

WWME 2024 VI. Jardunaldia



VI WORKSHOP WWME 2024

Wind (and) Marine Energy



Haize eta Itsas Energiari Buruzko Irakaskuntza-Oharrak

Lecture Notes on Wind and Marine Energy

Apuntes Docentes sobre Avances en Energía
Eólica y Marina

12 de diciembre del 2024

enari ta zabal zazu



Universidad
del País Vasco

Euskal Herriko
Unibertsitatea

Haize eta Itsas Energiari Buruzko Irakaskuntza- Oharrak

Lecture Notes on Wind and Marine Energy

**Apuntes Docentes sobre Avances en Energía Eólica y
Marina**

*PID2021-123543OB-C21 eta C22 proiektuen
VI. Jardunaldiako Monografia*

Monografía de la VI Jornada Internacional con
los proyectos PID2021-123543OB-C21 y PID2021-123543OB-C22
(MICIU/AEI/10.13039/501100011033/FEDER, UE)

WWME 2024 VI. Jardunaldia / VI Jornada WWME 2024

Haize eta Itsas Energiari Buruzko Irakaskuntza- Oharrak

Lecture Notes on Wind and Marine Energy

**Apuntes Docentes sobre Avances en Energía Eólica y
Marina**

*PID2021-123543OB-C21 eta C22 proiektuen
VI. Jardunaldiako Monografia*

Monografía de la VI Jornada Internacional de
Energía Eólica (y) Marina
proyectos PID2021-123543OB-C21 y C22

Aitor J. Garrido, Matilde Santos, Izaskun Garrido (arg./eds.)



Universidad del País Vasco Euskal Herriko Unibertsitatea

VI Jornada Internacional de Energía Eólica (y) Marina, proyectos PID2021-123543OB-C21 y PID2021-123543OB-C22 (12 diciembre 2024)

Haize eta Itsas Energiari Buruzko Irakaskuntza-Oharrak [Recurso electrónico]: Haize eta Itsas Energiari Buruzko Irakaskuntza-Oharrak; Lecture Notes on Wind and Marine Energy; Apuntes Docentes sobre Avances en Energía Eólica y Marina / Aitor J. Garrido, Matilde Santos, Izaskun Garrido (arg./eds.). – Datos. – Bilbao: Universidad del País Vasco / Euskal Herriko Unibertsitatea, Argitalpen Zerbitzua = Servicio Editorial del grupo de Control Automático, [2024]. – 1 recurso en línea: PDF

En port.: WWWE 2024 VI. Jardunaldia / VI WORKSHOP WWWE 2024

Wind (and) Marine Energy

Textos en español, euskara e inglés. Abstracts en inglés

Modo de acceso: <http://www.ehu.es/acg>

ISBN: 978-84-09-70364-7.

1. Ingeniería de Sistemas y Automática – Estudio y enseñanza – Congresos.
2. Energías renovables marinas - Estudio y enseñanza – Congresos.
3. Control automático.

- I. Izaskun Garrido, Matilde Santos, Aitor J. Garrido coed.
- II. MICIU a través de los proyectos PID2021-123543OB-C21 y PID2021-123543OB-C22 financiado por MICIU/AEI/10.13039/501100011033/ y por FEDER Una manera de hacer Europa



- III. Título Haize eta Itsas Energiari Buruzko Irakaskuntza-Oharrak.

Batzorde zientifikoa / Comité científico

Koordinatzailea / Coordinador

Matilde Santos, Eduardo Muñoz-Palomeque (Universidad Complutense de Madrid, UCM)

Kideak / Miembros

Aitor J. Garrido (Universidad del País Vasco, UPV/EHU)

Alejandro Merino Gómez (Universidad de Burgos)

Carlos Armenta Deu (Universidad Complutense de Madrid)

César B. Guevara (Universidad Indoamérica, Ecuador)

Carolina A Evangelista (Universidad Nacional de La Plata - CONICET, Argentina)

Dictino Chaos García (Universidad Nacional de Educación a Distancia, UNED)

Edorta Carrascal-Lekunberri (Universidad del País Vasco, UPV/EHU)

Eduardo Muñoz-Palomeque (Universidad Complutense de Madrid)

Fares M'zoughi (Universidad del País Vasco, UPV/EHU)

Francisco Vázquez (Universidad de Córdoba)

Francisco Jesús Velasco González (Universidad de Cantabria)

Irfan Ahmad (Universidad del País Vasco, UPV/EHU)

Izaskun Garrido (Universidad del País Vasco, UPV/EHU)

Jesus Enrique Sierra García (Universidad de Burgos)

Lía García Pérez (Universidad Complutense de Madrid)

Lucas Bindelli (Universidad de Buenos Aires, Argentina)

Manuel Lara Ortiz (Universidad de Córdoba)

M. Tomas-Rodriguez (City, University of London)

M. José Gómez Silva (Universidad Complutense de Madrid)

Matilde Santos (Universidad Complutense de Madrid)

Payam Aboutalebi (Universidad Técnica de Noruega, NTNU)

Paul Puleston (Universidad Nacional de La Plata - CONICET, Argentina)

Pedro J Cabrera (Universidad de Las Palmas de Gran Canaria, ULPGC)

Ramon Vilanova Trees (Universidad Autónoma Barcelona, UAB)

Raul Marín-Prades (Universidad Jaime I)

Segundo Esteban San Román (Universidad Complutense de Madrid)

Tahereh Bagheri (Universidad del País Vasco, UPV/EHU)

Gonbidatutako hizlariak / Ponentes invitados

Dr. Segundo Esteban San Román **Universidad Complutense de Madrid - ISCAR**

Dr. María Tomás-Rodríguez **City University, London, UK**

Dr. Jesús Enrique Sierra García **Universidad de Burgos**

Prof. Dr. Matilde Santos Peñas **Universidad Complutense de Madrid - ISCAR**

Prof. Dr. Aitor Garrido Hernández **Universidad del País Vasco - ACG**

Parte hartzalileak / Conferenciantes invitados

D. Juan de Dios López **Asociación Empresarial Eólica (AEE)**

D. Sergio Fernández Munguía **Windletter**

D. Adrián Rodríguez Ortega **Selectra**

Dr. Néstor D. Galán Hernández **Universidad Politécnica de Sinaloa, México**

D. Alfonso García Márquez **Presidente de Unión Renovables**

Aurkibidea / Índice

<i>Introduction / Prólogo / Sarrera</i>	1
Aitor J. Garrido, Matilde Santos, Izaskun Garrido	

Komunikazioak / Comunicaciones

<i>Advancing Wind Energy Forecasting by Integrating Power Curves into SARIMAX Models</i>	3
L. Ricardo de la Rosa, Alejandro Gómez, Matilde Santos, Lía García-Pérez	

<i>Especificaciones de una interfaz de usuario para un gemelo digital de aerogeneradores</i>	9
José A. Tortosa-Aranda, Airam Martín Peraza, Segundo Esteban San Román, Matilde Santos	

<i>Classic Optimisation Methodology as an Inverse Problem for Parameter Identification for Floating Offshore Wind Turbines</i>	14
Sandra Piernikowska, María Tomás-Rodríguez	

<i>Detección de anomalías en aerogeneradores mediante una red neuronal MLP optimizada con un algoritmo genético</i>	20
Dennys Coronel, César Guevara, Matilde Santos	

<i>Quantification of power losses due to wake effect and yaw misalignment in a simulated wind farm</i>	25
Lucia Garcia-Lado, Samuel Martinez-Gutiérrez, Alejandro Merino-Gomez, Daniel Sarabia-Ortiz, Ruben Ruiz-Gonzalez	

<i>Estabilización de Voltaje y Energía Compartida en Microrredes Aisladas</i>	31
Tahereh Bagheri Rouch, Fares Mzoughi, Payam Aboutalebi, Irfan Ahmad, Aitor J. Garrido, Izaskun Garrido	

<i>Control Inteligente del ángulo de palas de un aerogenerador mediante aprendizaje por refuerzo.....</i>	<i>37</i>
<i>Inazio Cavero, Matilde Santos, J. Enrique Sierra-García</i>	
<i>Control de flujo de aire basado en ANFIS de turbinas eólicas marinas híbridas flotantes con columna de agua oscilante para mitigación de vibraciones.....</i>	<i>43</i>
<i>Fares Mzoughi, Payam Aboutalebi, Irfan Ahmad, Tahereh Bagheri Rouch, Izaskun Garrido, Aitor J. Garrido</i>	
<i>First Wind Power Prototype Response for System Behavior Analysis.....</i>	<i>49</i>
<i>Eduardo Muñoz-Palomeque, David Sanz, Lía García-Pérez</i>	
<i>Experimentos de relajación de un prototipo de FOWT.....</i>	<i>54</i>
<i>Segundo Esteban San Román, Eduardo Muñoz-Palomeque, Tahereh Bagheri, Payam Aboutalebi</i>	
<i>Experimentos con oleaje y viento de un prototipo de FOWT.....</i>	<i>59</i>
<i>Eduardo Muñoz-Palomeque, Segundo Esteban San Román, Tahereh Bagheri, Payam Aboutalebi</i>	
<i>Generación automática de datos de diseño de palas de turbinas eólicas.....</i>	<i>64</i>
<i>Fernando Herrera-Marín, J. Enrique Sierra-García, Matilde Santos</i>	
<i>Machine learning para la identificación de anomalías en turbinas eólicas.....</i>	<i>70</i>
<i>Bassel Weiss, Segundo Esteban San Román, Matilde Santos</i>	
<i>Estrategias de Control Avanzadas para Sistemas Híbridos de Aerogeneradores Flotantes y Columnas de Agua Oscilante: Un Enfoque PID.....</i>	<i>76</i>
<i>Payam Aboutalebi, Fares Mzoughi, Irfan Ahmad, Tahereh Bagheri, Aitor J. Garrido, Izaskun Garrido</i>	
<i>AI-Based Modeling of Integrated Floating Offshore Wind Turbine and Oscillating Water Column Systems Hybrid Systems.....</i>	<i>82</i>
<i>Irfan Ahmad, Fares Mzoughi, Payam Aboutalebi, Izaskun Garrido, Aitor J. Garrido</i>	

Introduction / Prólogo / Sarrera

Introduction

In 2024, global tensions persist, with conflicts such as those in Gaza and Ukraine continuing to impact the transportation and availability of crude oil. This reinforces the urgency of developing efficient and reliable marine renewable energy sources. As the transition to sustainable energy accelerates, ocean-based renewables present a largely untapped opportunity to transform the global energy landscape. Research on ocean energy control applications remains crucial to enhancing efficiency and reliability, making these systems more cost-effective and competitive with other energy sources. Technological advancements in this field could lead to new ocean energy technologies and strategies, expanding the range of harnessable resources.

WWME originated as an initiative linked to projects PID2021-123543OB-C21 / PID2021-123543OB-C22, led by the ISCAR group at the Complutense University of Madrid (<http://www.floatingwindturbineucm.com>) and the Automatic Control Group at UPV/EHU (<https://www.ehu.es/en/web/acg/ikerketa>). In a short time, it has evolved into an annual platform for presenting, discussing, and disseminating the latest developments and key findings in ocean energy research and education. It serves as a unique forum where multidisciplinary experts, academics, and industry professionals converge to exchange knowledge, tackle major challenges, and explore new opportunities. Other stakeholders benefit from deeper insights into the potential and challenges of wind and marine energy.

