha es común para todas las subfiguras.

de Petrov-Galerkin, el cual mejora la robustez del cálculo y reduce las oscilaciones no físicas en flujos dominados por la convección [16].

Una vez que el sistema de ecuaciones ha sido reducido a uno algebraico, emplearemos un *solver* iterativo segregado. En este procedimiento primero se debe obtener una ecuación para la presión. Para ello, se deduce una relación entre esta y la velocidad a través de las ecuaciones de momento. Dicha relación se sustituye en la forma integral de la ecuación de continuidad para así llegar a una ecuación explícita para la presión. De esta forma, las ecuaciones gobernantes pueden ser resueltas de forma separada para cada punto del espacio. El cálculo se repite tomando como valores iniciales las soluciones del anterior hasta que los valores converjan. Este método requiere menos memoria ya que solo se resuelve un grado de libertad por cada iteración [18].

C. Mallado

Por último, debemos de generar la red de puntos (mallado) sobre el espacio para los que obtendremos los valores numéricos de las variables dependientes. El mallado para nada es un proceso trivial, una mala elección de este puede hacer que la solución no converja. Por ello, la generación de mallas es un tópico por si solo cuando hablamos de CFD [14].

Tomemos el ejemplo del estudio un perfil aerodinámico. Cerca de la superficie de este encontramos la capa límite del fluido, donde el gradiente de velocidad es alto. En esta

zona nos interesa una alta densidad de puntos para estudiar en profundidad el comportamiento del aire por su recorrido sobre la superficie. Otras zonas de interés serían el borde de ataque, donde el cambio en la forma geométrica es abrupto, ó en el borde de salida y el espacio después de este, para estudiar la estela generada. En cambio, en el espacio alejado del perfil (salvo el que esté detrás de la cola, por donde irá la estela), nos interesa una densidad pequeña de puntos, pues estas son zonas sin interés de estudio. De esta manera logramos ahorrar memoria y disminuimos el tiempo de computación de la simulación.

D. Nuestro modelo a simular

La dinámica completa de una turbina *offshore* depende de la interacción simultánea de la aerodinámica, la hidrodinámica, la dinámica estructural y los sistemas de control [19]. La simulación del sistema anterior es extremadamente compleja y conllevaría un alto coste computacional. Para solventar el problema anterior, en este trabajo se propone un modelo simplificado centrado en el componente más crítico del sistema: la pala.

Para la validación de la metodología de simulación empleada, y poder extrapolarla posteriormente a simulaciones mas complejas, se realizarán cuatro simulaciones. En ellas, tomamos una pala eólica, fija e inelástica, sobre la que hacemos incidir un viento de 10 m/s en la dirección del eje y . Para parametrizar la turbulencia se emplea el modelo: *Low Reynold*

number $k - \epsilon$. Este es una variación del $k - \epsilon$, adaptado para resolver la turbulencia hasta la región cercana a la pared, donde el número de Reynolds disminuye debido al dominio de las fuerzas viscosas sobre las inerciales [20].

Para el análisis de los resultados empleamos como indicadores el índice de turbulencia y el coeficiente de presión. A continuación se presentan unas breves definiciones de ambos basadas en [13]:

- Índice de turbulencia (IT); Se define como la relación entre la desviación estándar de la velocidad del viento y la velocidad media. Es la medida para cuantificar la turbulencia. Para una misma velocidad nos permite someter a la pala a perfiles de viento de diferente homogeneidad.
- Coeficiente de presión (C_P); Es un número adimensional que describe la presión relativa en un punto del flujo de un fluido. Se define como la diferencia entre la presión estática y la de corriente libre dividida entre la presión dinámica del flujo. A través de el podemos hallar la distribución de fuerzas a lo largo de la pala, lo que nos permite identificar las regiones donde la estructura está sometida a mayores esfuerzos.

En los cuatro ensayos variamos el índice de turbulencia desde 0,10 hasta 0,40 en pasos de 0,10. Para cada uno de los índices de turbulencia se analiza como varía el campo escalar del coeficiente de presión a lo largo de la superficie de la pala sobre la que incide el viento. En la Tabla I se presenta un resumen de la configuración de las simulaciones.

No obstante, en las turbinas flotantes, las palas son elásticas y los movimientos de la plataforma provocados por el mar inducen velocidades y cargas adicionales en ellas [19]. En nuestro modelo futuro, la pala no será rígida y podrá flexar según sea la distribución de momentos. Además, será sometida a una serie de movimientos oscilatorios armónicos que simulen las vibraciones producidas por la interacción mar-estructura, con lo que se eliminará la necesidad de resolver la hidrodinámica de la plataforma.

El análisis de vibraciones es fundamental, ya que las oscilaciones no controladas son precursoras de deslaminación, grietas e incluso pueden provocar el colapso total de la pala, la cual es uno de los componentes más caros de la turbina [21]. Sumado a esto, la climatología estocástica del mar complica cualquier proceso ingenieril [19], lo que desemboca en un mayor coste del proceso de sustitución de la pala.

IV. RESULTADOS PREVIOS Y ESPERADOS

El equipo empleado para lanzar las cuatro simulaciones parametrizadas, para palas estáticas e inelásticas bajo diferentes cargas turbulentas, consta de un *Ryzen 5 4600H* con 6 núcleos y 12 hilos a 3 GHz, junto con una memoria RAM de 16 GB a 2667 MHz. La malla poseía un total de 22155 nodos y 89239 elementos. De menor a mayor índice de turbulencia, las simulaciones convergieron en 525, 343, 355, y 406 iteraciones respectivamente, con un tiempo de computación total de 25 minutos y 37 segundos.

Tabla I: Resumen de los parámetros de configuración de las simulaciones.

Parámetro	Valor / Descripción
Condiciones de Contorno	
Velocidad de entrada (V_{in})	10 m/s
Presión de salida	0 Pa Manométrica
Paredes del dominio (<i>Far field</i>)	Simetría / <i>Slip</i>
Modelo de Turbulencia	
Modelo empleado	Low-Re $k - \epsilon$
Intensidad de turbulencia	Variable (0,1 - 0,4)
C_μ	0,09
$C_{\epsilon 1}$	1,44
$C_{\epsilon 2}$	1,92
Parámetro de pared	1,55
Constante de VanDriest	26,0
κ	0,40
Criterios de Convergencia	
Esquema de advección	ADV-5
Iteraciones medias / simulación	407
Pendiente de convergencia instantánea	0,001
Pendiente de convergencia media	0,03162
Concavidad de convergencia media	0,03162
Fluctuaciones de las variables de campo	0,0001

En la Fig. 3 se presentan los coeficientes de presión obtenidos para cada índice de turbulencia sobre la superficie en la que incide el viento. Para la subfigura (a) encontramos los resultados para un índice de turbulencia de 0,1, en la (b) de 0,2, en la (c) de 0,3 y por último en la (d) de 0,4. Así mismo, en la Fig. 4 vienen indicadas las posiciones de cuatro puntos distintos sobre la superficie del álabe, para los que serán extraídos valores cuantitativos de C_p para cada una de las simulaciones realizadas. Estos se detallan en la Tabla II.

A medida que aumentamos el índice de turbulencia, observamos que el coeficiente de presión crece a lo largo de toda la pala. Esto nos indica que una turbulencia mayor genera un estrés extra en el álabe, tal y como se ve en la Tabla II, pasando de valores de 3,84 para una IT de 0,1 a valores de 5,14 con una IT de 0,4 en el punto D. Además, en todos los casos el C_p se maximiza donde la pala se une al buje. Este es un dato muy a tener cuenta, ya que si la fuerza fuese mayor en el extremo contrario en un caso elástico, el álabe podría flexionarse para compensar dicho esfuerzo. Sin embargo, en el extremo del buje no tiene margen para flexar y compensar la presión. Estos resultados están en consonancia por los obtenidos por otros autores en estudios previos [22] [23].

Dada la convergencia de las simulaciones ejecutadas y la consistencia de los resultados obtenidos, en un futuro pasaremos al estudio del sistema bajo movimientos oscilatorios. De estas simulaciones se espera obtener los patrones de esfuerzo y vibraciones sobre el álabe, en función de la velocidad del viento incidente y su índice de turbulencia.




Fig. 4: Puntos A, B, C y D sobre la superficie del álabo.

Tabla II: Valores numéricos del coeficiente de presión (C_p) para los puntos de la Fig. 4.

Punto	C_p (IT=0,1)	C_p (IT=0,2)	C_p (IT=0,3)	C_p (IT=0,4)
A	2,24	2,30	2,38	2,42
B	1,58	2,60	3,15	3,66
C	1,26	2,23	2,86	3,30
D	3,84	3,95	4,49	5,14

V. CONCLUSIONES

Las simulaciones ejecutadas en estado estacionario son necesarias para la adecuada realización de las próximas en estado transitorio. Estas simulaciones han mostrado un aumento del 25,3 % en el valor del coeficiente de presión para el punto de estudio más cercano al buje de la turbina al aumentar el índice de turbulencia de 0,1 a 0,4. La validez de estos ensayos preliminares nos permiten avanzar en el estudio planteado, pasando a un modelo dinámico que permita hallar el comportamiento aerodinámico-vibracional que se plantean en los objetivos. Los resultados permitirán establecer las condiciones de operación óptimas de las turbinas flotantes, ofreciendo a los operarios del parque eólico marino los datos para asegurar el correcto funcionamiento de este mismo.

REFERENCIAS

- [1] G. J. Suppes and T. S. Storvick, "The history of energy," in *Sustainable Nuclear Power*. Academic Press, 2007, ch. 2, pp. 9–32.
- [2] J. K. Kaldellis and D. Zafirakis, "The wind energy (r)evolution: A short review of a long history," *Renewable Energy*, vol. 36, no. 7, pp. 1887–1901, 2011.
- [3] F. Landis, E. B. Woodruff, C. R. Russell, R. Wailes, and R. L. Seale. (2024, mar) Energy conversion. [Online]. Available: <https://www.britannica.com/technology/energy-conversion/History-of-energy-conversion-technology>
- [4] D. M. Martinez and B. W. Ebenhack, "Understanding the role of energy consumption in human development through the use of saturation phenomena," *Energy Policy*, vol. 36, no. 4, pp. 1430–1435, 2008.
- [5] H. Ritchie, P. Rosado, and M. Roser, "Global primary energy consumption by source (substitution method)," Our World in Data, 2025. [Online]. Available: <https://ourworldindata.org/grapher/global-energy-substitution>
- [6] IPCC, "Climate change: The ipcc scientific assessment," Intergovernmental Panel on Climate Change, Cambridge, UK, Tech. Rep., 1990.
- [7] UNFCCC, "Kyoto protocol to the united nations framework convention on climate change," United Nations, 1997, adoptado en Kioto, Japón, el 11 de diciembre de 1997. [Online]. Available: <https://unfccc.int/resource/docs/convkp/kpeng.pdf>
- [8] International Renewable Energy Agency (IRENA), "Statistics Time Series: Capacity and Generation Data," IRENA Data Platform, 2025. [Online]. Available: <https://www.irena.org/Data/View-data-by-topic/Capacity-and-Generation/Statistics-Time-Series>
- [9] R. E. de España. Informe del sistema eléctrico. Red Eléctrica de España (REE). [Online]. Available: <https://www.sistemaelectrico-ree.es/es/informe-del-sistema-electrico>
- [10] Global Wind Energy Council, "Global wind report 2025," Global Wind Energy Council (GWEC), Brussels, Belgium, Tech. Rep., 2025. [Online]. Available: <https://gwec.net/global-wind-report-2025>
- [11] Q. Gao, N. Ertugrul, and B. Ding, "Review and evaluation of offshore wind energy: Resources, markets and technologies," *International Marine Energy Journal*, vol. 8, pp. 309–319, 9 2025.
- [12] S. Bhattacharya and G. Nikitas, *Wind energy: status and outlook with focus on offshore wind*. Elsevier, 2025, pp. 197–224.
- [13] J. F. Manwell, J. G. McGowan, and A. L. Rogers, *Wind Energy Explained: Theory, Design and Application*, 2nd ed. Chichester, UK: John Wiley & Sons, 2009.
- [14] J. D. Anderson, *Computational Fluid Dynamics: The Basics with Applications*. New York: McGraw-Hill, 1995.
- [15] Autodesk Inc., "Autodesk CFD 2026 Help: Governing Equations," Autodesk Knowledge Network, 2026. [Online]. Available: <https://help.autodesk.com/view/SCDSE/2026/ENU/?guid=GUID-56CD9EA2-3AEA-476E-9B03-4E7A954F9E66>
- [16] Autodesk Inc., "Autodesk CFD 2026 Help: Discretization Method," Autodesk Knowledge Network, 2026. [Online]. Available: <https://help.autodesk.com/view/SCDSE/2026/ENU/?guid=GUID-DEE0664D-771B-4446-9ED4-1498267D13FB>
- [17] Autodesk Inc., "Autodesk CFD 2026 Help: Finite Element vs Finite Volume," Autodesk Knowledge Network, 2026. [Online]. Available: <https://help.autodesk.com/view/SCDSE/2026/ENU/?guid=GUID-12A9AED8-2047-4D3A-BC80-82BE9CF47517>
- [18] Autodesk Inc., "Autodesk CFD 2026 Help: Solution Method," Autodesk Knowledge Network, 2026. [Online]. Available: <https://help.autodesk.com/view/SCDSE/2026/ENU/?guid=GUID-46AC3A14-5C6E-485D-95BA-E174F1BC1A47>
- [19] F. Vorpahl, M.-A. Schwarzkopf, M. Strobel, H. Schulze, M. Sandberg, M. Krafczyk, and R. Wüchner, "Offshore wind turbine environment, loads, simulation, and design," *WIREs Energy and Environment*, vol. 2, no. 5, pp. 548–570, 2013.
- [20] Autodesk Inc., "Autodesk CFD 2026 Help: Turbulence," Autodesk Knowledge Network, 2026. [Online]. Available: <https://help.autodesk.com/view/SCDSE/2026/ENU/?guid=GUID-E9E8ACA1-8D49-4A49-8A35-52DB1A2C3E5F>
- [21] T. Naqash and M. Alam, "Vibration analysis of wind turbine blades," *Energies*, vol. 18, no. 3319, 2025.
- [22] M. Khalafallah, A. Ahmed, and M. Emam, "Cfd study of some factors affecting performance of hawt with swept blades," *International Journal of Sustainable Energy*, vol. 36, no. 5, pp. 489–501, 2017.
- [23] B. Belabes and M. Paraschivoiu, "Numerical study of the effect of turbulence intensity on vawt performance," *Energy*, vol. 233, pp. 121–139, 2021.

Respuesta Dinámica de una Plataforma Híbrida de Turbina Eólica Flotante con Columna de Agua Oscilante

Payam Aboutalebi,

Associate Member, IEEE Departamento de Arquitectura de Computadores y Control Automático, Universidad Complutense de Madrid Madrid, Spain

ORCID: 0000-0003-2716-1894

Email: payamabo@ucm.es

Segundo Esteban San Román

Departamento de Arquitectura de Computadores y Control Automático, Universidad Complutense de Madrid Madrid, Spain

ORCID: 0000-0002-4071-2147

Email: sesteban@ucm.es

Matilde Santos

*Instituto de Tecnología del Conocimiento
Universidad Complutense de Madrid (UCM)*

Madrid, España

ORCID: 0000-0003-1993-8368

Email: msantos@ucm.es

Abstract—This paper investigates the behavior of a hybrid Floating Wind Turbine (FWT) equipped with Oscillating Water Columns (OWCs) when subjected to irregular wave excitation generated using a JONSWAP spectrum. While previous studies have examined the system under regular sea states, real offshore environments are dominated by broadband wave energy, making irregular waves a critical evaluation scenario. A PID-based airflow control strategy is applied to the OWC valves to generate stabilizing forces that counteract pitch oscillations. Results demonstrate that the hybrid system reduces average pitch amplitude by approximately 94% compared with a reference semi-submersible platform, even under stochastic wave loading. Power output stability also improves, though modestly, with a 1.18% increase in mean electrical production under below-rated conditions. These findings confirm that active airflow regulation maintains effectiveness in non-periodic environmental conditions, highlighting the system's suitability for realistic offshore operations.

Keywords—Floating wind turbine, oscillating water column, irregular waves, active damping, control, platform motion

Resumen—Este trabajo analiza el comportamiento de una turbina eólica flotante (FWT) híbrida equipada con columnas de agua oscilante (OWCs) cuando se encuentra sometida a una excitación de oleaje irregular generada mediante un espectro JONSWAP. Aunque estudios previos han evaluado el sistema bajo estados de mar regulares, los entornos marinos reales están dominados por energía de oleaje de banda ancha, lo que convierte al oleaje irregular en un escenario fundamental para la evaluación del sistema. Se aplica una estrategia de control de flujo de aire basada en un regulador proporcional-integral-derivativo a las válvulas de las columnas de agua oscilante con el fin de generar fuerzas estabilizadoras que contrarresten las oscilaciones de cabeceo. Los resultados muestran que el sistema híbrido reduce la amplitud media del cabeceo en aproximadamente un noventa y cuatro por ciento en comparación con una plataforma

semisumergible de referencia, incluso bajo cargas estocásticas de oleaje. La estabilidad de la potencia generada también mejora, aunque de manera moderada, con un incremento del uno coma dieciocho por ciento en la producción eléctrica media bajo condiciones de viento por debajo de la velocidad nominal. Estos hallazgos confirman que la regulación activa del flujo de aire mantiene su eficacia en condiciones ambientales no periódicas, lo que resalta la idoneidad del sistema para operaciones en entornos marítimos reales.

Palabras claves—Turbina eólica flotante, columna de agua oscilante, oleaje irregular, amortiguamiento activo, control, movimiento de la plataforma.

I. INTRODUCCIÓN

La energía eólica flotante marina ha surgido como una tecnología clave para aprovechar los recursos eólicos en regiones de aguas profundas donde las cimentaciones fijas no son viables ni desde el punto de vista técnico ni económico. Las plataformas flotantes semisumergibles, en particular, ofrecen una estabilidad hidrostática favorable y requerimientos de calado relativamente bajos, lo que permite su despliegue en una amplia variedad de entornos marinos. Sin embargo, a pesar de sus ventajas, estas plataformas siguen siendo susceptibles al movimiento de cabeceo inducido por las olas, lo que afecta directamente la alineación del aerogenerador, la eficiencia aerodinámica, la carga estructural y la vida útil a largo plazo [1], [2].

El movimiento de cabeceo de la plataforma es especialmente crítico bajo condiciones de oleaje dominadas por componentes de periodo largo, que pueden excitar las frecuencias naturales de la estructura flotante. Investigaciones previas han demostrado que un cabeceo excesivo impacta

negativamente el rendimiento del generador, aumenta los requerimientos de espacio entre las palas y la torre, y amplifica significativamente las cargas en la góndola y la base de la torre [3]. Por estas razones, múltiples esfuerzos se han centrado en desarrollar estrategias de estabilización pasivas, semi-activas y totalmente activas. Entre ellas se incluyen amortiguadores de masa sintonizada [4], sistemas de lastre reactivo [5], optimización hidrodinámica de la forma [6] y estrategias avanzadas de control del aerogenerador, como el control de paso individual y la retroalimentación colectiva optimizada [7].

En los últimos años, se han propuesto conceptos híbridos flotantes que integran cámaras de columna de agua oscilante (OWC) en la estructura de la plataforma como una solución de doble propósito capaz de generar energía renovable adicional y mejorar la estabilidad dinámica del sistema simultáneamente. Los dispositivos OWC convierten la energía de las olas incidentes en energía neumática mediante la oscilación vertical de la cámara, y su respuesta dinámica puede modularse a través del control del flujo de aire. Varios estudios han mostrado que la estrangulación del flujo de aire, regulada mediante válvulas o turbinas auto-rectificantes, puede proporcionar un efecto de amortiguamiento controlable sobre la estructura de soporte [8], [9].

Trabajos tempranos de Bagheri et al. demostraron que la interacción aire-agua dentro de las cámaras OWC puede generar fuerzas estabilizadoras con una fuerte dependencia de la frecuencia [10]. Investigaciones más recientes de Zhou et al. analizaron el comportamiento no lineal y los efectos de acoplamiento hidrodinámico en sistemas multi-cámara, confirmando su potencial tanto para la extracción de energía de las olas como para la amortiguación estructural [11]. Sobre estas bases, varios investigadores han comenzado a explorar plataformas híbridas que integran aerogeneradores con cámaras OWC para mejorar tanto la captura de energía como el desempeño estructural. Entre ellos, Aboutalebi et al. presentaron recientemente un sistema semisumergible híbrido que utiliza control activo del flujo de aire para suprimir las oscilaciones de cabeceo bajo condiciones de oleaje regular [3].

No obstante, los entornos marinos reales no están dominados por olas regulares monocromáticas, sino por estados de mar aleatorios de banda ancha, caracterizados por grupos de olas estocásticos, múltiples picos espectrales e interacciones no lineales entre olas. Las olas irregulares a menudo introducen eventos transitorios de alta energía que amplifican los movimientos de baja frecuencia de la plataforma, constituyendo el escenario más exigente para las estrategias de control [12]. Por lo tanto, validar la efectividad de la estabilización basada en OWC bajo excitación de olas irregulares es esencial para evaluar la viabilidad real de tales conceptos híbridos.

El presente estudio se centra exclusivamente en el escenario de olas irregulares y proporciona una evaluación ampliada del comportamiento dinámico de la plataforma híbrida bajo estados de mar estocásticos generados mediante un espectro JONSWAP. Aplicando una estrategia de control del flujo

de aire proporcional-integral-derivativa (PID) a las válvulas de la OWC, se evalúa la capacidad de la plataforma para suprimir el movimiento de cabeceo, mantener la estabilidad y mejorar la regularidad de la producción de energía en entornos marinos realistas. El objetivo de este análisis ampliado es determinar si el efecto de amortiguamiento activo observado bajo condiciones de oleaje regular persiste cuando se introduce excitación de olas de banda ancha, un requisito clave para la operatividad marina.

II. DESCRIPCIÓN DEL SISTEMA

Este estudio se centra en una turbina eólica flotante semisumergible (FWT) modificada, INO WINDMOOR, equipada con cámaras OWC integradas dentro de sus columnas, como se muestra en la Figura 1. Cada OWC, equipada con una turbina Wells, aprovecha la energía de las olas para generar electricidad y proporcionar fuerzas de amortiguamiento que reducen el movimiento de balanceo y mejoran la estabilidad bajo condiciones dinámicas de las olas. Las OWCs contribuyen con momentos restauradores, mitigando efectivamente las oscilaciones mientras aumentan la producción de energía.




Fig. 1. INO WINDMOOR, turbina eólica flotante semisumergible con OWCs integradas.

Los análisis hidrodinámicos mostraron una mejora en la estabilidad de la FWT híbrida y una reducción de las amplitudes de balanceo en comparación con el diseño base. Se encontró que un diámetro de cámara de 4.5 m era óptimo para cumplir con los requisitos de estabilidad, desplazando las frecuencias naturales y reduciendo las amplitudes de respuesta. Este estudio amplía trabajos previos [13] incorporando la carga del viento y el control de válvulas de OWC, refinando el rendimiento dinámico del sistema bajo condiciones acopladas de viento y olas.

Las especificaciones técnicas de los componentes principales se detallan en las siguientes secciones. La Tabla I resume las características clave de la subestructura de la plataforma. Por su parte, la Tabla II presenta los parámetros operativos del sistema WINDMOOR, incluyendo la potencia nominal de la turbina. El modelado de estos elementos emplea la teoría de flujo potencial con la adición del modelo de Morison para los efectos de arrastre viscoso, asegurando así predicciones precisas de la respuesta del sistema híbrido.

TABLA I
CARACTERÍSTICAS DE LA SUBESTRUCTURA REMODELADA INO
WINDMOOR

Propiedad	Valor
Potencia eléctrica nominal	12 MW
Diámetro de la columna	15 m
Altura de la columna	31 m
Ancho del pontón	10 m
Altura del pontón	4 m
Distancia centro a centro	61 m
Ancho de la viga de cubierta	3.5 m
Altura de la viga de cubierta	3.5 m
Masa total de la subestructura incluyendo lastre	12058t
CGx total de la subestructura	-6.34 m
CGy total de la subestructura	0 m
CGz total de la subestructura	-10.02 m

TABLA II
PROPIEDADES DE LA TURBINA EÓLICA WINDMOOR DE 12 MW

Parámetro	WINDMOOR 12 MW
Potencia eléctrica nominal	12 MW
Potencia específica	324.8 W/m ²
Orientación del rotor	Rotación en sentido horario - contra el viento
Número de palas	3
Diámetro del rotor	216.9 m
Diámetro del cubo del rotor	5 m
Longitud de la pala	105.4 m
Presturbulencia de la pala	6.8 m
Inclinación del eje	6.0 grados
Presturbina del rotor	-4.0 grados
Altura del cubo	131.7 m
Velocidad de viento de encendido/nominal/apagado	4.0/10.6/25.0 m/s
Eficiencia del generador	94.4 %
Velocidad de rotor de encendido/nominal (rpm)	5.5/7.8
Velocidad máxima de la punta (m/s)	88.6
Masa de las palas (kg)	3×63.24
Masa del cubo (kg)	60000
Masa de la góndola (kg)	600000

III. ENFOQUE DE MODELADO DINÁMICO

El comportamiento de la plataforma híbrida se ha representado mediante un modelo completamente acoplado aero-hidro-servo-elástico, con el objetivo de capturar las interacciones simultáneas entre las fuerzas hidrodinámicas inducidas por el oleaje, las cargas aerodinámicas generadas por la turbina eólica, la dinámica estructural de la plataforma semisumergible y la respuesta neumática de las cámaras de columna de agua oscilante. Este enfoque permite describir con precisión tanto los efectos lineales como los no lineales presentes en el sistema, especialmente relevantes cuando la excitación proviene de estados de mar irregulares.

La ecuación de movimiento generalizada se expresa como:

$$\mathbf{M}\ddot{\mathbf{x}} + \mathbf{B}\dot{\mathbf{x}} + \mathbf{C}\mathbf{x} = \mathbf{f}_{\text{hidrodinámico}} + \mathbf{f}_{\text{aerodinámico}} + \mathbf{f}_{\text{OWC}}, \quad (1)$$

donde $\mathbf{M}$ representa la matriz de masas y masas añadidas, $\mathbf{B}$ la matriz de amortiguamiento hidrodinámico y estructural, $\mathbf{C}$ la matriz de rigidez hidroestática y elástica, y $\mathbf{x}$ es el vector de desplazamientos generalizados de la plataforma.

Las fuerzas generadas por las cámaras de columna de agua oscilante dependen de la interacción acoplada entre el movimiento del nivel de agua en el interior de la cámara, la compresibilidad del aire y el flujo volumétrico regulado por la válvula de control. Este mecanismo introduce un efecto amortiguador cuya magnitud es función directa de la variación de presión interna y del régimen de abertura de la válvula.

A. Representación del Oleaje Irregular

El estado de mar empleado en este estudio corresponde a oleaje irregular generado mediante el espectro JONSWAP, ampliamente utilizado para representar condiciones oceánicas moderadas con energía concentrada en un rango de frecuencias específico. Para este trabajo, los parámetros adoptados fueron:

- altura significativa de uno coma tres metros,
- periodo de pico de seis coma cinco segundos,
- factor de realce igual a tres coma tres.

Para garantizar una representación adecuada de las componentes de baja frecuencia y de los efectos de agrupación de olas, se generó una realización temporal de larga duración. Estas realizaciones permiten reproducir picos energéticos intermitentes que resultan críticos para evaluar la estabilidad de la plataforma y la efectividad del control en escenarios altamente variables.

El oleaje irregular se discretiza como suma de armónicos con amplitudes y fases aleatorias, de acuerdo con el proceso descrito por el espectro JONSWAP. Esta formulación introduce trenes de olas y eventos extrema que no se presentan en oleajes regulares y que representan un desafío significativo para las estrategias de control.

B. Modelado del Aire en la Cámara

El comportamiento del aire contenido en cada cámara se representa mediante un modelo adiabático del gas ideal, adecuado para ciclos de compresión y expansión rápidos y de pequeña pérdida térmica. La ecuación de evolución de la presión interna se describe como:

$$\frac{dp_c}{dt} = \frac{c_s^2}{V} \left(\frac{dm}{dt} - \rho \frac{dV}{dt} \right), \quad (2)$$

donde p_c es la presión interna del aire, V el volumen de la cámara, m la masa de aire contenida, ρ la densidad del fluido y c_s la velocidad del sonido.