Prólogo

En 2024, las tensiones globales persisten, con conflictos como los de Gaza y Ucrania que siguen afectando el transporte y la disponibilidad de petróleo crudo. Esto refuerza la urgencia de desarrollar fuentes de energía renovable marina eficientes y fiables. A medida que la transición hacia la energía sostenible se acelera, las energías renovables oceánicas representan una oportunidad en gran parte inexplorada para transformar el panorama energético global. La investigación en aplicaciones de control de la energía oceánica sigue siendo crucial para mejorar la eficiencia y la fiabilidad, haciendo que estos sistemas sean más rentables y competitivos frente a otras fuentes de energía. Los avances tecnológicos en este campo podrían dar lugar a nuevas tecnologías y estrategias en energía oceánica, ampliando la gama de recursos aprovechables.

WWME surgió como una iniciativa vinculada a los proyectos PID2021-123543OB-C21 / PID2021-123543OB-C22, liderados por el grupo ISCAR de la Universidad Complutense de Madrid (<http://www.floatingwindturbineucm.com>) y el Grupo de Control Automático de la UPV/EHU (<https://www.ehu.eus/en/web/acg/ikerketa>). En poco tiempo, ha evolucionado hasta convertirse en una plataforma anual para la presentación, discusión y difusión de los últimos avances y hallazgos clave en la investigación y educación sobre energía oceánica. Sirve como un foro único donde expertos multidisciplinares, académicos y profesionales de la industria convergen para intercambiar conocimientos, abordar los principales desafíos y explorar nuevas oportunidades. Otros actores involucrados se benefician de una comprensión más profunda del potencial y los retos de la energía eólica y marina.

Sarrera

2024an, mundu mailako tentsioek bere horretan diraute, Gaza eta Ukrainakoak bezalako gatazkek petrolio gordinaren garraioan eta eskuragarritasunean eragina izaten jarraitzen baitute. Horrek itsas energia berriztagarrien iturri eraginkor eta fidagarriak garatzeko premia indartzen du. Energia iraunkorrerako trantsizioa bizkortzen den heinean, ozeanoetan oinarritutako berriztagarriek energia-paisaia globala eraldatzeko neurri handi batean aprobetxatu gabeko aukera dute. Ozeanoen energia kontrolatzeko aplikazioen ikerketa funtsezkoa da oraindik eraginkortasuna eta fidagarritasuna hobetzeko, sistema horiek errentagarriagoak eta lehiakorragoak izan daitezkeen beste energia-iturri batzuekin. Arlo honetako aurrerapen teknologikoez ozeanoko energiaren teknologia eta estrategia berriak ekar litzakete, aprobetxa daitezkeen baliabideen sorta zabalduz.

WWME bertoko ekimen gisa sortu da, PID2021-123543OB-C21 / PID2021-123543OB-C22 proiektuei lotuta, Madrilgo Unibertsitate Complutenseko ISCAR (<http://www.floatingwindturbineucm.com>) eta UPV/EHUko Kontrol Automatikoko Taldea (<https://www.ehu.eus/en/web/acg/ikerketa>) ikerketa taldeen eskutik. Epe laburrean, jardunaldia gune arrakastatsu bihurtu da: han aurkezten, eztabaidatzen eta zabaltzen dira ikerkuntza eta hezkuntza arloei dagozkien energia ozeanikoaren aplikazioen azken garapen eta emaitza garrantzitsuenak. Jardunaldiak, arloko diziplina desberdineko adituak, akademiko zein profesionalak, biltzeko aukera eskaintzen du. Hor, sektorean sortutako azken garapenari buruzko esperientziak truka daitezke eta agertzen diren arazo nagusiei aurre egiteko konponbideak azter eta eztabaida daitezke.

2024ko abendua. Diciembre de 2024.

Izaskun Garrido

Matilde Santos

Aitor J. Garrido

Organizadores de la VI Jornada Internacional de Energía Eólica (y) Marina, proyectos PID2021-123543OB-C21/C22 (MICIU/AEI/10.13039/501100011033/FEDER, UE)

Advancing Wind Energy Forecasting by Integrating Power Curves into SARIMAX Models

L. R. De la Rosa
Complutense University of Madrid
28040-Madrid, Spain
ORCID 0000-0001-6579-5949

Alejandro Gómez
Independent Researcher
Madrid, Spain
agomezmo16@outlook.es

M. Santos
Institute of Knowledge Technology
Complutense University of Madrid
28040-Madrid, Spain
ORCID 0000-0003-1993-8368

L. García-Pérez
Complutense University of Madrid
28040-Madrid, Spain
ORCID 0000-0002-6519-9108

Abstract—Effective forecasting of wind energy is crucial to optimizing the integration of renewable energy into power grids. Traditional forecasting models often rely on historical wind speed data, which may not fully capture the complexities of wind energy generation. This study examines the enhancement of wind energy forecasts by incorporating power-wind speed curves as an exogenous variable within a SARIMAX model. Data preprocessing was performed using a public dataset from Kelmarsh, UK, which involved handling missing values and normalization, followed by an in-depth analysis of stationarity and seasonality. A power-wind speed curve was fitted to historical data and compared with the use of raw wind speed as an exogenous input in the SARIMAX model. The analysis indicates that integrating the power-wind speed curve leads to improved forecast performance, as evaluated by metrics such as RMSE, MAE, and MAPE, compared to using wind speed alone. These findings highlight the potential of incorporating domain-specific features to improve wind energy forecasting, contributing to more efficient management of renewable energy resources.

Index Terms—Wind Energy Forecasting, SARIMAX, Power-Wind Speed Curve, Time Series Analysis, Exogenous Variables, Renewable Energy

I. INTRODUCTION

In recent years, the rapid integration of wind energy into national grids, driven by technological advances and policy incentives for carbon neutrality [1], has highlighted the challenges posed by the intermittent nature of wind energy. Variability in wind speed can cause unpredictable power fluctuations, complicating grid stability and the balance between supply and demand [2]. Therefore, accurate forecasting of wind energy is crucial to ensure a reliable integration of wind resources while minimizing the reliance on fossil fuel-based backup systems [3]. These forecasts, which span time horizons from minutes to days, are essential for efficient grid operation, resource scheduling, and market trading [4]. Poor forecasts can lead to grid instability, increased operational costs, and financial losses from misestimating wind power generation. As wind farms expand, the demand for precise forecasting methods has increased, making it a key area of

renewable energy research [5]. Effective forecasting solutions are necessary to mitigate output variability, thus improving the stability of the grid and operational reliability [6].

Traditional approaches to wind energy forecasting, such as ARIMA (Autoregressive Integrated Moving Average) and SARIMA (Seasonal ARIMA), effectively capture linear patterns in historical data [7], but they struggle to address the non-linear relationship between wind speed and power output [8]. This nonlinearity arises from factors such as turbine cut-in speeds, rated power limits, and mechanical constraints, which means that increases in wind speed do not always result in proportional increases in power generation. To overcome these limitations, integrating wind speed-power curves into forecasting models has gained attention [9]. These curves provide a more accurate representation of turbine performance, enabling models such as SARIMAX (Seasonal ARIMA with Exogenous Variables) to incorporate non-linear behavior, thereby improving forecast accuracy, reducing grid imbalances, and optimizing energy dispatch [10].

Given these advantages, this study employs a SARIMAX model to forecast wind power generation by integrating wind speed-power curves as exogenous variables. SARIMAX was selected because of its ability to incorporate additional contextual information, such as atmospheric pressure and temperature, which improves the accuracy of wind power predictions. Compared to machine learning models such as Random Forest, Support Vector Machines (SVM), or Artificial Neural Networks (ANN), SARIMAX offers greater interpretability and efficiency, particularly when working with smaller datasets or highly seasonal data [11]. These characteristics make it an appropriate choice to capture the periodic fluctuations inherent in wind energy generation, without the risk of overfitting. The primary objective of this research is to evaluate whether the use of turbine-specific power curves, rather than relying solely on raw wind speed data, improves forecast accuracy. By demonstrating the value of integrating these curves into

forecasting models, this study aims to improve wind energy predictions, support more efficient renewable energy management, and facilitate smoother integration of wind power into the grid. Ultimately, better forecasting can lead to optimized energy dispatch, reduced grid imbalances, and a decreased reliance on conventional backup power sources.

II. DATA AND PREPROCESSING

A. Data Collection and Characteristics

The dataset used in this study originates from the Kelmarsh Wind Farm in the UK and is publicly available through Zenodo [12]. It includes data from six Senvion MM92 turbines, each with a rated power of 2.05 MW, a rotor diameter of 92.5 meters, and a hub height of 100 meters. The dataset comprises 10-minute high-resolution SCADA data collected from 2016 to mid-2021, which captures key operational parameters such as wind speed, power output, turbine status indicators, ambient temperature, and rotor speeds. In addition, the dataset provides static information, including turbine coordinates, technical specifications, and site substation as well as fiscal meter data where available. This comprehensive dataset enables detailed analysis of wind turbine performance and supports the development of sophisticated forecasting models.

B. Preprocessing

During preprocessing, the dataset variables were categorized into two groups: turbine-specific variables and external environmental variables. Turbine-specific variables, such as rotor speeds, nacelle positions, and turbine status indicators, reflect the internal operating state of each turbine and are essential for performance monitoring and diagnostics. These variables capture primarily internal turbine conditions rather than external factors affecting energy output. In contrast, external variables, such as wind speed, wind direction, and ambient temperature, directly influence energy generation by determining the available kinetic energy for conversion [4]. For this analysis, wind speed, wind direction, and ambient temperature were selected as key exogenous variables due to their significant impact on wind energy generation.

Handling missing values during preprocessing was critical for addressing temporal inconsistencies. Although the dataset did not explicitly mention time lags, gaps in signals suggested possible irregularities. To mitigate this, a two-step approach was applied: linear interpolation and hourly mean imputation. Linear interpolation estimated missing values using adjacent data points [13]. For remaining gaps, data were grouped by hour of the day, and missing values were filled using the mean for that specific hour. This approach preserved natural diurnal patterns in wind speed and turbine operations, ensuring consistency with expected temporal trends. Although the reconstructed values may not perfectly replicate the original time series, this limitation is unlikely to significantly affect the performance of the model. The preprocessing strategy

prioritizes capturing overall trends and relationships in the data over memorizing specific patterns, thus reducing the risk of overfitting. By maintaining robustness and generalization, this method supports reliable predictions despite potential temporal inconsistencies.

Wind speed, as a time series variable, exhibits highly variable behavior due to natural atmospheric dynamics, which can make it challenging to model effectively. Conventional methods for handling outliers could potentially filter out significant fluctuations that are essential to understanding the actual wind conditions that affect power generation. Removing these extreme values might lead to the loss of valuable information, as such variations are a natural aspect of wind patterns. Therefore, to preserve the inherent characteristics of the wind speed data, it was decided to retain these fluctuations instead of applying conventional outlier removal techniques. This approach is supported by the review conducted by Zou et al. [14], which emphasizes the importance of maintaining the natural variability in the wind speed data for accurate modeling and analysis.

The focus of the analysis was to forecast the energy output of the entire wind farm rather than individual turbines. Therefore, data from all six turbines were aggregated to generate farm-level metrics. Total power output and energy were calculated by summing these values across turbines. For external variables, such as wind speed, wind direction, and ambient temperature, average values were computed across turbines to produce a unified farm-level dataset. This aggregation approach captures the overall behavior of the wind farm under various environmental conditions.