El caudal másico de aire que atraviesa la válvula se estima mediante una formulación de orificio con borde afilado, cuya expresión depende del signo y de la magnitud de la diferencia de presión entre la cámara y la atmósfera. La apertura de la válvula, por tanto, regula de forma directa la velocidad de descarga del aire y la capacidad de la cámara para generar fuerzas verticales estabilizadoras.

Este acoplamiento neumático-hidrodinámico constituye el mecanismo central de amortiguamiento activo del sistema.

IV. ESTRATEGIA DE CONTROL

El flujo de aire a través de la válvula se gobierna mediante una ley de control proporcional-integral-derivativa cuyo objetivo principal es reducir al mínimo el ángulo de cabeceo de la plataforma. El control empleado se expresa como:

$$u(t) = K_p \theta(t) + K_d \dot{\theta}(t) + K_i \int \theta(t) dt, \quad (3)$$

donde $\theta(t)$ corresponde al ángulo instantáneo de cabeceo de la plataforma.

El término proporcional genera una reacción inmediata ante las desviaciones del cabeceo; el término derivativo proporciona amortiguamiento adicional frente a variaciones rápidas del movimiento; y el término integral asegura la eliminación del error estacionario en estado permanente.

Para evitar fenómenos de saturación y sobreacumulación del término integral, se incluye un mecanismo de limitación de anti-rebosamiento, especialmente relevante cuando la válvula alcanza sus límites físico-mecánicos de apertura.

V. DESCRIPCIÓN DEL ESCENARIO DE OLEAJE IRREGULAR

El análisis se centra exclusivamente en un estado de mar irregular correspondiente a un viento de siete coma nueve metros por segundo, representativo de condiciones de operación con velocidad por debajo del régimen nominal de la turbina eólica.

El oleaje presenta múltiples componentes de frecuencia y variaciones de amplitud que generan:

- excitación de banda ancha en torno a la frecuencia natural del cabeceo,
- trenes de olas que amplifican transitoriamente el movimiento de la plataforma,
- picos esporádicos de energía asociados a fenómenos de agrupación,
- transiciones rápidas entre crestas pronunciadas y valles profundos.

Este tipo de excitación no periódica impone un reto significativo para el controlador, que debe adaptarse continuamente a variaciones bruscas del oleaje y regular el flujo de aire para mantener la estabilidad global del sistema.

VI. RESULTADOS

En la Fig. 2 se presentan ocho subfiguras que muestran, de forma sincronizada, las variables más significativas registradas durante la simulación con oleaje irregular. A continuación se describe cada subfigura y se discuten las relaciones causales entre ellas.

A. Elevación de la ola (Fig. 2a)

La subfigura (a) representa la elevación instantánea de la superficie libre en las cercanías de la estructura. La señal proviene de una realización del espectro JONSWAP y exhibe agrupamiento de olas y picos esporádicos de energía. Estos eventos son los principales excitadores del sistema y condicionan la respuesta tanto neumática como estructural.

B. Señal de control (Fig. 2b)

La subfigura (b) muestra la señal de control calculada por el regulador proporcional-integral-derivativo a partir de la medida del ángulo de cabeceo. Bajo oleaje irregular la acción de control es no periódica: se observan pulsos de alta magnitud sincronizados con las agrupaciones de olas, así como periodos de esfuerzo reducido. Esta señal determina los órdenes de apertura/cierre de la válvula y refleja la capacidad del controlador para responder ante transitorios.

C. Apertura de la válvula (Fig. 2c)

La subfigura (c) expone la evolución de la posición de la válvula en grados. La válvula opera en un amplio rango operativo, desde completamente cerrada hasta completamente abierta, siguiendo la demanda del controlador. Se observan maniobras rápidas de apertura durante picos de excitación y posiciones intermedias sostenidas durante trenes de olas, lo que indica una acción adaptativa orientada a maximizar el efecto amortiguador sin provocar integrador excesivo ni oscilaciones de alta frecuencia en el actuador.

D. Densidad del aire (Fig. 2d)

La subfigura (d) muestra la evolución temporal de la densidad del aire en la cámara. Las variaciones de densidad están correlacionadas con las compresiones y expansiones del volumen de aire causadas por el movimiento de la columna de agua y por el flujo que atraviesa la válvula. La respuesta de la densidad es rápida ante cambios bruscos de presión, y actúa como indicador indirecto del estado termodinámico interno de la cámara.

E. Presión del aire (Fig. 2e)

La subfigura (e) presenta la presión interna del aire en la cámara. Los picos de presión coinciden con crestas pronunciadas del oleaje y con instantes en los que la válvula está parcialmente cerrada, acumulando compresión. La amplitud y la duración de estos picos determinan directamente la magnitud de la fuerza neumática que actúa sobre la columna.

F. Fuerza (Fig. 2f)

La subfigura (f) muestra la fuerza vertical resultante aplicada sobre la columna, derivada de la presión interna y del área efectiva de la superficie. Esta fuerza actúa como término de control físico sobre el movimiento de cabeceo: durante los episodios de mayor presión la fuerza proporciona un momento restaurador que contrarresta el cabeceo positivo; en fases de descarga la fuerza disminuye o invierte su signo, contribuyendo a la estabilidad global. La curva de fuerza aparece suavizada respecto a la presión debido a la filtración dinámica introducida por la masa de aire y el flujo a través del orificio.

G. Cabeceo de la plataforma (Fig. 2g)

La subfigura (g) compara el cabeceo de la plataforma bajo la configuración híbrida controlada frente a la plataforma de referencia sin intervención neumática. Se aprecia una reducción clara de la amplitud de las oscilaciones y la supresión de picos extremos que en la referencia alcanzan valores significativamente mayores. Estadísticamente, la amplitud media del cabeceo disminuye de forma sustancial, lo que confirma la eficacia del mecanismo de amortiguamiento activo frente a excitaciones no periódicas.




Fig. 2. Concepto de control para la estabilización del balanceo de la plataforma mediante el ajuste de la válvula de estrangulamiento OWC.

H. Potencia del generador (Fig. 2h)

La subfigura (h) expone la potencia instantánea del generador. La menor variabilidad en el cabeceo se traduce en una mayor estabilidad aerodinámica del rotor y, por consiguiente, en una reducción de las fluctuaciones de potencia. Además, se observa un ligero incremento en la potencia media debido a la mejora en el ángulo efectivo de incidencia del viento sobre el rotor durante los periodos de menor cabeceo.

I. Síntesis y conclusiones parciales

La cadena causal observada es consistente: los picos de elevación de la ola (subfigura a) generan demanda en la señal de control (subfigura b), que modula la apertura de la válvula (subfigura c). Esta acción modifica la dinámica termodinámica interna (subfiguras d y e), que a su vez produce fuerzas verticales (subfigura f) capaces de influir eficazmente sobre el cabeceo de la plataforma (subfigura g), con consecuencias positivas en la estabilidad de la potencia entregada por el generador (subfigura h). En conjunto, los datos muestran que el enfoque basado en la regulación activa del flujo de aire mediante válvulas ofrece un amortiguamiento adaptativo robusto frente al oleaje irregular, reduciendo tanto la magnitud como la frecuencia de los eventos extremos de cabeceo y mejorando la calidad de la potencia generada.

VII. CONCLUSIONES

Este estudio ha presentado un análisis detallado del comportamiento de una plataforma híbrida de turbina eólica flotante con columnas de agua oscilante sometida a oleaje irregular. La estrategia de control activa aplicada a las válvulas genera una reducción del cabeceo del orden del noventa y cuatro por ciento, manteniendo la estabilidad incluso frente a trenes de olas aleatorios. La producción eléctrica también se beneficia, aunque de manera moderada.

Los resultados confirman que la integración de cámaras de columna de agua oscilante con regulación activa constituye una solución efectiva para mejorar la estabilidad en condiciones operativas reales.

Como trabajo futuro, se propone ampliar el estudio mediante la optimización conjunta del diseño y las estrategias de control de las columnas de agua oscilante, así como la evaluación del comportamiento aero-hidro-servoelástico completo bajo un rango más amplio de condiciones ambientales, apoyándose en herramientas numéricas avanzadas y validación experimental adicional.

AGRADECIMIENTOS

Este trabajo fue financiado por el proyecto PID2021-23543OB-C21 y por la beca de Incorporación

Juan de la Cierva (JDC2023-052400-I) y PID2024-155653OB a través de MCIN/AEI.

REFERENCIAS

- [1] J. M. Jonkman, *Dynamics modeling and loads analysis of an offshore floating wind turbine*. University of Colorado at Boulder, 2007.
- [2] Y. Liu, Q. Xiao, A. Incecik, and D.-c. Wan, "Investigation of the effects of platform motion on the aerodynamics of a floating offshore wind turbine," *Journal of Hydrodynamics*, vol. 28, no. 1, pp. 95–101, 2016.
- [3] P. Aboutaleb, I. Garrido, D. T. Nguyen, and A. J. Garrido, "Stabilization and dynamic control of semi-submersible hybrid floating wind turbine—oscillating water column platforms," *Energy Conversion and Management*, vol. 348, p. 120623, 2026.
- [4] D. Villoslada, M. Santos, and M. Tomás-Rodríguez, "Identification and validation of a barge floating offshore wind turbine model with optimized tuned mass damper," in *10th EUROSIM Congress, La Rioja, Logroño, Spain*, 2019.
- [5] C. Li, P. Chen, S. Deng, S. Wang, Z. Cheng, and L. Xiao, "Effects of ballast transfer on modeling and dynamic responses of a 15mw semi-submersible floating wind turbine," *Ocean Engineering*, vol. 302, p. 117581, 2024.
- [6] D. Matha, "Model development and loads analysis of an offshore wind turbine on a tension leg platform with a comparison to other floating turbine concepts: April 2009," National Renewable Energy Lab.(NREL), Golden, CO (United States), Tech. Rep., 2010.
- [7] E. A. Bossanyi, "Further load reductions with individual pitch control," *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, vol. 8, no. 4, pp. 481–485, 2005.
- [8] A. F. d. O. Falcão, "Wave energy utilization: A review of the technologies," *Renewable and sustainable energy reviews*, vol. 14, no. 3, pp. 899–918, 2010.
- [9] M. Takao and T. Setoguchi, "Air turbines for wave energy conversion," *International Journal of Rotating Machinery*, vol. 2012, no. 1, p. 717398, 2012.
- [10] T. Bagheri-Rouch, P. Aboutaleb, A. J. Garrido, and I. Garrido, "Dynamic performance analysis of floating offshore wind turbines integrated with oscillating water columns matrix," *Ocean Engineering*, vol. 339, p. 122128, 2025.
- [11] Y. Zhou, D. Ning, L. Chen, and G. Iglesias, "Nonlinear hydrodynamic modeling of an offshore stationary multi-oscillating water column platform," *Ocean Engineering*, vol. 227, p. 108919, 2021.
- [12] T. A. Adcock, P. H. Taylor, and S. Draper, "Nonlinear dynamics of wave-groups in random seas: unexpected walls of water in the open ocean," *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 471, no. 2184, p. 20150660, 2015.
- [13] P. Aboutaleb, A. J. Garrido, I. Garrido, D. T. Nguyen, and Z. Gao, "Hydrostatic stability and hydrodynamics of a floating wind turbine platform integrated with oscillating water columns: A design study," *Renewable Energy*, vol. 221, p. 119824, 2024.

Análisis Hidrodinámico de Aerogeneradores Marinos Flotantes

1st Tahereh Bagheri-Rouch

*Automatic Control Group (ACG),
Institute of Research and Development of Processes-IIDP
Department of Automatic Control and Systems Engineering,
Bilbao School of Engineering
University of the Basque Country-EHU, Edificio
II, Paseo Rafael Moreno 3, Bilbao, Spain
tahereh.bagheri@ehu.eus*

3rd Irfan Ahmad

*Automatic Control Group (ACG),
Institute of Research and Development of Processes-IIDP
Department of Automatic Control and Systems Engineering,
Bilbao School of Engineering,
University of the Basque Country-EHU,
Edificio II, Paseo Rafael Moreno 3, Bilbao, Spain
irfanahmad.irfan@ehu.eus*

2nd Fares Mzoughi

*Sustainable Systems Design Lab-SSDL,
Institute for Integrated Energy Systems-IESVic, Department
of Mechanical Engineering,
Faculty of Engineering and Computer Science,
University of Victoria-UVic,
3800 Finnerty Road, V8P 5C2 Victoria BC, Canada
faresmzoughi@uvic.ca*

4th Aitor J. Garrido

*Automatic Control Group (ACG),
Institute of Research and Development of Processes-IIDP
Department of Automatic Control and Systems
Engineering, Bilbao School of Engineering,
University of the Basque Country-EHU,
Edificio II, Paseo Rafael Moreno 3, Bilbao, Spain
aitor.garrido@ehu.eus*

5th Izaskun Garrido

*Automatic Control Group (ACG),
Institute of Research and Development of Processes-IIDP
Department of Automatic Control and Systems
Engineering,
Bilbao School of Engineering,
University of the Basque Country-EHU,
Edificio II, Paseo Rafael Moreno 3, Bilbao, Spain
izaskun.garrido@ehu.eus*

Abstract—The dynamic response of Floating Offshore Wind Turbines (FOWTs) to wave excitation affects both their stability and energy generation. This work presents a novel rectangular active platform featuring a matrix of Oscillating Water Columns (OWCs) designed to reduce wave-induced motions. The OWCs can operate in open or closed configurations, enabling potential active tuning strategies to prevent resonance. Analysis using the Response Amplitude Operator (RAO) and numerical simulations demonstrates that this platform considerably diminishes motions, especially in pitch, when compared to a traditional square barge, resulting in enhanced stability and increased power capture.

Index Terms—Floating offshore wind turbines, Oscillating water columns, Active rectangular platform, Hydrodynamic analysis, Response amplitude operator.

Resumen— La respuesta dinámica de los aerogeneradores marinos flotantes (FOWTs) ante la excitación de las olas afecta tanto su estabilidad como la generación de energía. Este trabajo presenta una novedosa plataforma activa rectangular que incorpora una matriz de Columnas de Agua Oscilantes (OWCs) diseñada para reducir los movimientos inducidos por las olas. Las OWCs pueden operar en configuraciones abiertas o cerradas, lo que permite estrategias de ajuste activo para evitar la resonancia. El análisis mediante el Operador de Amplitud de Respuesta (RAO) y las simulaciones numéricas muestran que esta

plataforma reduce considerablemente los movimientos, especialmente en cabeceo, en comparación con una barcaza cuadrada tradicional, mejorando así la estabilidad y el aprovechamiento energético.