Finally, normalization of the dataset was performed to ensure that variables with different scales did not disproportionately affect the forecasting model. For this purpose, Z-score normalization was applied to standardize the features. This technique involves transforming each feature by subtracting its mean and dividing by its standard deviation, thereby centering the data around zero with a unit variance. The transformation is defined by the equation:

$$X_{normalized} = \frac{X - \mu}{\sigma} \quad (1)$$

where X is the original value, μ is the mean of the feature, and σ is the standard deviation. This normalization step is essential because variables like power output (measured in kilowatts) and temperature (measured in degrees Celsius) operate on different scales. Without normalization, features with larger numerical ranges could dominate the model, potentially leading to biased predictions.

III. PRELIMINARY ANALYSIS

A. Wind Speed-Power Curve Fitting

A preliminary analysis was conducted to evaluate the relevance of external variables in predicting wind energy gen-

eration. The correlation and mutual information metrics were used to identify the variables with the most significant impact on power output. The results indicated that wind speed was the primary driver of energy generation, showing the strongest correlation with power output. In contrast, other factors, such as ambient temperature and wind direction, exhibited much weaker associations, suggesting that they contributed minimally to predictive performance in the given dataset. Based on these findings, the focus was placed on wind speed as the key exogenous variable to optimize the forecasting model. However, it is important to note that in other contexts, such as regions with complex terrain or during atypical weather conditions, variables like wind direction or temperature might play a more substantial role.

The relationship between wind speed and power output follows a sigmoidal pattern, characteristic of wind turbine performance. At low wind speeds (below the cut-in speed), power generation is minimal due to insufficient force to turn the blades. As the wind speed increases beyond the cut-in speed, the power output increases rapidly until it reaches the rated speed, where the turbine achieves the maximum power output. Beyond this point, the power output is reduced to prevent mechanical wear and ensure safe operation [15]. This sigmoidal relationship can be effectively modeled using a logistic function:

$$P(w) = \frac{P_{max}}{1 + e^{-k(w-w_0)}} \quad (2)$$

where $P(w)$ is the predicted power at wind speed w , P_{max} is the maximum power output, k controls the steepness of the curve, and w_0 is the wind speed at the inflection point where power output rises most rapidly. As shown in Figure 1, fitting this function to the data accurately captures the turbine's performance, thereby improving the integration of wind speed data into forecasting models.




Fig. 1. Fitted sigmoidal curve representing the relationship between wind speed and power output.

To fit the logistic function to the data, the non-linear least-squares method was used. This technique minimizes the

sum of the squared residuals, where each residual represents the difference between the observed power output and the predicted value from the logistic function. The optimization process iteratively adjusts the parameters P_{max} , k , and w_0 to find the best-fit curve that minimizes the error.

B. Stationarity and Seasonal Analysis

To analyze the stationarity and seasonality of the dataset, a seasonal decomposition was performed (as shown in Figure 2). This process helps break down the time series data into its core components: trend, seasonality, and residuals. By using an additive model, which assumes that these components sum together to form the observed data, it becomes possible to isolate the repeating seasonal patterns that occur over a set period while also identifying any underlying trends and irregular fluctuations [16].

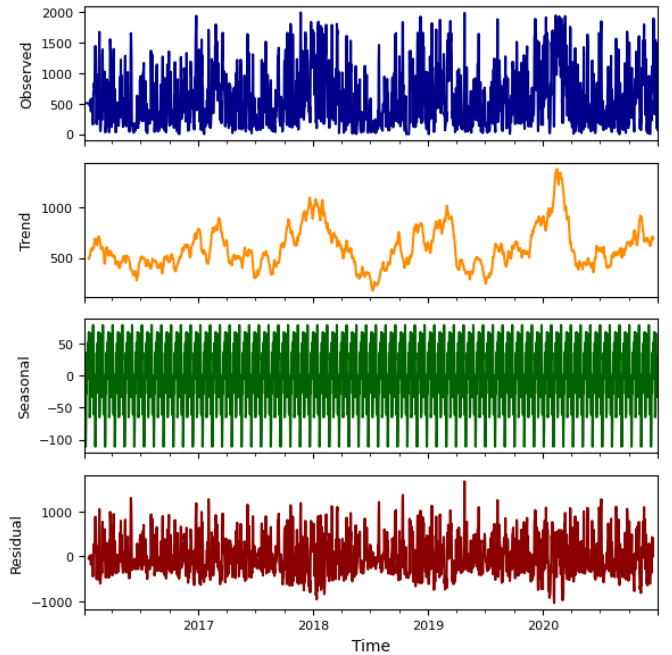


Fig. 2. Seasonal decomposition of wind generation.

A period of 31 days was selected for this analysis to capture potential monthly cycles in wind patterns and energy output. The decomposition revealed a very slight, recurring variation in the seasonal component. However, this fluctuation was minimal and could potentially be insignificant, given the narrow range of values it comprised. This suggests that while there may be a minor influence of monthly patterns on energy generation, the impact is likely too small to be of practical significance for the forecasting model.

To further analyze the stationarity and confirm the seasonality of the data, the Augmented Dickey-Fuller (ADF) test and the Kwiatkowski-Phillips-Schmidt-Shin (KPSS) test were performed. These two tests are commonly used but they approach the problem from different perspectives [17]. The

ADF test checks for the presence of a unit root by testing the null hypothesis that the time series is non-stationary. If the null hypothesis is rejected, it suggests that the series is stationary, meaning its statistical properties such as mean and variance do not change over time. Conversely, the KPSS test evaluates stationarity by testing the null hypothesis that the time series is stationary around a deterministic trend. Rejecting its null hypothesis suggests the series is non-stationary and may include a unit root. The results of the ADF test suggested that the time series is stationary. While the KPSS test indicated the opposite, suggesting non-stationarity. The discrepancy suggests that the series may exhibit characteristics of both stationarity and non-stationarity, potentially influenced by seasonal patterns.

IV. MODEL DEVELOPMENT AND EXPERIMENTAL SETUP

A. Overview of SARIMAX Models

The SARIMAX model combines several components to enhance predictive capabilities. The autoregressive (AR) part captures the influence of past values on the current observation, enabling the model to identify patterns where the current output is dependent on its historical values. The differencing (I) component is employed to remove non-stationarity by transforming the series into one where statistical properties such as mean and variance are constant over time. The moving average (MA) terms focus on modeling past forecast errors, smoothing out random fluctuations to provide more stable predictions [18].

To handle seasonality, SARIMAX includes periodic adjustments through seasonal AR, differencing, and MA terms, denoted as P , D , Q , respectively, which allow the model to capture repeating patterns occurring over a defined seasonal cycle length s . An important enhancement in SARIMAX is the inclusion of exogenous variables (X_t), which allows the model to integrate external data sources that influence the target variable. These exogenous inputs can include any time-dependent factors that provide additional context, such as meteorological data for wind energy forecasting, macroeconomic indicators for financial models, or other domain-specific drivers.

The SARIMAX model is defined by the following equation:

$$\Phi_P(L^s)\phi_p(L)(1-L^s)^D(1-L)^dY_t = \Theta_Q(L^s)\theta_q(L)\epsilon_t + \beta X_t \quad (3)$$

Here, $\phi_p(L)$ and $\theta_q(L)$ represent the non-seasonal AR and MA polynomials, respectively, while $\Phi_P(L^s)$ and $\Theta_Q(L^s)$ denote the seasonal AR and MA polynomials with lag s . The differencing operators $(1-L)^d$ and $(1-L^s)^D$ are applied to achieve stationarity in the non-seasonal and seasonal components. The term βX_t accounts for the effect of the exogenous variables, and ϵ_t is the error term that captures the residuals not explained by the model.

To effectively deploy a SARIMAX model, it is essential to optimize the parameters:

- Non-seasonal components: p (autoregressive), d (differencing), q (moving average).
- Seasonal components: P (seasonal autoregressive), D (seasonal differencing), Q (seasonal moving average), and s (seasonal period length).
- Exogenous variables (X_t): These are carefully selected based on their relevance and influence on the target time series.

B. Model parameter selection and tuning process

To optimize the parameters of the SARIMAX model, the stepwise search algorithm was utilized. This method systematically adjusts combinations of parameters, including autoregressive (AR), differencing (I), and moving average (MA) components, to find the best configuration. The algorithm iterates by adding or removing terms and evaluates each model to determine the best fit. The evaluation criterion used is the Akaike Information Criterion (AIC), which measures the model's fit while penalizing complexity [19]. The AIC balances the trade-off between model accuracy and simplicity by assigning a lower score to models that better capture the data patterns without unnecessary complexity. A lower AIC score indicates a model that is both efficient and effective for forecasting, reducing the risk of overfitting by avoiding overly complex models.

Using this approach, the optimal model identified was ARIMA(1,1,2)(0,0,0)(30). In this notation, the first part ARIMA(p,d,q) represents the non-seasonal components: 1 autoregressive term ($p=1$), 1 differencing term ($d=1$) to handle non-stationarity, and 2 moving average terms ($q=2$) to model the error patterns. The second part (P,D,Q) indicates that there are no seasonal autoregressive, differencing, or moving average terms (all set to 0). The (30) signifies a periodicity of 30 days, capturing potential monthly patterns or cycles. This configuration allows the model to address trends and dependencies in the data without explicitly including seasonal adjustments, focusing on monthly patterns implicitly.

C. Configuration of models with different exogenous variables

The previously identified optimal model was adjusted by setting the periodicity to 4320 to account for the dataset's 10-minute sampling rate. This adjustment was necessary because 4320 intervals correspond to one full 30-day cycle when data is sampled every 10 minutes ($144 \text{ intervals/day} \times 30 \text{ days}$). This modification ensures that the model accurately captures the monthly patterns in the data, aligning with its natural frequency.

The model was trained using two different configurations for the exogenous variables: one setup utilized wind speed as the exogenous input, while the other employed the logistic

curve representing the power-wind speed relationship. The aim was to compare how these two configurations influence the model’s forecasting capability, determining whether the inclusion of the wind speed-power curve could enhance the model’s performance compared to using raw wind speed alone. Additionally, the analysis included testing with different sampling rates (10-minute vs. 30-minute intervals) to evaluate the impact of data resolution on the model’s performance.

V. RESULTS AND EVALUATION

The model’s forecasting capabilities were tested with a 72-hour horizon, projecting power generation three days into the future. This extended forecast period was chosen to evaluate how well the model performs over a short-term timeframe, allowing for the assessment of its ability to capture fluctuations in wind energy output.

To evaluate the performance of the model with the different configurations, the following metrics were utilized:

- R^2 score (coefficient of determination): Measures how well the model’s forecasts align with actual power generation data. An R^2 value near 1 indicates the model effectively captures the variability in wind energy output, reflecting its ability to explain fluctuations caused by changing wind conditions.
- MAE (Mean Absolute Error): Represents the average absolute difference between the predicted and actual generation, providing a straightforward measure of typical forecast errors. Lower MAE values indicate consistent predictions with minimal deviation, crucial for operational decisions.
- RMSE (Root Mean Squared Error): Emphasizes larger errors by squaring the differences before averaging. In wind energy forecasting, a lower RMSE indicates the model handles extreme fluctuations well, which is important during sudden changes in wind speed.
- MAPE (Mean Absolute Percentage Error): Expresses errors as a percentage of actual generation, allowing for easier comparison across different power scales. This helps ensure a meaningful performance evaluation, especially given the variability in wind power output.