Términos del índice—Aerogeneradores marinos flotantes, Columnas de agua oscilantes, Plataforma rectangular activa, Análisis hidrodinámico, Operador de amplitud de respuesta.

I. INTRODUCCIÓN

El cambio climático, impulsado por emisiones humanas de gases de efecto invernadero y la dependencia de combustibles fósiles, requiere una transición hacia energías limpias y renovables [1]. La energía renovable marina, aprovechando viento, olas, mareas y corrientes, ofrece recursos más constantes, permite turbinas más eficientes y genera menor impacto visual [2]. La energía undimotriz destaca por su alta densidad energética y estabilidad frente a la eólica y solar [3]. Los WECs producen electricidad constante, útil en zonas costeras con oleaje intenso, mejorando la estabilidad de la red y reduciendo la dependencia de fuentes variables [4]. Se han explorado diversas estrategias para reducir las vibraciones en FOWTs, siendo el control de pitch especialmente eficaz para minimizar

las cargas en la raíz de las palas y las fluctuaciones de potencia causadas por las fuerzas del viento y las olas [5]. Además, autores en [6] han presentado técnicas metaheurísticas, incluidos algoritmos genéticos, para optimizar sistemas de control semi-activo en plataformas tipo barcaza. El control robusto multimodal, mediante ajustes de pitch y torque, ha mejorado la estabilidad, especialmente en plataformas TLP, para reducir los movimientos de cabeceo y balanceo [7]. Los cables pasivos disminuyen los movimientos de avance, desplazamiento lateral y cabeceo [8], mientras que los controles avanzados amortiguan tanto los movimientos traslacionales como rotacionales [9].

Los avances en energía marina han incrementado la demanda de WECs eficientes [10]. Aunque numerosos estudios combinan FOWTs y WECs para la generación dual de energía [11], pocos se centran en el uso de OWCs para mejorar la estabilidad [12]. Las OWCs resultan prometedoras debido a su eficiencia, simplicidad y adaptabilidad a entornos marinos [13].

Económicas y ampliamente estudiadas, las OWCs pueden aumentar la producción energética, amortiguar los movimientos de la plataforma y reducir las cargas estructurales en los FOWTs [14]. Su integración es especialmente adecuada en plataformas tipo barcaza, facilitando el desarrollo de sistemas híbridos de energías renovables [15]. Las OWCs convierten el movimiento de las olas en energía eléctrica mediante la compresión de aire en cámaras que acciona turbinas [16].

Estudios previos, como [17, 18], muestran que la integración de WECs puede reducir los movimientos de la plataforma, aunque también destacan los costos asociados. Autores en [19] presentaron un diseño de subestructura semisumergible orientado a minimizar oscilaciones y promover la viabilidad a largo plazo. Autores en [20] demostraron cómo los WECs absorben la energía de las olas para amortiguar cabeceo, balanceo y alabeo, mejorando la estabilidad de la plataforma, como también respaldan en [21].

Las OWCs se han integrado en FOWTs, especialmente en plataformas tipo spar, para reducir el movimiento [22]. Algunos estudios las aplicaron a barcasas cuadradas mediante modelos no lineales. En [23] se propuso un moonpool cuadrado para integrar OWCs, aunque no para estabilización. En [24] se comparó una barcaza estándar con otra con cuatro OWCs, sin considerar efectos del viento. Luego, se propuso una estrategia de control basada en RAO para reducir oscilaciones en condiciones sin viento [25], optimizando el flujo de aire para mejorar la estabilidad y reducir fluctuaciones de potencia [26]. Sin embargo, la integración de matrices de OWCs configurables aún no ha sido estudiada. Este artículo muestra cómo la apertura o el cierre de la matriz de OWCs influye en la reducción de las oscilaciones.

La estructura del artículo es la siguiente: la Sección II aborda la dinámica de las olas y el modelado de la plataforma activa rectangular equipada con una matriz de OWCs. La Sección 3 presenta un análisis en el dominio de la frecuencia de la plataforma bajo configuraciones de OWCs abiertas y cerradas, comparando los resultados con los de una barcaza

cuadrada convencional. Finalmente, los resultados del estudio se resumen en la Sección 4.

II. MODELADO DE UNA PLATAFORMA TIPO BARCAZA CON CONTROL ACTIVO MEDIANTE UNA MATRIZ DE OWCs

Este estudio examina ondas regulares unidireccionales utilizando la teoría de ondas de Airy [27].

$$r(t) = A_{\text{wave}} \sin(2\pi ft) = A_{\text{wave}} \sin\left(\frac{2\pi}{\lambda} ct\right) \quad (1)$$

donde $c = \lambda f$ denota la velocidad de la onda, A_{wave} es la amplitud de la onda y λ es la longitud de onda. El comportamiento temporal de la onda, que captura el movimiento oscilatorio macroscópico de las partículas de agua en una ubicación fija, se expresa como:

$$r(x, t) = A_{\text{wave}} \sin\left(\frac{2\pi}{\lambda}(ct - x)\right) \quad (2)$$

La ecuación (2) se puede reescribir como (3) usando el número de onda $k = \frac{2\pi}{\lambda}$:

$$r(x, t) = \frac{H_{\text{wave}}}{2} \sin(\omega t - kx) \quad (3)$$

donde H_{wave} denota la altura de la onda medida desde el seno hasta la cresta. Este estudio modela la dinámica no lineal completa del aerogenerador flotante acoplado y la plataforma rectangular como:

$$M_{\text{INERTIA}_{ij}}(q, u, t)\ddot{q}_j = f_j(q, \dot{q}, u, t) \quad (4)$$

donde $M_{\text{INERTIA}_{ij}}$ es la matriz de masa-inercia, u son las entradas de control, y f_j incluye fuerzas aerodinámicas, hidrodinámicas y estructurales.

Para el análisis en el dominio de la frecuencia, el modelo no lineal se linealiza alrededor del equilibrio, asumiendo desplazamientos pequeños y amplitudes de onda pequeñas según la teoría de ondas de Airy. El sistema linealizado se expresa como:

$$I_{\text{FOWT}}(\omega)\ddot{q} + D_{\text{FOWT}}(\omega)\dot{q} + S_{\text{FOWT}}(\omega)q = N_{\text{FOWT}}(\omega) + N_{\text{PTO}}(\omega) \quad (5)$$

donde I_{FOWT} , D_{FOWT} y S_{FOWT} representan la inercia relacionada con la masa, el amortiguamiento y las propiedades de restauración. Los vectores $\vec{N}_{\text{FOWT}}(\omega)$ y $\vec{N}_{\text{PTO}}(\omega)$ describen, respectivamente, las fuerzas externas hidrodinámicas y viscosas debidas a las olas y las fuerzas internas producidas por la unidad de Power Take-Off (PTO).

La variable q en la Ecuación (4) denota el total de grados de libertad (DOFs).

$$q = \begin{bmatrix} \text{surge} \\ \text{sway} \\ \text{heave} \\ \text{roll} \\ \text{pitch} \\ \text{yaw} \\ \text{fore-aft} \\ \text{side-to-side} \end{bmatrix} \quad (6)$$

En este trabajo se analizan dos configuraciones utilizando MultiSurf, una herramienta de modelado de superficies para estructuras marinas, con el fin de diseñar la geometría de la plataforma. La Figura 1a muestra la plataforma rectangular con OWCs abiertos, donde las cámaras están ventiladas a la atmósfera, permitiendo el libre flujo de aire, mientras que la Figura 1b presenta OWCs cerrados, en los que las cámaras están selladas, atrapando aire y modificando la respuesta hidrodinámica de la plataforma. Estas configuraciones se utilizan para evaluar el efecto de los modos de operación de las OWCs en la hidrodinámica de la plataforma. El mado se realiza únicamente sobre la superficie humedecida en su condición no perturbada.

III. ANÁLISIS AVANZADO DE AEROGENERADORES FLOTANTES Y DE UNA PLATAFORMA RECTANGULAR ACTIVA CON MATRIZ DE OWCs

Tras modelar la geometría de la plataforma, las interacciones ola-estructura se analizan con WAMIT para obtener las cargas hidrodinámicas sobre las superficies humedecidas. Para los aerogeneradores flotantes, se consideran también cargas aerodinámicas, flexibilidad estructural y control [28]. Los RAOs se calculan con OpenFAST mediante simulaciones en el dominio del tiempo con excitación de olas de ruido blanco, capturando movimientos traslacionales y rotacionales, y mostrando la respuesta en frecuencia y la resonancia del sistema.

Para garantizar la robustez estadística, las simulaciones se repiten M veces con diferentes semillas aleatorias de oleaje. Se descartan los transitorios iniciales y los datos restantes se promedian a lo largo de las ejecuciones para reducir el ruido espectral, minimizar los efectos de fuga y mejorar la confiabilidad de los resultados [29]. El RAO se define entonces como:

$$\text{RAO} = \frac{C_{xy}(\omega)}{C_{xx}(\omega)} \quad (7)$$

$C_{xy}(\omega)$ denota la densidad espectral cruzada entre la entrada $x(t)$ y la salida $y(t)$, mientras que $C_{xx}(\omega)$ representa la densidad espectral autosimilar de la señal de entrada (elevación de la superficie de la ola). Estas funciones se expresan como:

$$C_{xy}(\omega) = \frac{1}{M} \sum_{s=1}^M Y_{\text{salida}}[s](r) \overline{X_{\text{entrada}}[s](r)} \quad (8)$$

$$C_{xx}(\omega) = \frac{1}{M} \sum_{s=1}^M X_{\text{entrada}}[s](r) \overline{X_{\text{entrada}}[s](r)} \quad (9)$$

Aquí, $X_{\text{entrada}}[s]$ representa la Transformada Rápida de Fourier (FFT) del s -ésimo segmento temporal, siendo M el número total de ejecuciones de la simulación y r el patrón de ruido aleatorio utilizado. El símbolo $\overline{X_{\text{entrada}}}$ denota el conjugado complejo de X_{entrada} .

A. Comparación del desempeño de la plataforma rectangular activa con matriz de OWCs y la plataforma cuadrada convencional para aerogeneradores flotantes

Este estudio investiga un aerogenerador eólico flotante de 5 MW montado sobre una plataforma rectangular activa. A través de una extensa investigación, se introdujo una plataforma innovadora, de geometría rectangular, que incorpora una matriz de OWCs. Esta configuración actúa como una estrategia de control fundamental, en la que los estados operativos de los OWCs (abiertos o cerrados) se utilizan para influir en el comportamiento hidrodinámico de la plataforma.

La plataforma rectangular activa con OWCs se comparó con la barcaza cuadrada convencional para periodos de ola de 2 a 40 s (0,025–0,5 Hz). Los RAOs muestran reducción en los movimientos de desplazamiento (surge) y cabeceo (pitch), con la resonancia de cabeceo adelantada 3,8 s. Este diseño disminuye la frecuencia natural y el ángulo máximo de cabeceo en 3° , mostrando un mejor desempeño dinámico.

Se realizaron seis simulaciones con entradas de ola de tipo ruido blanco generadas a partir de distintas semillas aleatorias [30]. Tal como se muestra en la Figura 2, cada entrada tuvo una duración de 8000 s, descartando los primeros 2000 s para eliminar efectos transitorios, con una amplitud constante de 2 m según la teoría lineal de ondas. Promediar las seis ejecuciones permitió suavizar el espectro, centrar el histograma y minimizar la sensibilidad al ruido [31].

En este trabajo, los RAOs se evalúan para seis grados de libertad-surge, sway, heave, pitch, yaw y desplazamientos torre proa-popa-como se muestra en las Figuras 3a–f. La figura compara dos configuraciones: la plataforma rectangular activa con matriz de OWCs cerrados (línea azul continua), la plataforma rectangular activa con matriz de OWCs abiertos (línea verde discontinua) y la plataforma barcaza cuadrada (línea marrón trazo-punto).

En la Figura 3a, ambas configuraciones de la plataforma rectangular activa (OWCs cerrados y abiertos) presentan RAOs de surge similares para periodos de ola de 2–4 s y 17–40 s. Los RAOs máximos son 1,4 m/m a 8,2 s (OWCs cerrados) y 1,6 m/m a 9,8 s (OWCs abiertos), mientras que la barcaza cuadrada alcanza 2,4 m/m a 11,9 s.

Bajo una dirección de ola de 0° y sin viento, las oscilaciones de sway son mínimas. En resonancia, el RAO de sway es menor con OWCs cerrados que con OWCs abiertos, y cercano a cero en la barcaza cuadrada. De manera similar, los RAOs de yaw son prácticamente nulos para todas las configuraciones, como se muestra en las Figuras 3b,e.

En la Figura 3c, los RAOs de heave son menores en la configuración con OWCs cerrados, indicando una mayor estabilidad vertical. Para periodos de ola superiores a 13 s, el




Fig. 1. Geometrías de la plataforma rectangular con (a) matriz de OWCs abierta y (b) matriz de OWCs cerrada




Fig. 2. Entrada de onda de ruido blanco

RAO de los OWCs abiertos se aproxima a 1 m/m, similar al de la barcaza cuadrada, reflejando un incremento del movimiento.

Las Figuras 3d,f muestran los RAOs de desplazamiento torre proa-popa y de pitch. Los máximos de desplazamiento ocurren a 8,1 s para OWCs cerrados, 9,5 s para OWCs abiertos y 11,7 s para la barcaza cuadrada. Los OWCs cerrados presentan valores mayores antes de 8,8 s, y todas las configuraciones tienden a cero después de 13 s. Estos resultados indican que la plataforma rectangular activa con OWCs cerrados ofrece un mejor desempeño dinámico en periodos cortos.

Minimizar el movimiento de pitch es esencial para el desempeño de la plataforma rectangular activa. Como se muestra en la Figura 3f, los RAOs de pitch coinciden hasta 3,2 s y alcanzan máximos de 11,5° a 8,1 s (OWCs cerrados) y 12,7° a 9,5 s (OWCs abiertos), disminuyendo luego hacia cero alrededor de 25 s. En comparación, la barcaza cuadrada presenta un máximo de 14,5° a 11,9 s. Estos resultados evidencian la mejora en pitch de la plataforma rectangular activa.

IV. CONCLUSIÓN

Este estudio presenta una plataforma rectangular activa con matriz de OWCs, diseñada para reducir oscilaciones, mejorar

la estabilidad y optimizar la captura de energía eólica. Se realizó un análisis comparativo con una barcaza cuadrada convencional, calculando los RAOs en ambas configuraciones de la plataforma rectangular: OWCs abiertas y cerradas.

Los resultados muestran que la plataforma rectangular redujo el RAO de cabeceo hasta 3,8° en olas cortas. Las OWCs abiertas fueron más efectivas para periodos < 8.9 s, mientras que las cerradas ofrecieron mejor desempeño en periodos más largos (8,9–40 s), demostrando su adaptabilidad frente a distintas condiciones de mar.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación (MICIU) y la Agencia Estatal de Investigación (AEI) a través de los proyectos PID2021-123543OB-C21 y PID2021-123543OB-C22, así como PID2024-155653OB-C21 y PID2024-155653OB-C22, cofinanciados por el Fondo Europeo de Desarrollo Regional (FEDER/UE). Asimismo, este trabajo ha contado con el apoyo adicional de la ayuda PRE2022-101853, financiada por MICIU/AEI/10.13039/501100011033 y por el Fondo Social Europeo Plus (FSE+).




Fig. 3. RAOs para la plataforma rectangular activa con matriz de OWCs y para la plataforma convencional de barcaza cuadrada

REFERENCIAS

- [1] Kabeyi MJ, Olanrewaju OA. Sustainable energy transition for renewable and low carbon grid electricity generation and supply. *Frontiers in Energy research*. 2022 Mar 24;9:743114.
- [2] Marino E, Gkantou M, Malekjafarian A, Bali S, Baniotopoulos C, van Beeck J, Borg RP, Bruschi N, Cardiff P, Chatzi E, Čudina I. Offshore renewable energies: A review towards Floating Modular Energy Islands—Monitoring, Loads, Modelling and Control. *Ocean engineering*. 2024 Dec 1;313:119251.
- [3] Bouhrim H, El Marjani A, Nechad R, Hajjout I. Ocean wave energy conversion: A review. *Journal of Marine Science and Engineering*. 2024 Oct 28;12(11):1922.
- [4] Rajapakse G, Jayasinghe S, Fleming A, Negnevitsky M. Grid integration and power smoothing of an oscillating water column wave energy converter. *Energies*. 2018 Jul 18;11(7):1871.
- [5] Li Z, Wen B, Dong X, Long X, Peng Z. Effect of blade pitch control on dynamic characteristics of a floating offshore wind turbine under platform pitching motion. *Ocean Engineering*. 2021 Jul 15;232:109109.
- [6] Ramírez A, Tomás-Rodríguez M, Sierra-García JE, Santos M. Metaheuristic optimized semi-active structural

- control approaches for a floating offshore wind turbine. *Applied Sciences*. 2024 Dec 5;14(23):11368.
- [7] Shektaei SR, Sadati N. Multi model robust control design for a floating offshore variable speed wind turbine with tension leg platform. *Ocean Engineering*. 2022 Dec 15;266:113033.
- [8] Yu J, Luo C, Wang C, Sun H, Yin B. Theoretical and experimental study on vibration control of a floating offshore wind turbine using damping cables. *Ocean Engineering*. 2025 Mar 1;319:120261.
- [9] Yucu HU, Yanping HE, Ming QI, Yadong LI, Mingzhi LI. Overall vibration-reduction technology of FPSO top-sides based on elastic connection. *Chinese Journal of Ship Research*. 2023 Aug 2;19(3):278-91.
- [10] Golbaz D, Asadi R, Amini E, Mehdipour H, Nasiri M, Nezhad MM, Naeeni ST, Neshat M. Ocean wave energy converters optimization: A comprehensive review on research directions. *arXiv preprint arXiv:2105.07180*. 2021 May 15.
- [11] Cheng Z, Wen TR, Ong MC, Wang K. Power performance and dynamic responses of a combined floating vertical axis wind turbine and wave energy converter concept. *Energy*. 2019 Mar 15;171:190-204.
- [12] Ahmad I, M'zoughi F, Aboutalebi P, Garrido I, Garrido AJ. A regressive machine-learning approach to the non-linear complex FAST model for hybrid floating offshore wind turbines with integrated oscillating water columns. *Scientific Reports*. 2023 Jan 27;13(1):1499.
- [13] Konispoliatis DN. Floating Oscillating Water Column Wave Energy Converters: A Review of Developments. *Journal of Energy and Power Technology*. 2024 Feb;6(1):1-29.
- [14] Cayuela-Padilla S, M'zoughi F, Garrido I, Garrido AJ. Design and stability analysis of a new six-floater oscillating water column-based floating offshore wind turbine platform. *Scientific Reports*. 2024 Jul 13;14(1):16191.
- [15] Han M, Shi H, Cao F, Zhu K, Liu B, Yu M, Wei Z. Dynamic characteristics and parameter analysis of a floating hybrid wind-wave energy system based on a novel coupled numerical framework. *Energy Conversion and Management*. 2024 Jul 15;312:118558.
- [16] Gayathri R, Chang JY, Tsai CC, Hsu TW. Wave energy conversion through oscillating water columns: a review. *Journal of Marine Science and Engineering*. 2024 Feb 17;12(2):342.
- [17] M'zoughi F, Lekube J, Garrido AJ, De La Sen M, Garrido I. Machine learning-based diagnosis in wave power plants for cost reduction using real measured experimental data: Mutriku Wave Power Plant. *Ocean Engineering*. 2024 Feb 1;293:116619.
- [18] Haji MN, Kluger JM, Sapsis TP, Slocum AH. A symbiotic approach to the design of offshore wind turbines with other energy harvesting systems. *Ocean Engineering*. 2018 Dec 1;169:673-81.
- [19] Aboutalebi P, Garrido AJ, Garrido I, Nguyen DT, Gao Z. Hydrostatic stability and hydrodynamics of a floating wind turbine platform integrated with oscillating water columns: A design study. *Renewable Energy*. 2024 Feb 1;221:119824.
- [20] Koo W, Kim HB. Numerical and experimental studies of the effects of WEC motion on a combined wind-wave energy platform. In *Proceedings of the European Wave and Tidal Energy Conference 2023 Sep 2 (Vol. 15)*.
- [21] Ahmad I, M'zoughi F, Aboutalebi P, Garrido I, Garrido AJ. Fuzzy logic control of an artificial neural network-based floating offshore wind turbine model integrated with four oscillating water columns. *Ocean Engineering*. 2023 Feb 1;269:113578.
- [22] Khurshid H, Mohammed BS, Al-Yacoubi AM, Liew MS, Zawawi NA. Analysis of hybrid offshore renewable energy sources for power generation: A literature review of hybrid solar, wind, and waves energy systems. *Developments in the Built Environment*. 2024 Oct 1;19:100497.
- [23] Jonkman JM. Dynamics modeling and loads analysis of an offshore floating wind turbine. University of Colorado at Boulder; 2007.
- [24] Aboutalebi P, M'zoughi F, Garrido I, Garrido AJ. Performance analysis on the use of oscillating water column in barge-based floating offshore wind turbines. *Mathematics*. 2021 Jan;9(5):475.
- [25] Aboutalebi P, M'zoughi F, Martija I, Garrido I, Garrido AJ. Switching control strategy for oscillating water columns based on response amplitude operators for floating offshore wind turbines stabilization. *Applied Sciences*. 2021 Jun 5;11(11):5249.
- [26] Aboutalebi P, M'zoughi F, Garrido I, Garrido AJ. A control technique for hybrid floating offshore wind turbines using oscillating water columns for generated power fluctuation reduction. *Journal of Computational Design and Engineering*. 2023 Feb;10(1):250-65.
- [27] Bagheri-Rouch T, Aboutalebi P, Garrido AJ, Garrido I. Dynamic performance analysis of floating offshore wind turbines integrated with oscillating water columns matrix. *Ocean Engineering*. 2025 Nov 15;339:122128.
- [28] Jonkman JM, Matha D. Dynamics of offshore floating wind turbines—analysis of three concepts. *Wind Energy*. 2011 May;14(4):557-69.
- [29] Gao Z, Merino D, Han KJ, Li H, Fiskvik S. Time-domain floater stress analysis for a floating wind turbine. *Journal of Ocean Engineering and Science*. 2023 Aug 1;8(4):435-45.
- [30] Ramachandran GK, Robertson A, Jonkman JM, Masciola MD. Investigation of response amplitude operators for floating offshore wind turbines. In *ISOPE International Ocean and Polar Engineering Conference 2013 Jun 30 (pp. ISOPE-I)*. ISOPE.
- [31] Bonnefoy F, Ducrozet G, Le Touzé D, Ferrant P. Time domain simulation of nonlinear water waves using spectral methods. In *Advances in numerical simulation of nonlinear water waves 2010 (pp. 129-164)*.

Estudio de Análisis Hidrodinámico Comparativo en el Dominio de la Frecuencia de una Plataforma Híbrida de Aerogenerador Marino Flotante OWC

Fares M'zoughi^{1,2,*}, Virag Mishra³, Curran Crawford¹, Aitor J. Garrido² and Izaskun Garrido²

¹ Institute for Integrated Energy Systems–IESVic, Department of Mechanical Engineering,
Faculty of Engineering and Computer Science, University of Victoria–UVic,
Victoria, BC, Canada

² Automatic Control Group–ACG, Department of Automatic Control and Systems Engineering,
Faculty of Engineering of Bilbao, University of the Basque Country–UPV/EHU,
Bilbao, Bizkaia, Spain

³ Pacific Marine Energy Center–PMEC, Oregon State University–OSU,
Corvallis, Oregon, United States

* Corresponding author email: faresmzoughi@uvic.ca

Abstract— In this research work, the vibration mitigation of Floating Offshore Wind Turbine (FOWT) in a new proposed hybrid wind-wave platform has been studied. The results of frequency domain hydrodynamic analysis using three modelling packages on two FOWT platforms has been compared side-by-side. The platforms under consideration are the standard ITI Energy Barge and ITI Energy barge with four integrated Oscillating Water Columns (OWCs). The OWCs are used for two objectives on one hand harness wave energy along with the wind energy and on the other hand be used as active structural control to mitigate the undesired vibration induced by the wind and wave loads. The modelling approaches considered are WAMIT, ShipMo and Ansys Aqwa. While linear wave theory only necessitates meshing of the wetted surface in the undisplaced position, numerical tools vary in their requirements. The results show similar expected behavior where they peak out at some intermediate frequency and level out at higher frequencies. Also, all three models show a spike at a certain sloshing resonance frequency which is due to the sloshing water inside the capture chambers of the introduced moonpools. The achieved results provide an insight into the platform's stability and design.

Keywords—OWC, FOWT, Barge, RAO, MultiSurf, WAMIT, Rhino, ShipMo, Ansys AQWA

Resumen— En este trabajo de investigación, se ha estudiado la mitigación de vibraciones de turbinas eólicas marinas flotantes (FOWT) en una nueva plataforma híbrida propuesta de viento-olas. Se han comparado lado a lado los resultados del análisis hidrodinámico del dominio de la frecuencia utilizando tres paquetes de modelado en dos plataformas FOWT. Las plataformas en consideración son la barcaza ITI Energy estándar y la barcaza ITI Energy con cuatro columnas de agua oscilantes (OWC) integradas. Las OWC se utilizan para dos objetivos: por un lado, aprovechar la energía de las olas junto con la energía eólica y, por otro lado, usarse como control estructural activo para mitigar la vibración no deseada inducida por las cargas de viento y olas. Los enfoques de modelado considerados son WAMIT, ShipMo y Ansys Aqwa. Si bien la teoría de olas lineales solo necesita el mallado de la superficie mojada en la posición no desplazada, las herramientas numéricas varían en sus requisitos. Los resultados muestran un comportamiento esperado similar donde alcanzan un pico en una frecuencia intermedia y se estabilizan en frecuencias

más altas. Además, los tres modelos muestran un pico en una determinada frecuencia de resonancia de chapoteo, debido al chapoteo del agua dentro de las cámaras de captura de las piscinas lunares introducidas. Los resultados obtenidos ofrecen una perspectiva sobre la estabilidad y el diseño de la plataforma.

Palabras clave—OWC, FOWT, Barcaza, RAO, MultiSurf, WAMIT, Rhino, ShipMo, Ansys AQWA

I. INTRODUCCIÓN

El cambio global hacia energías limpias ha sido impulsado por el agotamiento de las reservas de combustibles fósiles y la necesidad urgente de mitigar el cambio climático [1]. En este contexto, las fuentes de energía renovable como la eólica, la solar y la undimotriz han ganado protagonismo como soluciones sostenibles y escalables para satisfacer la creciente demanda energética prevista para 2050 [2]. Entre ellas, la energía eólica destaca por su madurez tecnológica, su amplia implementación y su competitividad económica, contribuyendo de manera significativa a los esfuerzos globales de descarbonización [3].

Si bien la energía eólica terrestre ha sido ampliamente adoptada, la energía eólica marina ofrece recursos de viento superiores y menores conflictos relacionados con el uso del suelo. Las turbinas eólicas marinas flotantes (Floating Offshore Wind Turbines, FOWTs) amplían el alcance de la energía eólica marina hacia aguas profundas, donde las estructuras de cimentación fija resultan inviables [4]. Los avances recientes en la tecnología FOWT se han centrado en mejorar la estabilidad de la plataforma, la fiabilidad estructural y el rendimiento en la captación de energía bajo condiciones marinas variables.