A. Performance Comparison: Wind Speed vs. Power Curve Exogenous Inputs

As observed in Figures 3 and 4, the performance of each model is significantly improved by using the power curve as an exogenous input. The exact results are summarized in Table I, where the improvement is particularly evident across all performance metrics. The use of the power curve leads to a much closer fit to the observed data, demonstrating a substantial enhancement in the model’s forecasting capabilities compared to using raw wind speed alone.

For instance, the R^2 score improved by 25% at the 10-minute sampling rate (from 0.70 to 0.93) and by 13% at the 30-minute sampling rate (from 0.84 to 0.97). The MAE showed a 50% reduction with the 10-minute interval (from 0.44 to 0.22) and a 53% reduction with the 30-minute interval (from 0.32 to 0.15). Similarly, the RMSE decreased by 53% at the 10-minute rate (from 0.60 to 0.28) and by 58% at the 30-minute rate (from 0.43 to 0.18). In terms of MAPE, using the power curve resulted in a 17% improvement for the 10-minute sampling rate (from 0.69 to 0.57) and a 33% improvement for the 30-minute rate (from 0.36 to 0.24). These significant reductions in error metrics highlight the model’s enhanced ability to capture the non-linear relationship between wind speed and power output more effectively.

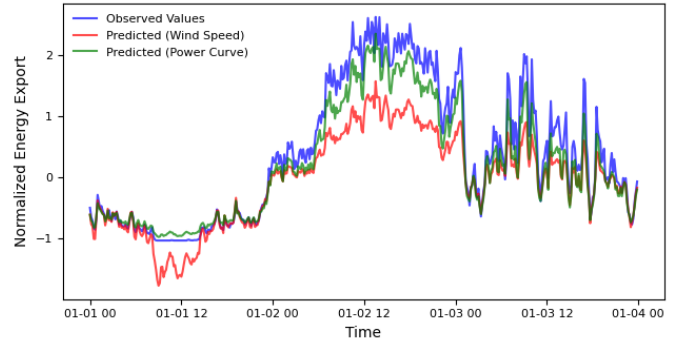


Fig. 3. Comparison of observed vs. predicted normalized energy export values over a 72-hour period using a 10-minute sampling rate and two different exogenous inputs: wind speed (red line) and the logistic power curve (green line).

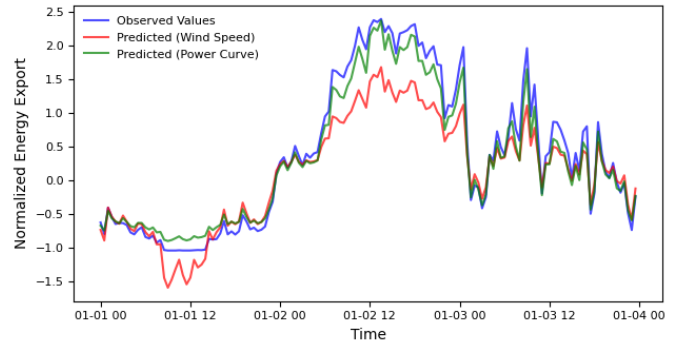


Fig. 4. Comparison of observed vs. predicted normalized energy export values over a 72-hour period using a 30-minute sampling rate and two different exogenous inputs: wind speed (red line) and the logistic power curve (green line).

The integration of the logistic power curve, combined with an optimized sampling rate, enables the model to better capture the true dynamics of wind power generation, resulting in a closer alignment with the observed data. This approach also significantly reduces forecast errors and improves the stability of the model, especially during extended forecast periods. These findings highlight that the use of turbine-specific power curves and the selection of an appropriate sampling interval are crucial strategies to improve wind power forecasts.

TABLE I
MODEL PERFORMANCE METRICS USING WIND SPEED AND POWER CURVE
AS EXOGENOUS INPUTS WITH DIFFERENT SAMPLING RATES.

Metric	Sampling Rate	Wind Speed	Power Curve
R ² score	10 min	0.70	0.93
	30 min	0.84	0.97
MAE	10 min	0.44	0.22
	30 min	0.32	0.15
RMSE	10 min	0.60	0.28
	30 min	0.43	0.18
MAPE	10 min	0.69	0.57
	30 min	0.36	0.24

CONCLUSIONS AND FUTURE WORK

This study demonstrated the effectiveness of using SARI-MAX models with exogenous variables to forecast wind energy generation. By incorporating the turbine-specific power curve, which captures the non-linear relationship between wind speed and power output, the model significantly outperformed configurations that relied solely on raw wind speed data. The results showed substantial improvements in key performance metrics, including R², MAE, RMSE, and MAPE, indicating a more reliable alignment with the actual power output. This highlights the value of using domain-specific knowledge, such as power curves, to improve forecasting models and improve the integration of wind energy into power grids.

However, several challenges were identified, particularly regarding the inherent variability of wind speed data, which introduces noise and unpredictability. Techniques that address data irregularities, such as anomaly detection and explainable methods, could further enhance model performance [20]. The analysis also revealed that sampling rates play a crucial role in model performance. Comparison between 10-minute and 30-minute sampling intervals showed that a coarser sampling rate helped reduce noise, resulting in better forecast stability and lower error rates. This suggests that optimizing the sampling rate is critical for balancing data granularity and noise reduction, ultimately leading to more reliable predictions.

For future research, several avenues could improve the current approach. One promising direction is applying signal decomposition techniques to filter and reduce noise in the data before forecasting. Methods such as wavelet transforms or empirical mode decomposition (EMD) could help isolate underlying patterns, improving prediction accuracy. Additionally, advanced machine learning models like Long Short-Term Memory (LSTM) networks could be used to capture complex non-linear relationships and long-term dependencies that the SARIMAX model may not fully address. Hybrid models, which combine traditional statistical methods with machine learning techniques, offer another potential improvement by leveraging the strengths of both approaches. These strategies could lead to more robust and precise wind energy forecasts,

ultimately supporting efficient grid management and smoother integration of renewable energy sources.

ACKNOWLEDGMENT

This work has been partially funded by the Spanish Ministry of Science and Innovation, under the MCI/AEI/FEDER project number PID2021-123543OBC21.

REFERENCES

- [1] S. D. Ahmed, F. S. Al-Ismael, M. Shafiqullah, F. A. Al-Sulaiman, and I. M. El-Amin, "Grid integration challenges of wind energy: A review," *Ieee Access*, vol. 8, pp. 10 857–10 878, 2020.
- [2] 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-art, challenges and future trends," *Wind Engineering*, vol. 47, no. 2, pp. 422–441, 2023.
- [3] M. Scacie, M. Santos, R. López, and R. Pandit, "Use of state-of-art machine learning technologies for forecasting offshore wind speed, wave and misalignment to improve wind turbine performance," *Journal of Marine Science and Engineering*, vol. 10, no. 7, p. 938, 2022.
- [4] H. Yun, C. D. Giurcăneanu, and G. Dobbie, "Several approaches for the prediction of the operating modes of a wind turbine," *Electronics*, vol. 13, no. 8, p. 1504, 2024.
- [5] B. Loza, L. I. Minchala, D. Ochoa-Correa, and S. Martinez, "Grid-friendly integration of wind energy: A review of power forecasting and frequency control techniques," *Sustainability*, vol. 16, no. 21, p. 9535, 2024.
- [6] O. Benzohra, S. S. Echcharqaouy, F. Fraija, and D. Saifaoui, "Integrating wind energy into the power grid: Impact and solutions," *Materials Today: Proceedings*, vol. 30, pp. 987–992, 2020.
- [7] E. Yatiyana, S. Rajakaruna, and A. Ghosh, "Wind speed and direction forecasting for wind power generation using arima model," in *2017 Australasian universities power engineering conference (AUPEC)*. IEEE, 2017, pp. 1–6.
- [8] K. Szostek, D. Mazur, G. Drałus, and J. Kuszniar, "Analysis of the effectiveness of arima, sarima, and svr models in time series forecasting: A case study of wind farm energy production," *Energies (19961073)*, vol. 17, no. 19, 2024.
- [9] M. Lydia, S. Suresh Kumar, A. Immanuel Selvakumar, and G. Edwin Prem Kumar, "Wind farm power prediction based on wind speed and power curve models," in *Intelligent and Efficient Electrical Systems: Selected Proceedings of ICIEES'17*. Springer, 2018, pp. 15–24.
- [10] F. R. Alharbi and D. Csala, "A seasonal autoregressive integrated moving average with exogenous factors (sarimax) forecasting model-based time series approach," *Inventions*, vol. 7, no. 4, p. 94, 2022.
- [11] Y. Kim and J. Hur, "An ensemble forecasting model of wind power outputs based on improved statistical approaches," *Energies*, vol. 13, no. 5, p. 1071, 2020.
- [12] J. M. Polito, C. Johnson, D. J. Paul, and N. W. Hodnett, "Kelmarsch wind farm scada dataset," <https://zenodo.org/record/5841834>, Jan. 2022.
- [13] M. Lepot, J.-B. Aubin, and F. H. Clemens, "Interpolation in time series: An introductory overview of existing methods, their performance criteria and uncertainty assessment," *Water*, vol. 9, no. 10, p. 796, 2017.
- [14] M. Zou and S. Z. Djokic, "A review of approaches for the detection and treatment of outliers in processing wind turbine and wind farm measurements," *Energies*, vol. 13, no. 16, p. 4228, 2020.
- [15] T. Burton, N. Jenkins, D. Sharpe, and E. Bossanyi, *Wind energy handbook*. John Wiley & Sons, 2011.
- [16] G. E. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- [17] P. J. Brockwell and R. A. Davis, *Introduction to time series and forecasting*. Springer, 2002.
- [18] F. R. Alharbi and D. Csala, "A seasonal autoregressive integrated moving average with exogenous factors (sarimax) forecasting model-based time series approach," *Inventions*, vol. 7, no. 4, 2022.
- [19] R. Hyndman, *Forecasting: principles and practice*. OTexts, 2018.
- [20] S. Cuéllar, M. Santos, F. Alonso, E. Fabregas, and G. Farias, "Explainable anomaly detection in spacecraft telemetry," *Engineering Applications of Artificial Intelligence*, vol. 133, p. 108083, 2024.

Especificaciones de una interfaz de usuario para un gemelo digital de aerogeneradores

José Antonio Tortosa
Aranda
Universidad Complutense
de Madrid
28040-Madrid, Spain
josetort@ucm.es

Airam Martín Peraza
Universidad Complutense
de Madrid
28040-Madrid, Spain
airammar@ucm.es

Segundo Esteban San
Román
Universidad Complutense
de Madrid
28040-Madrid, Spain
sesteban@ucm.es

Matilde Santos
Universidad Complutense
de Madrid
28040-Madrid, Spain
msantos@ucm.es

Resumen - Este artículo presenta las principales especificaciones que debe tener un interfaz de una plataforma web para el monitoreo y control de parques eólicos. La interfaz hombre-máquina debe permitir a los usuarios visualizar las ubicaciones de los parques eólicos en un mapa interactivo, donde un panel de selección facilite el acceso a parques específicos. Al seleccionar un parque, la interfaz se acerca a su ubicación en el mapa y muestra los datos relevantes de los aerogeneradores que lo componen. Un modelo de gemelo digital de un aerogenerador mejora aún más la interacción del usuario al permitir ajustes en parámetros operativos, como la velocidad de rotación y la orientación de las palas. El sistema está pensado para ser fácilmente escalable, admitiendo diferentes tipos de cuentas de usuario, desde aquellas con capacidades completas de control y gestión hasta otras con acceso solo de visualización. La plataforma dotará al usuario de un potencial significativo para optimizar los procesos de gestión de parques eólicos a través de una interfaz web accesible y flexible.