Con el fin de mejorar aún más la eficiencia y la resiliencia de las plataformas, los sistemas híbridos de energía renovable han surgido como una línea de investigación prometedora, al combinar la energía eólica con otras fuentes como la energía de las olas, la solar o la mareomotriz. El desarrollo de los sistemas FOWT ha puesto de manifiesto importantes desafíos estructurales derivados de la acción combinada del viento y las olas. Estas cargas ambientales dinámicas incrementan los niveles de tensión y aumentan la probabilidad de fatiga

estructural o fallo, comprometiendo en última instancia la eficiencia del sistema y su vida útil operativa. Para mitigar estos efectos, se han propuesto dos estrategias principales: el control aerodinámico y el control estructural. El enfoque aerodinámico tiene como objetivo reducir el cabeceo de la plataforma aprovechando el empuje del rotor como par restaurador, principalmente mediante el ajuste del ángulo de paso de las palas. Jonkman et al. [5,6] introdujeron la herramienta de simulación FAST e implementaron controladores proporcional-integrales (PI) con ganancia programada para el control del paso de las palas en diversas configuraciones de FOWT. Por su parte, Lackner et al. [7] propusieron modificar la velocidad nominal del rotor para influir en la dinámica del empuje, mientras que Staino et al. [8] combinaron mecanismos de paso pasivo con tendones activos integrados en las palas para mejorar la amortiguación aerodinámica. Asimismo, Yang et al. [9] contribuyeron con el diseño de una plataforma híbrida que integra características de las configuraciones tipo spar y semisumergible, con el objetivo de mejorar la estabilidad global. La segunda estrategia se basa en el control estructural. Lackner et al. [7,10] desarrollaron FAST-SC, incorporando un amortiguador de masa sintonizada (Tuned Mass Damper, TMD) pasivo en la góndola y optimizando su desempeño para plataformas tipo barcaza. Luo et al. [11] emplearon un amortiguador de columna líquida sintonizada (Tuned Liquid Column Damper, TLCD) para reducir los desplazamientos en surge, mientras que Hu et al. [12] introdujeron un sistema de control estructural activo mediante un amortiguador de masa híbrido con limitación de carrera, gobernado por un regulador lineal-cuadrático.

En este trabajo, la integración de Columnas de Agua Oscilantes (Oscillating Water Columns, OWCs) en plataformas FOWT se presenta como una oportunidad para la captación simultánea de energía eólica y undimotriz, al tiempo que se contribuye a la estabilización de la plataforma. No obstante, las complejas interacciones hidrodinámicas presentes en este tipo de plataformas híbridas requieren el uso de herramientas de simulación avanzadas para una evaluación precisa de su comportamiento. En este contexto, se presenta un estudio comparativo de diferentes enfoques de modelado hidrodinámico, considerando los códigos WAMIT, ShipMo y ANSYS AQWA.

II. CONCEPTO HÍBRIDO FOWT VIENTO-OLAS

La turbina eólica marina flotante (FOWT) analizada en este trabajo se basa en el modelo de referencia NREL de 5 MW [8]. La turbina es de tres palas, configuración a barlovento, con velocidad variable y control activo del ángulo de paso. Está soportada por una plataforma tipo barcaza lastrada y estabilizada mediante líneas de amarre en catenaria. La barcaza considerada es la ITI Energy barge, se muestra en la Figura 1, una plataforma cuadrada y lastrada ampliamente utilizada en la literatura para investigación en energía eólica marina, especialmente en estudios de análisis de cargas y validación de conceptos en etapas tempranas de diseño.

Las ecuaciones completas de movimiento no lineales en el dominio del tiempo del sistema acoplado turbina eólica flotante-plataforma de soporte-OWCs pueden expresarse de forma general como:

$$M_{ij}(q, u, t) \ddot{q}_j = f_i(q, \dot{q}, u, t) \quad (1)$$

donde M_{ij} es la matriz de masas e inercias, u representa las entradas de control, t es el tiempo, $\ddot{q}_j$ es la segunda derivada temporal del grado de libertad j , y f_i corresponde a la componente de la fuerza externa generalizada asociada al grado de libertad i , que incluye cargas aerodinámicas, fuerzas hidrodinámicas, fuerzas elásticas y fuerzas del sistema de control.

La ecuación lineal del movimiento del sistema en el dominio de la frecuencia se expresa como [9]:

$$I_{FOWT}(\omega) \ddot{q} + B_{FOWT}(\omega) \dot{q} + C_{FOWT}(\omega) q = \vec{f}_{FOWT}(\omega) \quad (2)$$

donde I_{FOWT} , B_{FOWT} y C_{FOWT} son las matrices de inercia, amortiguamiento y rigidez del sistema, respectivamente.

El vector de desplazamientos generalizados q , que agrupa los grados de libertad (DOF), se define como:

$$q = [\text{Surge} \quad \text{Sway} \quad \text{Heave} \quad \text{Roll} \quad \text{Pitch} \quad \text{Yaw}]^T \quad (3)$$

La matriz de inercia se define como:

$$I_{FOWT}(\omega) = A_{Hydro}(\omega) + M_{Platform} + M_{Tower} \quad (4)$$

donde $M_{Platform}$ y M_{Tower} son las matrices de masa de la plata-




Figura 1. Vista 3D del 4OWC-FOWT (a), Vista transversal del 4OWC-FOWT (b).

forma y la torre, respectivamente, y $A_{Hydro}(\omega)$ es la masa añadida del sistema, dependiente de la frecuencia y calculada mediante el programa de radiación hidrodinámica basado en paneles.

La matriz de amortiguamiento se define como:

$$B_{FOWT}(\omega) = B_{Hydro} + B_{Viscous} + B_{Tower} \quad (5)$$

donde $B_{Hydro}(\omega)$ representa el amortiguamiento hidrodinámico, $B_{Viscous}$ el arrastre viscoso no lineal y B_{Tower} el amortiguamiento estructural de la torre.

La matriz de rigidez C_{FOWT} se expresa como:

$$C_{FOWT}(\omega) = C_{Hydro} + C_{Mooring} + C_{Tower} \quad (6)$$

donde C_{Hydro} corresponde a la rigidez hidrostática de la plataforma, $C_{Mooring}$ a la rigidez de las líneas de amarre y C_{Tower} a la rigidez estructural de la torre.

El término del lado derecho de la ecuación (2), f_{FOWT} , se define como:

$$\vec{f}_{FOWT}(\omega) = \vec{f}_{Hydro}(\omega) + \vec{f}_{Viscous}(\omega) + \vec{f}_{PTO}(\omega) \quad (7)$$

donde $f_{viscous}(\omega)$ es la fuerza hidrodinámica inducida por el oleaje, $f_{Hydro}(\omega)$ representa la contribución viscosa y $f_{PTO}(\omega)$ son las fuerzas de reacción generadas por los OWCs integrados.

Suponiendo que la superficie libre interna del agua dentro de la cámara se comporta como un pistón y que la presión es uniforme en el interior [10], la fuerza del sistema de toma de potencia (PTO) puede definirse como:

$$\vec{f}_{PTO}(\omega) = -p(\omega)S \quad (8)$$

donde p es la caída de presión a través de la turbina y S es el área de la superficie libre interna del agua dentro de la cámara.

III. MATERIALES Y MÉTODOS

La generación de la geometría y el mallado para el análisis hidrodinámico se llevó a cabo utilizando MultiSurf, Rhino y ANSYS AQWA Mechanical, cada uno en correspondencia con su respectivo entorno de simulación, como se muestra en la Figura 2.




Figura 2. Diseño geométrico de la barcaza ITI Energy con cuatro OWC utilizando diferentes herramientas numéricas.

IV. RESULTADOS Y DISCUSIÓN

Los resultados obtenidos a partir de los tres entornos de modelado se presentan en la Figura 3, donde se comparan la masa añadida y los coeficientes de amortiguamiento asociados al modo de cabeceo (pitch) de la plataforma empleando tres enfoques numéricos distintos: MultiSurf + WAMIT en (a), Rhino + ShipMo en (b) y ANSYS AQWA en (c).


El análisis se centró en parámetros hidrodinámicos clave, incluyendo la masa añadida, los coeficientes de amortiguamiento y los Operadores de Amplitud de Respuesta (RAOs).

En el caso de MultiSurf, únicamente se modela y malla la superficie mojada de la estructura en su posición no desplazada, de acuerdo con la teoría lineal del oleaje [11], tal como se ilustra en la Figura 2.a. Por el contrario, al emplear ShipMo3D, se modelan tanto la superficie mojada (en color amarillo) como la superficie no mojada o emergida (en color verde) de la estructura en su posición no desplazada [12], como se muestra en la Figura 2.b. ShipMo3D incorpora el uso de panel lids en la interfaz entre el agua y el aire con el objetivo de eliminar las frecuencias irregulares en los cálculos de radiación y difracción del casco, cerrando de manera efectiva la superficie libre del agua.

De forma similar, ANSYS AQWA dispone de una funcionalidad conocida como external lids, la cual atenúa o suprime las ondas estacionarias que pueden formarse en las regiones confinadas entre estructuras hidrodinámicamente acopladas, como es el caso de los moonpools [13], tal como se presenta en la Figura 2.c.

El comportamiento hidrodinámico de la barcaza fue analizado principalmente mediante WAMIT, el cual emplea el Método de Ecuaciones Integrales de Contorno tridimensional (BIEM), comúnmente denominado método de paneles, para resolver los problemas de radiación y difracción hidrodinámica linealizados en el dominio de la frecuencia [14]. Análisis complementarios se realizaron utilizando ShipMo [15] y ANSYS AQWA [13], los cuales también se basan en teoría de flujo potencial en el dominio de la frecuencia, aunque presentan diferencias en los requisitos de mallado y en la implementación de sus solucionadores numéricos.

Este enfoque comparativo permite evaluar la consistencia, precisión y robustez numérica de los tres entornos de modelado, proporcionando una comprensión más completa del comportamiento hidrodinámico de la plataforma.






Figura 3. Coeficientes de masa añadida y amortiguamiento asociados al movimiento de cabeceo de la barcaza propuesta con cuatro OWCs, obtenidos mediante diferentes enfoques de modelado numérico.

Aunque WAMIT es ampliamente reconocido por su precisión y robustez en el modelado hidrodinámico, su uso requiere un mallado detallado de alta calidad y conlleva un mayor coste computacional.

Por su parte, ShipMo proporciona una interfaz más simplificada para el análisis en el dominio de la frecuencia, si bien presenta ciertas limitaciones en la flexibilidad del manejo geométrico.

ANSYS AQWA ofrece un entorno versátil que permite simulaciones tanto en el dominio de la frecuencia como en el dominio del tiempo; no obstante, su requisito de mallado tanto por encima como por debajo de la superficie libre

puede introducir una complejidad adicional en el preprocesado.

La utilización combinada de estas herramientas permite la verificación cruzada de los resultados, al tiempo que se aprovechan las ventajas específicas de cada entorno de simulación, contribuyendo a una evaluación más completa y fiable del comportamiento hidrodinámico de la plataforma.

Para evaluar la respuesta en movimiento de las plataformas, se analizan los Operadores de Amplitud de Respuesta (RAOs) calculados mediante WAMIT. La Figura 4 muestra los resultados de los RAOs obtenidos para ambas plataformas en una comparación directa.




Figura 4. RAO traslacionales y rotacionales para la barcaza de energía ITI estándar frente al 4OWC-barcaza propuesta.

Los RAOs correspondientes a los modos dinámicos del sistema proporcionan información valiosa sobre el desempeño de la plataforma bajo diferentes condiciones de estado de mar, lo que permite una evaluación comparativa de su estabilidad y comportamiento. En este estudio se considera una simulación en WAMIT utilizando olas regulares con un ángulo de incidencia de 0° y en ausencia de viento

La Figura 4 ilustra los RAOs de los modos traslacionales y rotacionales obtenidos a partir de la simulación en WAMIT para ambas plataformas: la plataforma barcaza ITI Energy estándar, representada con curvas de línea continua azul, y la

barcaza propuesta con cuatro OWCs integrados, representada con curvas de línea discontinua roja.

Al analizar los RAOs de los movimientos de surge, heave y pitch de ambas plataformas, se observa una buena concordancia, lo que indica comportamientos dinámicos similares. No obstante, en los tres modos se aprecia un pequeño pico en el período de ola $T = 5.026$ s, el cual corresponde a la frecuencia de resonancia por *sloshing* dentro de los *moonpools*, $\omega_1 = 1.25$ rad/s. Asimismo, al examinar con mayor detalle el RAO de pitch, se observa una reducción de su amplitud máxima de 8.65 deg/m a 7.88 deg/m.

V. CONCLUSIÓN

Este trabajo presenta el diseño y el análisis de la integración de Columnas de Agua Oscilante (OWCs) en plataformas de Aerogeneradores Offshore Flotantes (FOWT), permitiendo el aprovechamiento conjunto de la energía eólica y undimotriz, al tiempo que se mejora la estabilidad hidrodinámica de la plataforma.

Debido a las complejas interacciones entre las cargas inducidas por el viento, la excitación de las olas y la dinámica de la plataforma flotante, una evaluación fiable del rendimiento requiere el uso de herramientas numéricas avanzadas. En este contexto, el estudio presenta una evaluación comparativa de diferentes enfoques de modelado hidrodinámico, concretamente WAMIT, ShipMo y ANSYS AQWA, aplicados a un sistema FOWT integrado con OWCs. Los resultados obtenidos a partir de los tres entornos de modelado muestran los coeficientes de masa añadida y amortiguamiento asociados al movimiento de cabeceo de la plataforma, calculados mediante tres enfoques de modelado distintos.

El primer método combina el diseño de malla en MultiSurf con un modelo en WAMIT; el segundo enfoque utiliza el diseño geométrico en Rhino junto con un modelo en ShipMo; y el tercer método emplea un modelo desarrollado en ANSYS AQWA. Si bien WAMIT es ampliamente reconocido por su precisión y robustez en el modelado hidrodinámico, requiere una discretización detallada y presenta un elevado coste computacional. ShipMo ofrece una interfaz más simplificada para el análisis en el dominio de la frecuencia, aunque con menor flexibilidad en el manejo de geometrías complejas. Por su parte, ANSYS AQWA proporciona un entorno versátil que permite simulaciones tanto en el dominio de la frecuencia como en el dominio del tiempo; sin embargo, su necesidad de mallar superficies tanto sumergidas como emergidas puede introducir una complejidad adicional.

El uso combinado de estas herramientas permite la validación cruzada de los resultados, aprovechando al mismo tiempo las ventajas específicas de cada enfoque numérico.

AGRADECIMIENTO

Los autores desean agradecer al Gobierno Vasco la financiación de esta investigación a través del proyecto IT1555-22, así como al Ministerio de Ciencia e Innovación mediante los proyectos PID2021-123543OBC21 y PID2021-123543OB-C22, financiados por MICIU/AEI/10.13039/501100011033/FEDER, UE.

El autor de correspondencia desea agradecer al programa de investigación e innovación Horizonte 2020 de la Unión Europea por la financiación de su proyecto en el marco del acuerdo de subvención Marie Skłodowska-Curie número 101110315.