Keywords—*Aerogenerador, Gemelo digital, Plataforma web, especificaciones, interface hombre-máquina*

Abstract - This paper presents the main specifications that a web-based platform interface for monitoring and controlling wind farms should have. The human-machine interface should allow users to view wind farm locations on an interactive map, where a selection panel facilitates access to specific farms. Upon selecting a farm, the interface zooms to its location on the map and displays relevant data for the wind turbines within it. A digital twin model of a wind turbine further enhances user interaction by allowing adjustments to operational parameters such as rotation speed and blade orientation. The system is intended to be easily scalable, supporting different types of user accounts, from those with full control and management capabilities to those with view-only access. The platform will provide the user with significant potential to optimize wind farm management processes through an accessible and flexible web interface.

Keywords—*Wind turbine, Digital twin, web platform, specifications, human-machine interface*

I. INTRODUCCIÓN

La creciente adopción de energías renovables, particularmente la energía eólica, ha generado una demanda de sistemas avanzados para monitorear y controlar parques eólicos de manera eficiente. La gestión remota de estos parques presenta desafíos significativos, especialmente en lo que respecta al acceso en tiempo real a datos críticos de los aerogeneradores y a la capacidad de ajustar parámetros operativos para maximizar la eficiencia y minimizar el tiempo de inactividad [1].

Este proyecto propone una plataforma web diseñada para facilitar la supervisión y el control de parques eólicos mediante la integración de gemelos digitales [2].

El presente trabajo continúa la línea de investigación desarrollada en dos Trabajos de Fin de Grado (TFGs) previos. El primer TFG, titulado Arquitectura Hardware para el Control Remoto de Turbinas Eólicas Offshore, propuso una arquitectura hardware asequible y modular para el control remoto de turbinas eólicas offshore mediante gemelos digitales, con un prototipo que permite gestionar el ángulo de pitch y recopilar datos inerciales [3]. El segundo TFG, Integración de Datos en Tiempo Real y Funcionalidades Interactivas en Sistemas de Monitorización Eólica, avanzó en la integración de datos en tiempo real y en funcionalidades interactivas [4], documentadas también en el artículo disponible en Dialnet (Digital Twins and Wind Turbine Monitoring: Challenges and Solutions) [5]. Ambos trabajos, recopilados en el repositorio científico de la Universidad Complutense (Repositorio de Producción Científica UCM) [6], sientan las bases para este proyecto, que amplía estas funcionalidades con un enfoque más integral.

La plataforma permite a los usuarios, en función de su tipo de cuenta, visualizar los parques eólicos asociados a su empresa, acceder a los datos de cada turbina y ajustar los parámetros en tiempo

real. Un mapa interactivo muestra la ubicación de cada parque, mientras que un panel de selección permite a los usuarios elegir un parque específico y ver información detallada sobre sus turbinas. Además, la implementación de un gemelo digital proporciona una interfaz intuitiva para la interacción directa con un aerogenerador virtual, lo que permite ajustar la velocidad de rotación y la orientación de las palas.

Después de esta breve introducción, en la Sección II se describe la metodología empleada en el desarrollo de la plataforma. A continuación, en la Sección III se expone de forma más detallada la arquitectura software de la interfaz. En la Sección IV se expresa el procedimiento de desarrollo del *Frontend* actual del proyecto. Posteriormente, en la Sección V se describen los resultados y el estado actual del proyecto. Finalmente, en la Sección VI se transmiten las conclusiones y el trabajo futuro.

II. METODOLOGÍA

Esta Sección describe el enfoque adoptado para desarrollar la plataforma de supervisión y control del parque eólico, detallando las tecnologías, la arquitectura y los puntos clave.

La arquitectura del sistema consta de tres componentes principales: el *Frontend*, el *Backend* y la base de datos, *Database*.

- *Frontend*: La interfaz de usuario se desarrolla utilizando HTML, CSS y EJS para el renderizado dinámico de contenidos. Se implementa un mapa interactivo utilizando NASA WorldWind WebWorldWind [7], una librería que proporciona un entorno de visualización de la Tierra en 3D. También incluimos Spill the Beans Wind [8], una librería para renderizar un modelo gemelo de una turbina.
- *Backend*: Construido con Node.js [9] y Express.js [10], gestiona la autenticación de usuarios, el procesamiento de datos y la comunicación con la base de datos.
- *Database*: MongoDB [11] se utiliza para gestionar los datos de usuarios y parques eólicos, permitiendo consultas y actualizaciones eficientes. Para mejorar la seguridad, las contraseñas de los usuarios se cifran mediante bcrypt [12], protegiendo las cuentas frente a posibles vulnerabilidades.

Los puntos clave a tener en cuenta son:

1. Gestión de cuentas de usuario: Las cuentas de usuario están vinculadas a empresas específicas. Cuando inician sesión, los usuarios pueden acceder a los parques eólicos asociados a su organización.

Actualmente, los permisos están limitados a la gestión completa, pero los futuros tipos de cuenta permitirán el acceso de sólo visualización.

2. Mapa interactivo: El mapa aprovecha la biblioteca WebWorldWind para mostrar el globo terráqueo, marcando la ubicación de los parques eólicos. Un carrusel consulta y muestra dinámicamente los parques eólicos pertenecientes a la misma empresa que el usuario, proporcionando una forma fluida de explorar los activos asociados.

3. Gemelos digitales: Con la biblioteca Spill The Beans Wind se implementa un gemelo digital de aerogenerador. Esta función permite a los usuarios ajustar los parámetros y variables de la turbina, como la velocidad de rotación, la dirección y la orientación de las palas, etc, mediante entradas de teclado. Aunque esta funcionalidad está aún en fase de desarrollo, es capaz de representar el potencial de una interfaz de control intuitiva que, en el futuro, utilizará entradas de bases de datos en lugar de entradas de teclado. La integración de datos SCADA en esta funcionalidad permitiría representar condiciones operativas reales de los aerogeneradores. Esto es clave para el monitoreo y análisis de datos en tiempo real, como se discute en estudios sobre el uso de sistemas SCADA para la supervisión de turbinas eólicas y su papel en la mejora de la eficiencia operativa [13].

La implementación de gemelos digitales en aerogeneradores no solo mejora la interacción del usuario, sino que también se convierte en una herramienta esencial para validar sistemas de control en tiempo real. Como se ha demostrado en el uso de entornos PIL (Platform Independent Language) para turbinas eólicas, los gemelos digitales facilitan la validación de controladores en tiempo real, optimizando la operación y el rendimiento de las turbinas [14].

Aunque este proyecto está centrado en el desarrollo de la interfaz con el usuario, también se debe abordar la conexión con sistemas reales o simulados. Se debe importar la información generada por una simulación en MATLAB o un modelo real a la base de datos, como se muestra en la Figura 1. Estos datos se almacenan en MongoDB y se representan en tiempo real en nuestra plataforma a través de node.js. Finalmente, una vez completada esta etapa, procederemos a enviar instrucciones a través de MongoDB para que sean recibidas por MATLAB o el modelo real. Estas instrucciones podrían incluir parámetros como la velocidad, la rotación, o cualquier otro aspecto del aerogenerador.



Fig. 1. Esquema del funcionamiento

III. ARQUITECTURA SOFTWARE DE LA INTERFAZ DE USUARIO

En la Figura 2 se presenta la estructura de las entidades utilizadas para representar los datos, los cuales se encuentran almacenados en una base de datos MongoDB [11]. Esta organización permite mantener las operaciones de forma sencilla, ya que el número de entidades a gestionar no es elevado. Esto convierte a las entidades en elementos compactos y fáciles de manejar, favoreciendo la eficiencia y simplicidad en su implementación.

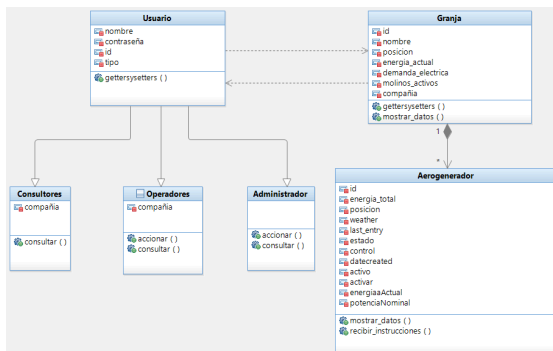


Fig. 2. Diagrama de Entidades con atributos y funciones

En la Figura 3 y en Figura 4, se presentan pseudocódigos sobre cómo se han implementado cada una de las librerías que nombramos anteriormente para llevar a cabo el desarrollo del Frontend.

INICIO

1. Instamos a la librería WorldWind.
2. Añadimos las capas necesarias al globo.
3. Realizamos ajustes específicos sobre ciertas capas como pueden ser (atomsphere o starField).
4. Añadimos los marcadores necesarios en el mapa para representar un aerogenerador.
 - a. Le añadimos un listener, para que se cambie la vista a su correspondiente gemelo digital al ser pulsado.
5. Añadimos funciones para realizar el movimiento hacia x parque eolico, cuando se pulsa sobre él en el carousel o bien sobre la lista de parques eólicos.

FIN

Fig. 3. Pseudocódigo modelo 3D de La Tierra

INICIO

1. Configuramos individualmente cada componente del generador (Aspas, Rotor, Cabezal, Torre, Cimientos...)
2. Añadimos funcionalidades a componentes concretos, giro de las aspas, giro del cabezal.
3. Añadir todos los componentes sobre uno nuevo llamado turbina.
4. Sobre una granja, representa turbina junto con el entorno.

FIN

Fig. 4. Pseudocódigo gemelo digital

IV. DESARROLLO DE LA INTERFAZ DE USUARIO

Combinar las dos bibliotecas principales, WebWorldWind y Spill The Beans Wind, plantearon importantes retos. Cada biblioteca tenía estructuras, dependencias y paradigmas de programación diferentes, lo que obligó a adaptarse

a tecnologías poco conocidas. Para optimizar el proyecto, se identificaron y eliminaron los componentes innecesarios de ambas bibliotecas, lo que racionalizó el código base.

Otro reto pendiente es la implantación de puntos finales específicos para gestionar las acciones de las turbinas. Estos endpoints permitirán funcionalidades avanzadas de control de los aerogeneradores, que es una característica clave aún en desarrollo.

El principal problema era que la biblioteca Spill the Beans utiliza React [15] para crear el modelo 3D de la turbina, que se basa en código .jsx [16]. El problema radica en que los navegadores web no pueden interpretar de forma nativa este tipo de código. Para solucionarlo, integramos Babel [13] para convertir el código .jsx a un formato .js y Webpack [18] para optimizar la versión resultante sobre una demo antes del lanzamiento.

Una vez convertido el código a formato .js, pudimos incrustarlo en un archivo HTML para renderizar el modelo 3D al seleccionar una turbina dentro del entorno 3D de la biblioteca WebWorldWind, Fig. 5.




Fig. 5. Gemelo digital renderizado

En la Figura 5, se muestra un gemelo digital, en el cual está previsto incorporar dos paneles laterales en el futuro. El primero, en el que estamos trabajando actualmente, mostrará los resultados generados a nivel individual por ese aerogenerador. El segundo panel presentará una serie de instrucciones que se pueden enviar al generador, como aumentar la resistencia, girar las aspas, cambiar el sentido de rotación o detener el sistema, entre otras opciones.

Este enfoque permitirá trabajar de forma remota con el aerogenerador, ya que el gemelo digital refleja su situación en tiempo real. Esto supone una mejora significativa en la usabilidad, especialmente para los aerogeneradores *offshore* [19], donde los costos y las dificultades de acceso representan un desafío considerable.

En la Figura 6, se muestra la estructura de carpetas, donde «gemeloDigital.js» representa el archivo output.js antes mencionado. Además, todo el proyecto de desarrollo del gemelo digital está

comprimido dentro del archivo "modelado_3D.zip".

```
TFG/
├─ bin/           # Archivos ejecutables o de inicialización del proyecto
├─ db/           # Archivos relacionados con la base de datos
├─ node_modules/ # Dependencias instaladas con npm
├─ public/       # Archivos públicos accesibles desde el navegador
├─ images/       # Imágenes del proyecto
├─ assets/       # Recursos gráficos
├─ img/          # Carpeta para imágenes
├─ models/       # Modelos 3D (JSON u otros formatos)
├─ pushpins/     # Archivos relacionados con marcadores en el mapa
├─ view/         # Contenido de vistas o gráficos adicionales
├─ javascripts/  # Scripts JavaScript para el frontend
├─ stylesheets/  # Archivos CSS para estilos
├─ routes/       # Rutas de la aplicación
├─ Test/         # Tests o pruebas del proyecto
├─ views/        # Plantillas EJS para las vistas del servidor
├─ logica/       # Lógica de vistas o plantillas específicas
├─ gemelo/       # Relacionado con el modelo de gemelos digitales
├─ salida/       # Archivo JavaScript específico
├─ gemeloDigital.js
├─ globo/        # Vistas relacionadas con el globo interactivo
├─ error.ejs     # Página de error
├─ gemelo.ejs    # Página de gemelo digital
├─ login.ejs     # Página de inicio de sesión
├─ main.ejs      # Página principal
├─ molinos.ejs  # Página de los molinos
├─ ubicaciones.ejs # Página de ubicaciones
├─ app.js        # Archivo principal de configuración del servidor
├─ modelado_3D.zip # Archivo comprimido relacionado con modelos 3D
├─ package.json # Dependencias y metadatos del proyecto
├─ package-lock.json # Archivo de bloqueo de dependencias
```

Fig. 6. Estructura de carpetas

Los trabajos en curso incluyen el perfeccionamiento de las funcionalidades del gemelo digital, la implantación de las funciones para el control de la turbina y la mejora de la experiencia general del usuario. El trabajo que continúa se centrará también en ampliar el sistema para que admita más tipos de cuentas con permisos personalizados, y en seguir optimizando el rendimiento de la plataforma.

V. RESULTADOS

Los resultados obtenidos hasta ahora demuestran un avance significativo hacia los objetivos del proyecto. El mapa interactivo y el carrusel simplifican la gestión del parque eólico al proporcionar una interfaz intuitiva para la navegación y la visualización de datos. La integración de un gemelo digital añade una innovadora capa de interacción que permite a los usuarios simular y controlar directamente los parámetros de las turbinas, simulando al molino real.

La Figura 7 muestra la funcionalidad del carrusel seleccionable, que permite al usuario explorar todas las granjas eólicas asignadas a su perfil. Cada elemento del carrusel corresponde a una granja eólica específica, e incluye información relevante como el nombre, la latitud, la longitud y el porcentaje de rendimiento total del parque eólico. Al hacer clic en la granja visible en el modal, la aplicación realiza automáticamente un zoom en el mapa hacia la ubicación geográfica correspondiente, centrando la vista en el área de interés. Además, sobre el carrusel se encuentra un botón con el símbolo "+" que permite al usuario

añadir nuevas granjas eólicas al sistema, ampliando así las opciones disponibles. Esta interacción facilita tanto la navegación entre granjas como la gestión de nuevas ubicaciones de manera rápida e intuitiva.

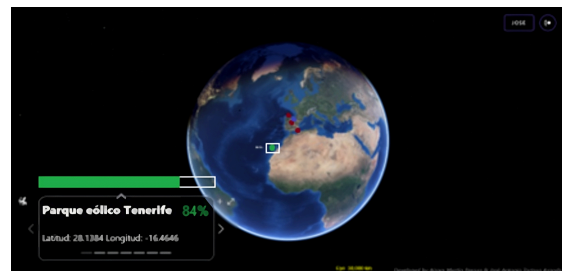


Fig. 7. Carrusel seleccionable para exploración de granjas eólicas

La Figura 7 muestra el mapa interactivo implementado en el sistema, en el que se permite la selección de áreas o puntos específicos directamente sobre el globo terráqueo. Esta funcionalidad utiliza una interfaz intuitiva que permite al usuario interactuar con el mapa mediante clics y gestos, facilitando la localización y selección precisa de regiones geográficas. El mapa está diseñado para representar información en tiempo real y cuenta con herramientas de navegación, como zoom y rotación, para explorar cualquier área del planeta de forma detallada. Esta funcionalidad resulta esencial para definir y monitorizar áreas específicas, como las ubicaciones de granjas eólicas.




Fig. 8. Mapa interactivo

En la Figura 8 se muestra la vista que aparece al hacer clic sobre una granja seleccionada desde el carrusel. En esta vista, la granja eólica se representa mediante un polígono verde que delimita su área en el mapa. Dentro de este polígono, se visualizan los aerogeneradores mediante iconos cuadrados de diferentes colores, los cuales indican el estado actual de cada aerogenerador. El color verde señala que este está en funcionamiento normal, mientras que el azul indica que opera a pleno rendimiento. Por otro lado, el color rojo se utiliza para representar aquellos aerogeneradores que están apagados. Al interactuar con cada aerogenerador se debería mostrar la información de ese aerogenerador en particular, permitiendo acceder a todo su historial y también el acceso al gemelo

digital para evaluar el estado actual de sus subsistemas. Esta parte está actualmente en desarrollo.

VI. CONCLUSIÓN Y FUTURO TRABAJO

En este proyecto se está desarrollando con éxito una plataforma funcional para la gestión de parques eólicos, integrando un mapa interactivo, un carrusel por los parques eólicos y un gemelo digital para la simulación y el control básicos de las turbinas. Estos logros demuestran el potencial de las herramientas basadas en la web para agilizar las operaciones de los parques eólicos y ofrecer una interfaz intuitiva a los usuarios.

Entre las principales aportaciones de la plataforma figuran la mejora de la accesibilidad a los datos de los parques eólicos y la introducción de la tecnología de gemelos digitales en el sector de las energías renovables. A pesar de estos avances, existen varias áreas de desarrollo futuro.

El trabajo futuro se centrará en implementar diferentes tipos de cuentas para permitir distintos niveles de acceso y permisos, como cuentas de sólo visualización. Las funciones avanzadas de control de la turbina se completarán con el desarrollo de puntos finales específicos para acciones como el arranque, la parada o los ajustes automáticos. Se añadirán funciones de visualización de datos en tiempo real para mostrar parámetros como la producción de energía y las condiciones meteorológicas. El gemelo digital se perfeccionará para aumentar su precisión y ampliar sus capacidades de simulación.

Uno de los principales retos fue integrar las bibliotecas WebWorldWind y Spill The Beans Wind, ya que sus distintas estructuras y dependencias exigían una adaptación considerable. Este proceso puso de manifiesto la necesidad de racionalizar las herramientas de terceros para alinearlas con la arquitectura de la plataforma. Además, el diseño estético y la experiencia de usuario actuales deben perfeccionarse para mejorar la usabilidad.

A pesar de estas limitaciones, el proyecto tiene importantes implicaciones prácticas. La plataforma tiene potencial para optimizar las operaciones de los parques eólicos al reducir los tiempos de respuesta y proporcionar acceso centralizado a datos clave. El trabajo futuro se centrará en ampliar los tipos de cuenta con permisos a medida, perfeccionar los controles del gemelo digital e implementar funciones de visualización de datos en tiempo real.

Por último, la integración en el interfaz de análisis predictivos e inteligencia artificial permitirá un mantenimiento proactivo y optimizará el rendimiento de las turbinas.

AGRADECIMIENTOS

Este trabajo está parcialmente financiado por el Ministerio de Ciencia e Innovación, España, con el MICIU/AEI/FEDER proyecto PID2021-123543OB-C21.

REFERENCES

- [1] Zhou, B., Zhang, Z., Li, G., Yang, D., & Santos, M. (2023). Review of key technologies for offshore floating wind power generation. *Energies*, 16(2), 710.
- [2] Digital twin. (n.d.). Wikipedia. Retrieved November 19, 2024, from https://es.wikipedia.org/wiki/Gemelo_digital
- [3] Universidad Complutense de Madrid. (n.d.). Arquitectura Hardware para el Control Remoto de Turbinas Eólicas Offshore. Retrieved November 23, 2024, from <https://docta.ucm.es/entities/publication/96ce92db-a401-48d4-bbf8-54f9408284d9>
- [4] Universidad Complutense de Madrid. (n.d.). Integración de Datos en Tiempo Real y Funcionalidades Interactivas en Sistemas de Monitorización Eólica. Retrieved November 23, 2024, from <https://docta.ucm.es/entities/publication/62cfe208-fec0-42bc-bfd2-57af8c9ec6aa7>
- [5] Dialnet. (2024). Digital Twins and Wind Turbine Monitoring: Challenges and Solutions. Retrieved November 23, 2024, from <https://dialnet.unirioja.es/servlet/articulo?codigo=9537007>
- [6] Universidad Complutense de Madrid. (n.d.). Repositorio de Producción Científica UCM. Retrieved November 23, 2024, from <https://produccioncientifica.ucm.es/documentos/6453edeab5d6a67124357b32>
- [7] NASA WorldWind WebWorldWind. (n.d.). NASA WorldWind. Retrieved November 19, 2024, from <https://worldwind.arc.nasa.gov/>
- [8] Spill the beans. (n.d.). Spill the beans. Retrieved 11 19, 2024, from <https://spillthebeans.beancandesign.com/wind>
- [9] Node.js. (n.d.). Node.js — Run JavaScript Everywhere. Retrieved November 19, 2024, from <https://nodejs.org/en/>
- [10] Express - Node.js. (n.d.). Express - Node.js web application framework. Retrieved November 19, 2024, from <https://expressjs.com/>
- [11] MongoDB. (n.d.). MongoDB. Retrieved 11 19, 2024, from <https://www.mongodb.com/es>
- [12] bcrypt - npm. (2023, August 16). NPM. Retrieved November 19, 2024, from <https://www.npmjs.com/package/bcrypt>
- [13] Pandit, R., Astolfi, D., Hong, J., Infield, D., & Santos, M. (2023). SCADA data for wind turbine data-driven condition/performance monitoring: A review on state-of-art, challenges and future trends. *Wind Engineering*, 47(2), 422-441.
- [14] Alberto Martínez, Matilde Santos and J. Enrique Sierra-García . PIL environment to validate wind turbine IEC61131-based real time controllers on digital twins. Proc. of the 16th APCA International Conference on Automatic Control and Soft Computing. CONTROL 2024, , Porto, Portugal.
- [15] React. (n.d.). React. Retrieved November 19, 2024, from <https://es.react.dev/>
- [16] JSX. (n.d.). JSX. Retrieved 11 19, 2024, from <https://es.reactjs.org/docs/introducing-jsx.html>
- [17] Babel. (n.d.). Babel · Babel. Retrieved November 19, 2024, from <https://babeljs.io/>
- [18] Webpack. (n.d.). webpack. Retrieved 11 19, 2024, from <https://webpack.js.org/>
- [19] Eólica marina flotante ¿qué es y cómo funciona? (n.d.). Iberdrola. Retrieved November 23, 2024, from <https://www.iberdrola.com/innovacion/eolica-marina-flotante>

Classic Optimisation Methodology as an Inverse Problem for Parameter Identification for 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—The primary objective of this work is to introduce a general methodology for effective model parameter identification, a critical step in the control design process. Accurate parameter identification ensures that the dynamic models of FOWTs closely reflect real-world behaviour, enabling the design of robust and efficient control strategies. By comparing the performance of different optimisation algorithms, this study provides insights into the trade-offs between computational efficiency and solution quality, offering guidance on algorithm selection for model parameter identification. As an example of the framework, the effectiveness of three classic optimisation algorithms for model parameter identification is shown for two types of support foundations, the spar-buoy and the barge, both compatible with the 5MW NREL FOWT and equipped with standard TMD.