REFERENCIAS

- [1] Global Wind Energy Council (2023), Global Offshore Wind Report 2023, GWEC, Brussels, <https://gwec.net/gwecs-global-offshore-wind-report-2023/>
- [2] Jonkman J M 2007. Dynamics Modeling and Loads Analysis of an Offshore Floating Wind Turbine; (No. NREL/TP-500-41958); NREL: Golden, CO, USA url: <https://docs.nrel.gov/docs/fy08osti/41958.pdf>
- [3] Lackner M A 2009 Controlling platform motions and reducing blade loads for floating wind turbines. *Wind Engineering* 33(6), 541-553 DOI: 10.1260/0309-524X.33.6.541
- [4] Staino A, Basu B 2015 Emerging trends in vibration control of wind turbines: a focus on a dual control strategy. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 373(2035), 20140069 DOI: 10.1098/rsta.2014.0069
- [5] Yang J, He Y P, Zhao Y S, Yang X Y, Zhang G R 2022. Coupled dynamic response analysis of multi-column floating offshore wind turbine with low center of gravity. *Journal of Ocean Engineering and Science* 9(1) 25-39 DOI: 10.1016/j.joes.2022.07.004
- [6] Luo N, Pacheco L, Vidal Seguí Y, Li H 2012. Smart Structural Control Strategies for Offshore Wind Power generation with floating wind turbines. *Renewable Energies & Power Quality Journal (RE&PQJ)* 1(10) 1200-1205 DOI: 10.24084/repqj10.637
- [7] Hu Y, He E 2017. Active structural control of a floating wind turbine with a stroke-limited hybrid mass damper. *Journal of Sound and Vibration* 410, 447-472 DOI: 10.1016/j.jsv.2017.08.050
- [8] Jonkman J M, Butterfield S, Musial W, Scott G 2009. Definition of a 5-MW Reference wind turbine for Offshore system Development, *Technical report, NREL* url: <https://docs.nrel.gov/docs/fy09osti/38060.pdf>
- [9] Aboutalebi P, M'zoughi F, Garrido I, Garrido A J 2021. Performance Analysis on the Use of Oscillating Water Column in Barge-Based Floating Offshore Wind Turbines. *Mathematics* 9(5), 475 DOI: 10.3390/math9050475
- [10] M'zoughi F, Aboutalebi P, Garrido I, Garrido A J, De La Sen M 2021. Complementary airflow control of oscillating water columns for floating offshore wind turbine stabilization. *Mathematics* 9(12), 1364 DOI: 10.3390/math9121364
- [11] MultiSurf User's Guide, AeroHydro, Inc., ME, 2013. url: <http://multisurf.com/tutorials.htm>
- [12] Uzunoglu E, and Soares C G, 2018. Parametric modelling of marine structures for hydrodynamic calculations. *Ocean Engineering* 160, 181-196. DOI: 10.1016/j.oceaneng.2018.04.049
- [13] AQWA Reference Manual, ANSYS, Inc., Canonsburg, PA, 2025. url: <http://www.ansys.com>
- [14] WAMIT user manual, WAMIT, Inc. Cambridge, MA, 2019. url: <https://www.wamit.com/manual.htm>
- [15] McTaggart K, 2012. *ShipMo3D Version 3.0 user manual for creating ship models* (No. DRDCAtlanticTM2011307). <https://proteusds.com/documentation/> url:

Optimización multi-coste de inventarios de repuestos en turbinas eólicas utilizando Particle Swarm

Multi-cost Inventory Optimization for Wind Turbine Spare Parts Using Particle Swarm

Verónica González González
Facultad de Ciencias Económicas y Empresariales
Universidad de Burgos
Burgos, España
veronica.gonzalez@ubu.es

Jesús Enrique Sierra García
Departamento de Digitalización
Universidad de Burgos
Burgos, España
jesierra@ubu.es

Abstract— Spare parts availability is critical for wind turbine operation, especially for components whose unavailability causes significant production losses. This study presents an optimization model for inventory decisions, based on a multi-cost objective function with eight nonlinear terms related to ordering, shortages, obsolescence, logistics, and lead time. Particle Swarm Optimization (PSO) solves the problem, enabling exploration of a high-dimensional decision space. Four scenarios based on component failure frequency and criticality allow analysis of the model's sensitivity to operational risk profiles. Results show that adjusting cost component weights balances availability and inventory cost, reproducing behaviors consistent with wind turbine spare parts management. The approach offers a tool to support spare parts prioritization under uncertainty, contributing to reliability-oriented optimization in energy systems.

Keywords— Inventory Optimization, Wind Turbines, Critical Spare Parts, Multi-cost Model, Particle Swarm Optimization (PSO), Reliability and Availability.

Resumen— La disponibilidad de repuestos es determinante en la operación de turbinas eólicas, especialmente en componentes críticos cuya indisponibilidad genera pérdidas significativas de producción. Este estudio presenta un modelo de optimización para decisiones de inventario, basado en una función objetivo multi-coste que integra ocho términos no lineales relacionados con pedido, rotura, obsolescencia, logística y plazo de suministro. Se emplea Particle Swarm Optimization (PSO) para explorar eficientemente un espacio de decisión de elevada dimensionalidad. Se construyen cuatro escenarios basados en la frecuencia de fallo y criticidad del componente, analizando la sensibilidad del modelo ante diferentes perfiles de riesgo. Los resultados muestran que la ponderación de costes permite equilibrar la tensión entre disponibilidad y coste de inventario, reproduciendo comportamientos coherentes con la gestión real. El enfoque propuesto ofrece una herramienta compacta para priorizar repuestos bajo incertidumbre, contribuyendo al debate sobre optimización en sistemas energéticos.

Palabras claves— Optimización de Inventarios, Turbinas Eólicas, Repuestos Críticos, Modelo Multicoste, Particle Swarm Optimization (PSO), Fiabilidad y Disponibilidad.

I. INTRODUCCIÓN

La operación y mantenimiento (O&M) de los parques eólicos se ha convertido en un vector crítico para garantizar la competitividad del sector energético en un contexto caracterizado por alta variabilidad operativa, presiones en costes y dependencia creciente de la fiabilidad de los activos. La literatura coincide en que una parte sustancial del coste total de O&M se concentra en el fallo de componentes de elevada complejidad técnica, como convertidores de potencia, cajas de engranajes, generadores o sistemas electrónicos auxiliares, cuya sustitución exige recursos logísticos significativos, largos tiempos de parada y, en muchos casos, la intervención de grúas de gran tonelaje. Estudios como [8,11,7,5] destacan que estos subsistemas concentran buena parte de la tasa de fallo y determinan la curva de disponibilidad anual de una turbina.

A ello se añade un contexto industrial tensionado: informes recientes de organismos internacionales como la IEA [6] y el Joint Research Centre de la Comisión Europea [2] subrayan la creciente vulnerabilidad de las cadenas de suministro de componentes electrónicos, materiales magnéticos y tierras raras, todos ellos elementos recurrentes en la arquitectura interna de una turbina eólica, lo que incrementa la criticidad de mantener un inventario de repuestos suficientemente robusto y adaptado al perfil real de fallos.

Tradicionalmente, la planificación de inventario en O&M se ha apoyado en modelos clásicos, tales como el modelo de cantidad económica de pedido (EOQ), la política de revisión continua (s, S) o aproximaciones basadas en demanda estacionaria, cuyo objetivo principal es la minimización de costes lineales de pedido y posesión [10,13]. No obstante, este enfoque resulta insuficiente cuando el sistema presenta fallos dependientes del estado, penalizaciones no lineales, restricciones de disponibilidad, riesgo de obsolescencia tecnológica y una elevada variabilidad asociada a la criticidad

del componente. Estudios más recientes han puesto de manifiesto la necesidad de integrar explícitamente inventario, mantenimiento y riesgo operativo mediante formulaciones más ricas y flexibles, capaces de capturar compromisos entre coste, nivel de servicio y fiabilidad del sistema [1,12,9].

En este contexto, trabajos preliminares han demostrado que la incorporación de funciones de coste no lineales y penalizaciones dependientes del estado operativo permite representar de forma más realista la dinámica de los sistemas de mantenimiento industrial. En particular, González y Sierra [4] introduce una formulación multicoste optimizada mediante algoritmos evolutivos, mostrando que este tipo de planteamientos mejora simultáneamente la gestión del inventario frente a políticas clásicas. El presente trabajo amplía dicha línea de investigación, adaptando y calibrando el modelo para su aplicación específica a la gestión de repuestos en turbinas eólicas, junto con un análisis sistemático basado en escenarios operativos y el nivel de servicio.

El presente estudio avanza en esta línea y propone una formulación específica para sistemas de repuestos orientados al mantenimiento predictivo de turbinas eólicas. El modelo incorpora:

- (i) una taxonomía basada en criticidad y frecuencia de fallo,
- (ii) un conjunto de escenarios operativos que representan distintos perfiles de riesgo,
- (iii) una función objetivo con penalizaciones no lineales y dependientes del estado,
- (iv) un procedimiento de optimización mediante Particle Swarm Optimization (PSO) para obtener políticas de inventario más eficientes que una política de referencia no optimizada.

El resto del artículo se estructura de la siguiente manera. En la Sección 2 se describe la metodología propuesta, incluyendo la formulación del modelo de inventario multicoste, la definición de la política de referencia y el enfoque de optimización basado en Particle Swarm Optimization. La Sección 3 presenta el estudio de casos y el análisis de resultados, donde se evalúa el comportamiento del modelo bajo distintos escenarios operativos, comparando de forma sistemática la política optimizada con la política de referencia en términos de coste real, nivel de servicio e inventario. Finalmente, la Sección 4 recoge las principales conclusiones del trabajo y plantea posibles líneas de investigación futura orientadas a la mejora de la planificación de repuestos en sistemas eólicos.

II. METODOLOGÍA

La Fig. 1 muestra la metodología desarrollada en este trabajo que integra tres componentes principales: (i) la construcción de un conjunto de datos técnico representativo de repuestos en turbinas eólicas, (ii) la definición de escenarios operativos basados en la clasificación conjunta de criticidad y frecuencia de fallo, y (iii) la formulación y optimización de una función objetivo multicoste mediante Particle Swarm Optimization (PSO), comparada frente a una política de referencia (B1) no optimizada.




Fig. 1. Mapa conceptual del flujo metodológico del estudio

A. Conjunto de datos técnico y caracterización de componentes

Se construyó un conjunto de datos de 30 componentes representativos de los subsistemas clave de una turbina eólica (convertidor, generador, sistema de orientación, sistema de paso de pala, sensores, electrónica auxiliar, etc.). Para cada componente se parametrizaron su coste unitario, penalización por rotura de stock, coeficientes de envejecimiento y obsolescencia, parámetros logísticos, plazo de suministro, inventario inicial y demanda mensual para un parque de 100 aerogeneradores.

La demanda de repuestos se generó a partir de tasas anuales de fallo λ_i obtenidas de literatura especializada en fiabilidad eólica [8,11,3]. En particular, cada tasa de fallo anual λ_i se transformó en una demanda mensual esperada bajo el supuesto de fallos independientes que posteriormente fue ajustada mediante factores de escenario para representar distintos niveles de severidad operativa.

Además de su papel en la estimación de la demanda, la tasa de fallo λ_i se emplea como indicador de frecuencia de fallo del componente, permitiendo caracterizar su comportamiento desde el punto de vista de la fiabilidad. De este modo, λ_i actúa como nexo entre la generación de demanda y la clasificación de los componentes según su frecuencia de fallo, manteniendo una nomenclatura coherente con la literatura de fiabilidad y mantenimiento.

Conviene destacar que λ_i no forma parte de la función objetivo de costes, sino que se utiliza exclusivamente para la caracterización de componentes y la definición de escenarios.

B. Clasificación por criticidad y frecuencia

Con el fin de estructurar el análisis y facilitar la construcción de escenarios operativos, cada componente fue clasificado atendiendo a dos dimensiones complementarias:

a) Frecuencia de fallo.

Derivada directamente de la tasa anual de fallo λ_i , normalizada en una escala adimensional [0,10]. Esta

normalización permite comparar componentes con órdenes de magnitud distintos en sus tasas de fallo, manteniendo la proporcionalidad relativa entre ellos.

b) Criticidad operativa.

Definida mediante un índice compuesto que integra el impacto del fallo del componente en la disponibilidad del aerogenerador, la necesidad de grúa pesada, la complejidad mecánica de la intervención, la dependencia de sistemas electrónicos y el riesgo de parada prolongada.

Ambas dimensiones se combinaron mediante un índice conjunto de riesgo operativo definido como:

$$J_i = \text{Criticidad}_i \times \text{Frecuencia}_i \quad (1)$$

Este índice permite capturar simultáneamente la probabilidad de fallo y su impacto operativo, proporcionando una medida sintética del riesgo asociado a cada componente. A partir de J_i , los componentes se segmentaron en tres grupos:

- G1: alta criticidad y alta frecuencia de fallo
- G2: criticidad y frecuencia medias
- G3: baja criticidad y frecuencia de fallo

Esta clasificación facilita tanto la definición de escenarios operativos diferenciados como la interpretación de los resultados en términos de fiabilidad, riesgo y política de inventario, permitiendo analizar cómo la optimización redistribuye el stock en función del perfil de riesgo de los componentes.

C. Definición de escenarios operativos (S1–S4)

A partir del índice J_i se definieron cuatro escenarios operativos:

- S1 – Base: demanda igual a la demanda media base.
- S2 – Benigno: mayor peso relativo de componentes poco críticos y poco frecuentes, es decir, del grupo G3.
- S3 – Intermedio: predominio de componentes del grupo G2.
- S4 – Severo: incremento intensificado de la demanda en los componentes del grupo G1.

La demanda base $d_{i,t}^{base}$ se obtiene previamente a partir de la tasa anual de fallo λ_i , que se interpreta como la frecuencia esperada de fallo del componente i y se transforma en una demanda mensual equivalente. Los escenarios operativos no modifican λ_i ni la clasificación de los componentes, sino que representan distintos contextos de operación mediante factores de amplificación o atenuación de la demanda.

La Ecuación (2) muestra cómo se define la demanda en cada escenario.

$$d_{i,t}^s = k_s(i) \cdot d_{i,t}^{base} \quad (2)$$

Los índices y variables se definen como sigue: $i \in \{1, \dots, n\}$ denota el índice del componente, donde n es el número total de

componentes considerados en el sistema; $t \in \{1, \dots, T\}$ representa el periodo temporal dentro del horizonte de planificación, expresado en meses; y $s \in \{S1, S2, S3, S4\}$ identifica el escenario operativo considerado.