Index Terms—FOWT, modeling, identification, TMD, structural control

I. INTRODUCTION

Wind energy is part of the renewable energy group, alongside solar power and hydrogen, which are critical to addressing contemporary energy demands. In today's energy market, the primary objectives are to ensure a sufficient and widely accessible energy supply at an affordable cost while simultaneously addressing climate challenges linked to global warming and the depletion of natural resources.

Among renewable energy technologies, offshore wind power, particularly floating offshore wind turbines (FOWTs), presents a highly promising solution to the energy market's challenges. FOWTs are marine-based energy structures that combine the advantages of onshore and fixed offshore wind technologies, including environmental sustainability, cost efficiency, and reliability. Their placement in deep and open waters enables the construction of larger turbines that can generate up to 30% more electricity than traditional offshore wind turbines (OWTs). Furthermore, FOWTs capitalize on offshore wind resources, which are stronger and more consistent than onshore winds. With over 80% of these resources located

in coastal areas where fixed foundations are impractical, FOWTs are uniquely positioned to harness this vast potential effectively [1], [2].

A key control objective in wind energy technology is the maximisation of power production. However, floating offshore wind turbines (FOWTs) face distinct challenges due to their significantly larger size, exposure to harsh environmental conditions, and the absence of fixed foundations. Ensuring structural stability is therefore crucial to addressing these challenges, which stem from the dynamic and unpredictable nature of the marine environment. One widely adopted approach to meet this objective is the implementation of structural control. Structural control is a method used to manage and mitigate the vibrational responses in wind turbines, originally adapted from civil engineering applications [3]–[5]. Among various structural control devices, tuned dampers (TDs) are particularly prominent, with the tuned mass damper (TMD) being a preferred solution for wind turbine applications. A TMD is a mechanical device comprising a mass element, a spring, and a damper, which can be designed to operate in passive, semi-active, or active modes. Passive TMDs are especially favored for their simplicity and independence from external energy sources [6], [7].

To apply any control methodology to meet the objectives of floating offshore wind turbines (FOWTs), it is essential to first develop a mathematical model representing the system under investigation. Such models provide the foundation for implementing and testing control laws. While various modelling approaches are available, reduced-order models are often the most effective for control design. These models focus on the system's dominant dynamics, such as key degrees of freedom (DOFs), and can significantly reduce computational requirements, a critical advantage when dealing with the identification of numerous parameters. Additionally, although the dynamics of FOWTs are inherently nonlinear, linearising these models by treating the structure as rigid can simplify the modelling process and further aid control design.

Within the FOWT research community, system modelling is universally regarded as the first step in any analysis, whether

*This research is 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 project MCI/AEI/FEDER number PID2021-123543OBC21.

the focus is on addressing stability challenges or optimizing power production. For instance, in [8], the authors explored the modelling and parameter tuning of a passive nacelle-based tuned mass damper (TMD) for a 5MW NREL FOWT with an OC3-Hywind spar-buoy foundation. The study analyzed the relationship between spring and damper coefficients and operating regions for power production. Using D'Alembert's principle of inertial forces, the authors derived the equations of motion under the assumption of a rigid tower hinged at the base. The model was reduced to five DOFs, encompassing platform pitch, surge, heave, tower fore-aft bending, and TMD translation. The modelling was further simplified by focusing only on hydro and mooring loads, neglecting contributions from wind and wave forces.

A similar approach was taken in [9], where Kane's equations of motion considered a simple holonomic multibody system, based on Newton's laws, were applied to model a spar-buoy FOWT. This model a fully coupled representation, including external loading, to perform a parametric study on the influence of mass and inertia ratios. In contrast, [10] introduced a comprehensive nonlinear model with 22 DOFs to investigate the impact of misaligned wave and wind loadings, reflecting a more detailed analysis of coupled dynamics. These examples highlight the importance and versatility of system modelling in tackling the complex dynamics and control challenges associated with FOWTs.

This contribution presents a general methodology and an overview of the model identification process for floating offshore wind turbines (FOWTs), using two support foundation types as examples. The focus of the paper is on comparing classical optimisation algorithms to evaluate their effectiveness in achieving accurate parameters of the model in the identification process.

II. MODEL FRAMEWORK

In this paper, the 5MW reference wind turbine developed by the National Renewable Energy Laboratory (NREL) is utilised [11]. This baseline model represents a conventional three-bladed, upwind, variable-speed turbine with blade-pitch-to-feather control [12]. The NREL 5MW wind turbine has served as a benchmark for numerous international research efforts [13]–[19].

The modelling and identification process is performed for both spar and barge support foundations. In order to simplify the highly nonlinear dynamics of the floating offshore wind turbine (FOWT) system, the following assumptions are made [20]:

- The system is approximated as a 3DOFs system consisting of a platform, tower and rotor nacelle assembly with TMD. Dynamics associated with the rotor yaw, generator, or gearbox are neglected.
- The degrees of freedom considered are platform pitch, tower fore-aft bending and TMD translation.
- The tower flexibility is represented by a linear rigid rotating beam hinged at the tower bottom [21].
- Only the contribution of hydro loads is considered.

A. Model Derivation Process

A modeling and identification process is initially carried out for the 5MW NREL wind turbine with the OC3-Hywind spar buoy platform (Fig. 1) [11]. To make the approach more generic, the equations of motion are derived to describe only the structural dynamics of the system, with all external loading forces excluded from the initial derivation. This simplification allows the focus to remain on the inherent structural behaviour, while external loads can be incorporated at later stages of the analysis as needed.

To mathematically model the FOWT system, a set of equations of motion is required to describe both translational and rotational displacements. This can be accomplished through the application of Newtonian, Lagrange's or Hamilton's formulation. Based on Lagrange's approach for a non-conservative system with n generalized coordinates, a dynamic equation of motion for the FOWT with a spar-buoy foundation can be derived as follows [?].

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

$$L = T - V \quad (i = 1, 2, \dots, n) \quad (1)$$

where T refers to the total kinetic energy of the system; V is the total potential energy of the system. L describes the Lagrange operator where Q_i is the generalised non-potential force. T and V for the barge-type floating system can be characterised as the addition of all energies appearing in the multi-body system.

$$T = \frac{1}{2} I_t \dot{\theta}_t^2 + \frac{1}{2} I_p \dot{\theta}_p^2 + \frac{1}{2} m_T \dot{x}_T^2 \quad (2)$$

These are the tower's and platform's kinetic energies due to the rotation of the two of them, θ_t and θ_p , and mass kinetic energy due to the TMD mass translating inside the nacelle, x_T . Similarly, for potential energies, this is a summation of contributions coming from gravitational and restoring forces.

$$V = \frac{1}{2} k_t (\theta_t - \theta_p)^2 + \frac{1}{2} k_T (R_T \sin \theta_t - x_T)^2 + \frac{1}{2} k_p \theta_p^2$$

$$+ m_t g R_t \cos \theta_t - m_p g R_p \cos \theta_p + m_T g R_T \cos \theta_t$$

$$+ m_T g (R_T \sin \theta_t - x_T) \tan \theta_t \quad (3)$$

Moreover, the generalised damping forces can be obtained as follows.

$$\begin{cases} Q_{\theta_t} = -d_t (\dot{\theta}_t - \dot{\theta}_p) - \frac{d_T R_T (R_T \dot{\theta}_t \cos \theta_t - \dot{x}_T)}{\cos \theta_t} \\ Q_{\theta_p} = -d_p (\dot{\theta}_p + \dot{\theta}_t) - d_t (\dot{\theta}_t - \dot{\theta}_p) \\ Q_{x_T} = \frac{d_T (R_T \cos \theta_t \dot{\theta}_t - \dot{x}_T)}{\cos \theta_t} \end{cases} \quad (4)$$

The multi-body elements i.e., platform (barge), tower and TMD are indicated by subscripts p , t and T , respectively. Variables θ and x represent the rotational angular displacement and the translational displacement of the TMD from the vertical axis z , respectively. The equivalent spring stiffness and damping coefficients are described by k and d , respectively. I is the body moment of inertia about the centre of the mass,

R is the distance between the centre of the mass and tower hinge with m being the body's mass.

The completed nonlinear dynamic model of the spar-buoy floating offshore wind turbine is obtained by substitution of equations (2)-(4) into Lagrange's equations (1).

However, there can be a further simplification made to linearise the model. It can be assumed that the pitching of the structure platform never exceeds 10 degrees [19]. Hence the following small angle approximations can be made for the system linearization: $\cos\theta = 1$, $\sin\theta = \theta$, $\tan\theta = \theta$ and $\sec\theta = 1$. This way we obtain the equations is (5).

$$\begin{cases} I_p \ddot{\theta}_p = -d_p \dot{\theta}_p - k_p \theta_p - m_p g R_p \theta_p + k_t \theta_t - k_t - \theta_p \\ \quad + d_t (\dot{\theta}_t - \dot{\theta}_p) \\ I_t \ddot{\theta}_t = m_t g R_t \theta_t - k_t (\theta_t - \theta_p) - d_t (\dot{\theta}_t - \dot{\theta}_p) \\ \quad - m_T g (R_T \sin\theta_t - x_T) - k_T R_T (R_T \theta_t - x_T) \\ \quad - d_T R_T (R_T \dot{\theta}_t - \dot{x}_T) \\ m_T \ddot{x}_T = m_T g \theta_t + k_T (R_T \theta_t - x_T) + d_T (R_T \dot{\theta}_t - \dot{x}_T) \end{cases} \quad (5)$$

In (5), the model parameters are as follows: gravitational acceleration g , platform inertia I_p , mass of the platform rigid body m_p , platform centre of mass R_p , platform flexibility k_p , platform torsion properties d_p , tower inertia I_t , mass of the tower rigid body m_t , tower centre of mass R_t , tower flexibility k_t , tower torsion properties d_t , mass of the TMD inside nacelle m_T , TMD centre of mass R_T , TMD spring coefficient k_T and TMD damping coefficient d_T .