El parámetro $k_s(i)$ es un coeficiente adimensional dependiente del escenario s y del grupo de riesgo al que pertenece el componente i y permite representar distintos contextos operativos sin modificar la clasificación intrínseca de los componentes ni sus propiedades físicas.

D. Política de referencia (B1)

Se definió una política no optimizada que actúa como referencia en las comparaciones. Para cada componente:

- $Q_{i,t} = x_{min,i}$ donde $x_{min,i}$ representa el pedido mínimo técnico del componente i
- $S_{i,t}$ = inventario inicial

La política B1 sirve como referencia y mantiene valores constantes de inventario y pedidos sin utilizar información del sistema ni criterios de optimización.

E. Función objetivo multicoste

La planificación del inventario se formula como un problema de optimización multicoste con ocho términos no lineales. La Ecuación (3) muestra la función objetivo

$$\min_{s,q} \sum_{i,t} (w_1 C1_{i,t} + w_2 C2_{i,t} + w_3 C3_{i,t} + w_4 C4_{i,t} + w_5 C5_{i,t} + w_6 C6_{i,t} + w_7 C7_{i,t} + w_8 C8_{i,t}) \quad (3)$$

donde C_1 – C_8 representan, respectivamente, el coste lineal de pedido y almacenamiento, la penalización cuadrática por roturas de stock, el coste logístico logarítmico, el coste cúbico asociado a obsolescencia, la penalización relativa por desabastecimiento, la saturación logística exponencial, la desviación respecto al tamaño óptimo de pedido y la penalización asociada a los plazos de suministro.

Esta función es una extensión del modelo preliminar presentado en [4] según Ecuación (4).

$$\min_{s,q} \sum_{t=1}^T \sum_{i=1}^n \left[\begin{aligned} & Q_{i,t}(S_{i,t} + M_{i,t} + O_{i,t}) + p_{i,t} \cdot u_{i,t}^2 + \\ & \lambda_{i,t} \cdot \log(1 + Q_{i,t}) + \theta \cdot \frac{S_{i,t}^3}{1 + a_{i,t}} + \eta_i \left(\frac{u_{i,t}}{d_{i,t}} \right)^2 + \\ & \gamma \cdot e^{Q_{i,t}/K} + \varphi \cdot \frac{1}{1 + e^{-k(Q_{i,t} - Q_{i,opt})}} + \psi \cdot LT_{i,t} \end{aligned} \right] \quad (4)$$

En el presente trabajo, la función se amplía y recalibra para adaptarse específicamente a la lógica de repuestos para turbinas eólicas.

F. Optimización mediante Particle Swarm Optimization (PSO)

Para cada escenario S1–S4 se ejecutaron 20 ejecuciones independientes de PSO. Cada ejecución minimiza la función

penalizada, que incluye: restricciones de no negatividad, pedido mínimo $x_{min,i}$, capacidad logística máxima por periodo y actualización coherente del inventario entre periodos. El resultado del proceso es una política optimizada PSO_best(s) para cada escenario.

G. Configuración experimental y evaluación del algoritmo

Para evaluar la estructura de la función objetivo y verificar la estabilidad de los componentes individuales, se analizó la distribución empírica de los costes C1–C8. La Fig. 2 muestra las distribuciones gaussianas ajustadas para el escenario severo (S4), agregando los resultados de las 20 ejecuciones de PSO.




Fig. 2: Distribuciones gaussianas de C1–C8 en S4. Se muestra la distribución aproximada (kernel density) de los ocho componentes de coste C1–C8 en el escenario S4 optimizado mediante PSO. Se observa baja variabilidad entre ejecuciones, lo que refuerza la robustez del algoritmo.

Esta figura permite identificar qué costes dominan en escenarios críticos: típicamente C2 (roturas de stock) y C4/C6 (costes no lineales por inventario y logística).

H. Métricas de evaluación

La comparación entre la política B1 y la política optimizada PSO se realiza mediante: coste real total, coste real de inventario, roturas de stock totales y por componente, nivel de servicio, inventario acumulado, distribuciones de los costes $C_1 \dots C_8$, y estabilidad del PSO (variabilidad inter-ejecución).

Estas métricas cuantifican los beneficios de la optimización y permiten identificar patrones de comportamiento vinculados a la criticidad y frecuencia de los componentes.

III. RESULTADOS

Esta sección presenta los resultados obtenidos en los cuatro escenarios analizados (S1–S4) comparando la política de referencia (B1) con la política optimizada mediante PSO. Se analizan el coste real del inventario, los niveles de servicio, la reducción de roturas de stock, la robustez del optimizador y la distribución de los diferentes componentes del coste.

A. Comparación global B1 vs PSO: coste real y nivel de servicio

La Fig. 3 presenta la comparación global entre la política de referencia (B1) y la política optimizada mediante PSO, evaluadas en los cuatro escenarios operativos. En términos de coste real C_{real} , PSO reduce de forma consistente el coste agregado en todos los escenarios, con mejoras relativas del orden del 16–23%, evidenciando que la optimización encuentra combinaciones Q – S más eficientes que la regla de referencia. En paralelo, la reducción de roturas de stock es sustancial en los cuatro escenarios, lo que se traduce en un incremento sistemático del nivel de servicio. Este resultado es especialmente relevante porque muestra que la mejora económica no se obtiene a costa del desempeño operativo, sino que PSO desplaza simultáneamente la solución hacia menores roturas de stock y mejores niveles de disponibilidad del repuesto, manteniendo la comparabilidad entre escenarios al preservar el mismo horizonte temporal y la misma base de demanda por escenario.




Fig. 3: Comparación global B1 vs PSO por escenario. (Arriba) Coste real agregado C_{real} en cada escenario y porcentaje de ahorro relativo de PSO respecto a B1. (Abajo) Roturas de stock totales y nivel de servicio (SL) para B1 y PSO, incluyendo el porcentaje de reducción de roturas de stock logrado por PSO.

B. Ahorro relativo y reducción de roturas de stock por escenario

Para analizar el impacto del PSO con mayor detalle, la Fig. 4 representa la mejora porcentual en dos dimensiones: (i) reducción de coste real total y (ii) reducción del número de roturas de stock por escenario.




Fig. 4: Ahorro de coste real y reducción de roturas de stock

La Fig. 4 muestra el ahorro relativo (%) en coste real e incremento porcentual del nivel de servicio obtenido mediante PSO frente a B1, desglosado por escenario. En todos los casos PSO produce mejoras superiores al 20% en inventario y superiores al 50% en reducción de roturas de stock.

La representación con ejes separados permite visualizar claramente la doble mejora: menos coste y más servicio.

C. Robustez del algoritmo PSO

Para cada escenario se realizaron 20 ejecuciones independientes del algoritmo PSO. La Fig. 5 presenta la distribución de la función objetivo final normalizada respecto al valor medio de cada escenario. Los resultados muestran una dispersión muy reducida entre ejecuciones, con desviaciones relativas inferiores al 0.5%, lo que confirma la estabilidad y robustez del procedimiento de optimización.




Fig. 5: Distribución de los valores normalizados de la función objetivo final (20 ejecuciones por escenario). La reducida dispersión observada indica una alta estabilidad del algoritmo.

D. Análisis por criticidad y frecuencia: inventario y roturas de stock por componente

Para comprender la mejora a nivel de componente, se representaron los inventarios totales y las roturas de stock por componente en el escenario severo S4. La Fig. 6 muestra la reducción de roturas de stock por componente; se aprecia que los componentes del grupo G1 (alta criticidad y alta frecuencia) son los mayores beneficiados de la optimización.




Fig. 6: Roturas de stock por componente en B1 vs PSO (S4). Roturas de stock por componente comparando B1 y PSO en el escenario severo S4. La optimización reduce de manera casi universal las roturas de stock, especialmente en los componentes de mayor riesgo operativo.

La Fig. 7 representa la misma comparación, pero centrada en el inventario real acumulado.




Fig. 7: Inventario acumulado por componente en el escenario severo S4 para la política de referencia (B1) y la política optimizada (PSO). La política PSO ajusta el inventario de forma más eficiente según la criticidad y frecuencia de cada componente.

E. Resumen comparativo global

La Fig. 8 compara el nivel de servicio de la política de referencia B1 y la política optimizada mediante PSO en los cuatro escenarios analizados. Los resultados muestran de forma consistente que PSO supera a B1 en todos los casos, alcanzando niveles de servicio más altos incluso bajo condiciones de mayor severidad operativa (S3 y S4).

Mientras que B1 presenta mayor variabilidad y valores inferiores, especialmente en los escenarios benigno e intermedio, PSO mantiene una respuesta más estable y cercana al nivel objetivo, reduciendo significativamente las roturas de stock. En conjunto, la figura evidencia que la optimización mediante PSO mejora de forma robusta la disponibilidad global del sistema, reforzando la aplicabilidad del enfoque en la gestión real de repuestos para turbinas eólicas.




Fig. 8: Radar comparativo B1 vs PSO en coste real

Para complementar el análisis agregado de costes y nivel de servicio, se examina el comportamiento espacio-temporal del inventario en el escenario severo (S4), considerado el más exigente desde el punto de vista operativo. La Fig. 9 muestra los mapas de calor del inventario bajo la política de referencia B1, la política optimizada mediante PSO y la diferencia entre ambas,

permitiendo analizar la asignación de inventario por componente y periodo a lo largo del horizonte de planificación.

F. Análisis del inventario en el escenario severo (S4)

Bajo la política B1 se observa una acumulación progresiva de inventario en determinados componentes, especialmente hacia los últimos periodos, lo que refleja un enfoque estático y poco sensible a la estructura de criticidad y frecuencia. En contraste, la política PSO presenta una distribución más contenida y selectiva del inventario, reduciendo sobreinventarios y concentrando stock en componentes y periodos clave.




Fig. 9: Mapa de calor comparativo del inventario en el escenario severo (S4) bajo la política de referencia (B1) y la política optimizada mediante PSO.

El mapa de diferencias (Fig. 9) indica que la mejora no se basa en una reducción uniforme del inventario, sino en una redistribución estratégica que combina reducciones globales con incrementos puntuales necesarios para preservar el nivel de servicio, en coherencia con las mejoras observadas en coste real y disponibilidad.

IV. CONCLUSIONES

Los resultados obtenidos muestran que el modelo multi-coste propuesto captura de forma adecuada las dinámicas esenciales de la gestión de repuestos en turbinas eólicas, donde las decisiones de inventario están condicionadas por la interacción entre frecuencia de fallo, criticidad del componente, incertidumbre logística y costes no lineales asociados al nivel de stock. Frente a políticas de referencia estáticas, el enfoque desarrollado permite representar de manera más realista la naturaleza compleja y dependiente del contexto del problema de planificación de repuestos en sistemas eólicos.

La comparación de escenarios evidencia que la política optimizada mediante Particle Swarm Optimization (PSO) supera a la política de referencia en coste real total y nivel de servicio, sin que la mejora en un indicador implique degradación del otro. El modelo optimizado logra mejor equilibrio entre costes y disponibilidad de repuestos, incluso bajo condiciones severas de demanda y alta criticidad. El análisis por escenarios confirma la robustez del enfoque, mostrando reducción de roturas de stock y ajuste selectivo de niveles de inventario por componente y periodo, especialmente en el escenario severo.

Desde una perspectiva metodológica, la incorporación de una función objetivo multi-coste con penalizaciones no lineales refleja criterios de ingeniería difíciles de capturar mediante formulaciones clásicas basadas en costes lineales. El uso de PSO resulta adecuado para problemas no convexos y de alta

dimensionalidad, proporcionando soluciones estables. Los resultados avalan la utilidad del modelo como herramienta de apoyo para la planificación de repuestos en parques eólicos, con aplicación industrial. Como líneas futuras, se plantea la extensión a horizontes temporales más largos, la integración de mantenimiento predictivo y la comparación con otros enfoques metaheurísticos.

AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por el Ministerio de Ciencia e Innovación de España, con los proyectos MCI/AEI/FEDER PID2021-123543OB-C21 y PID2024-155653OB-C21.

REFERENCIAS

- [1] Basten, R. J. I., & van Houtum, G. J. (2014). System-oriented inventory models for spare parts. *Surveys in Operations Research and Management Science*, 19(1), 34–55.
- [2] Carrara, S., Baldassarre, B., Jakimow, M., Kuzov, T., McGuinness, G. L., Nohl, L., ... Christou, M. (2025). Deep dive on critical raw materials for wind turbines in the EU (JRC Technical Report). European Commission, Joint Research Centre.
- [3] Carroll, J., McDonald, A., & McMillan, D. (2016). Failure rate, repair time and unscheduled O&M cost analysis of offshore wind turbines. *Wind Energy*, 19, 1107–1119.
- [4] González, V., & Sierra, E. (2025). Optimización de costes de inventario con penalizaciones mediante algoritmos genéticos. En XX Simposio CEA de Control Inteligente (pp. xx–xx). Huelva, España.
- [5] Gonzalo, A., Muñoz, P., & Otero, C. (2022). Optimal maintenance management of offshore wind turbines by minimizing the costs. *Applied Energy*.
- [6] International Energy Agency (IEA). (2025). Critical minerals supply chains for energy technologies. IEA.
- [7] Jin, H., Tian, Z., Wu, W., & Zhou, Y. (2025). Multi-echelon joint optimization of spare parts inventory and maintenance planning for wind turbines. *Wind Energy*, 28(3), 267–282.
- [8] Pérez, J. M., Márquez, F. P. G., & Tobias, A. (2013). Wind turbine reliability analysis. *Renewable Energy*, 60, 378–387.
- [9] Scarf, P. A., et al. (2024). Joint maintenance and spare-parts inventory models: a review. *IMA Journal of Management Mathematics*.
- [10] Silver, E. A., Pyke, D. F., & Peterson, R. (1998). *Inventory management and production planning and scheduling* (3rd ed.). New York, NY: John Wiley & Sons.
- [11] Tautz-Weinert, J., & Watson, S. J. (2017). Using SCADA data for wind turbine condition monitoring—A review. *Wind Energy*, 20(4), 593–614.
- [12] Zhang, Y., Si, X., & Hu, C. (2021). Optimal condition-based opportunistic maintenance and spare parts provisioning. *Reliability Engineering & System Safety*.
- [13] Zipkin, P. H. (2000). *Foundations of inventory management*. Boston, MA: McGraw-Hill.

ISBN 978-84-18465-35-8



**UNIVERSIDAD
DE BURGOS**

**Servicio de Publicaciones e
Imagen Institucional**