Due to the similar geometry and coupling between elements, the equations of motion describing the barge-type FOWT are identical to the ones for the spar-buoy system, as presented in (5). All the assumptions and simplifications applied to the spar-buoy model remain valid for the barge-type configuration. This allows for a consistent approach in modelling both types of floating offshore wind turbines, with the same mathematical framework and simplified dynamics applicable in each case.

B. Model Identification Process

The model parameter identification is an inverse optimisation problem where the algorithm is asked to fit the model to the desired output data by adjusting the free parameters, similar to the regression task. The choice of the optimisation algorithm together with bounds and constraints is dependent on the available information about the system or process. As an example, in the case of FOWT, it is expected that the parameters' numerical values will be in order of high magnitude due to the nature of the system. We have this knowledge as some model parameters can be taken from the OpenFAST input file. The optimisation algorithms are broadly categorised into two types: derivative-based and derivative-free methods, based on whether or not they require information about the derivative of the objective function. Derivative-based optimisation algorithms rely on the gradient (first derivative) or Hessian (second derivative) of the objective function, e.g., gradient descent, Newton's method, Quasi-Newton methods or

trust region methods. They are commonly used when the objective function is differentiable. On the other hand, derivative-free optimisation algorithms do not require derivatives and are used for optimisation problems where the objective function is non-differentiable, noisy, or expensive to evaluate, e.g., simplex methods, evolutionary algorithms, simulated annealing, particle swarm optimisation (PSO), Bayesian optimisation or Pattern Search (PS).

The concepts of local and global optimisation differ from the previously discussed categorisation of optimisation methods, though they can overlap depending on the problem's nature and the methods employed. Local optimisation focuses on finding the nearest optimum within a specific region of the search space. It assumes a smooth landscape with well-behaved gradients, making derivative-based methods commonly used for such tasks. However, local optimisation is highly sensitive to the initial starting point, which directly influences the solution it converges to. This approach is generally suitable only for problems where finding the global optimum is unnecessary, and identifying the closest solution is sufficient. In contrast, global optimisation aims to identify the best overall solution across the entire search space, even in complex, multimodal landscapes where numerous local optima exist. It is especially well-suited for black-box or combinatorial problems where obtaining the global solution is critical. Global optimisation methods often employ derivative-free approaches or hybrid techniques to effectively escape local optima. These methods are typically more computationally intensive, requiring a higher number of function evaluations and additional resources.

To determine the best approach for a given problem, it is crucial to understand the specific nature and requirements of the application. The relationship between derivative-based/derivative-free and local/global optimisation methods depends heavily on these requirements.

- **Local + Derivative-Based Optimisation:** This combination leverages gradients to achieve quick convergence to the nearest optimum. It is ideal for small-scale, smooth problems where computational speed and efficiency are paramount.
- **Local + Derivative-Free Optimisation:** This method avoids the need for gradients, exploring a region through function evaluations. It is desired for situations where derivatives are unavailable, unreliable, or computationally expensive to obtain.
- **Global + Derivative-Free Optimisation:** This is a powerful combination for tackling complex, multimodal problems, especially those involving noisy or black-box functions. It excels in identifying global optima where the search space has multiple local optima and derivative information is either unavailable or unhelpful.
- **Global + Derivative-Based optimisation:** This combination is rare because derivatives are inherently local in nature.

For the identification of a FOWT model, a standard ap-

proach is to perform system identification using a free decay test. In this test, the platform is initially pitched at 5° , and the objective function is defined as the sum of squared differences between the model tower top displacement (TTD), initially displaced from equilibrium conditions by introducing the mentioned initial pitch angle of 5° , and the tower top displacement in the fore-aft direction (TTDspFA) from the OpenFAST output file. The objective function is given by the following equation:

$$objective = \sum (TTD - TTDspFA)^2 \quad (6)$$

It is a common practice to start with a line search or simplex algorithms. The Nelder-Mead simplex algorithm [22] was applied to identify the remaining parameters i.e., I_p , k_p , d_p , I_t , k_t , d_t , k_T and d_T . The Nelder-Mead simplex algorithm is a derivative-free optimisation method used to minimise an objective function in a multidimensional space. It is particularly well-suited for continuous, non-differentiable, or noisy functions. The algorithm is widely used because it is simple, intuitive, and effective for problems where derivative information is unavailable or unreliable. It is designed for finding local minima, and it may converge to a non-global minimum in multimodal functions. As a comparison, the local derivative-based (SQP) and global derivative-free algorithms (Pattern Search) are also used. Sequential Quadratic Programming (SQP) is a method for solving nonlinear optimisation problems, particularly effective for problems with nonlinear objective functions and constraints, providing a derivative-based approach that utilises both gradient and (optionally) Hessian information. Pattern Search, on the other hand, is used to find the optimum of an objective function by evaluating function values at a series of points defined by a set of patterns. It is typically used for black-box problems where the objective function may be noisy, non-differentiable, or computationally expensive to differentiate.

III. MODEL IDENTIFICATION FRAMEWORK

A. Model with barge-type platform

The model presented in (5) can be used as a mathematical description of the dynamics of the 5MW NREL FOWT with a barge-type platform. Certain parameters can be taken as constant such as barge center of mass $R_p = -0.281\text{m}$ (axis origin $Z= 0$ m), tower center of mass measured from the bottom of the structure (axis origin $Z= 0$ m) $R_t= 64.2$ m, mass of the platform rigid body $m_p= 5452000\text{kg}$ and mass of the tower rigid body $m_t= 697460\text{kg}$ with TMD mass unchanged and $R_T=90.6\text{m}$.

As mentioned earlier, three optimisation algorithms are tested in this experiment. The optimisation tasks are implemented using MATLAB, which is configured to utilize parallel computing across 14 workers with the computational environment based on an Intel Core i9 processor. The simulation setup is kept consistent for all three algorithms to ensure a fair comparison. Specifically, this means that the default settings for each algorithm are used without any

TABLE I
BARGE-TYPE MODEL PARAMETER IDENTIFICATION

Parameters	Nelder-Mead	SQP	Pattern Search
I_p [$\text{kg} \cdot \text{m}^2$]	1.7×10^9	1.99×10^{10}	1.99×10^9
k_p [$\text{kg} \cdot \text{m}^2/\text{s}^2$]	1.5×10^9	1.0×10^9	1.67×10^9
d_p [$\text{kg} \cdot \text{m}^2/\text{s}$]	2.52×10^7	6.0×10^7	4.28×10^7
I_t [$\text{kg} \cdot \text{m}^2$]	1.98×10^9	1.99×10^9	2.41×10^9
k_t [$\text{kg} \cdot \text{m}^2/\text{s}^2$]	1.02×10^{10}	9.99×10^9	1.21×10^{10}
d_t [$\text{kg} \cdot \text{m}^2/\text{s}$]	1.89×10^7	2.0×10^7	2.07×10^7
k_T [$\text{kg} \cdot \text{m}^2/\text{s}^2$]	3.93×10^3	4.19×10^3	4.18×10^3
d_T [$\text{kg} \cdot \text{m}^2/\text{s}$]	1.27×10^4	9.96×10^3	1.06×10^4

modifications. Additionally, the same initial guess for the optimisation parameters is provided to each algorithm, ensuring that the comparison is made under identical starting conditions. Furthermore, no bounds or constraints are applied to the optimisation problem, allowing the algorithms to explore the entire solution space freely. This consistency in setup ensures that the differences observed in the results are solely due to the algorithms themselves and not influenced by variations in the experimental conditions. The initial guesses across all algorithms are selected as follows: $I_p = 2e^9$, $k_p = 1.5e^9$, $d_p = 6e^7$, $I_t = 2.5e^9$, $k_t = 1e^{10}$, $d_t = 2e^7$, $k_T = 4.5e^3$, $d_T = 1.1e^4$. As mentioned previously, the right selection of initial guesses is crucial and it can be based on the prior knowledge of the system, such as the order of magnitude of the parameters, or can be obtained by trial and error through the assessment of the system sensitivity to the parameter changes. Alternatively, if numerical ranges are known, lower and upper bounds of the parameters can be provided instead of supplying initial guesses. However, it is important to highlight that not all algorithms have such functionality e.g., the Nelder-Mead simplex algorithm requires initial guesses rather than parameter constraints whereas, on the other hand as an example, the surrogate optimisation algorithm only needs parameter constraints to proceed. In Table I, the summary of the result of three optimisation algorithms is provided.

B. Model with spar-buoy platform

To further test the effectiveness of the classic optimisation for the inverse problem, the model presented in (5) is modified by the addition of the hydrostatic effects in the platform pitch equation of motion for the spar-buoy (C_{hydro}). The known parameters for spar-buoy are as follows: $g= 9.81\text{m/s}^2$, $R_p= 89.9155\text{m}$, $R_t= 60.5961\text{m}$, $m_p= 7466330\text{kg}$, $m_t= 599718\text{kg}$ with TMD mass $m_T= 40000\text{kg}$ and the centre of the TMD mass $R_T= 80.6\text{m}$. The optimisation set-up remains as discussed above, with initial guesses as follows: $I_p = 4e^{10}$, $k_p = -1e^{10}$, $d_p = 4e^8$, $I_t = 2e^9$, $k_t = 1e^{10}$, $d_t = 1e^9$, $k_T = 1e^4$, $d_T = 8e^4$. The units of these parameters are provided within tables. The results of the spar-buoy model identification are presented in Table II.

IV. DISCUSSION

The effectiveness in solving the optimisation problem for each optimisation algorithm is evaluated based on the selected

TABLE II
SPAR-BUOY MODEL PARAMETER IDENTIFICATION

Parameters	Nelder-Mead	SQP	Pattern Search
I_p [$kg \cdot m^2$]	8.97×10^9	3.99×10^{10}	1.1×10^{11}
k_p [$kg \cdot m^2/s^2$]	-1.1×10^{10}	-1.0×10^{10}	-1.0×10^{10}
d_p [$kg \cdot m^2/s$]	1.35×10^8	4.0×10^8	1.14×10^9
I_t [$kg \cdot m^2$]	3.89×10^9	1.99×10^9	3.06×10^9
k_t [$kg \cdot m^2/s^2$]	1.5×10^{10}	9.99×10^9	1.52×10^{10}
d_t [$kg \cdot m^2/s$]	1.46×10^9	1.33×10^9	9.99×10^8
k_T [$kg \cdot m^2/s^2$]	1.77×10^5	2.51×10^6	9.39×10^5
d_T [$kg \cdot m^2/s$]	6.1×10^5	7.81×10^6	1.43×10^7

TABLE III
PERFORMANCE METRICS OF BARGE-TYPE PARAMETER IDENTIFICATION PROCESS

	Nelder-Mead	SQP	Pattern Search
Iterations	981	17	761
Objective Function	3.7842	851.8524	3.2707
Time [s]	1097.67	172.48	1621.35
Evaluations	16001	273	12177

performance metrics and criteria i.e., convergence speed that is based on the number of iterations, solution quality that is indicated by the final objective function value and robustness assessed based on run time and number of function evaluations. The resultant comparison for barge FOWT is presented in Table III and the same comparison of the performance metrics across selected methods for spar-bouy is summarised in Table IV.

Based on the performance metrics, several conclusions can be drawn regarding the tested optimisation algorithms. Referring to Table III for the barge example i.e., linear, simplified 3DOF model, isolated from environmental factors. The results show that the global derivative-free algorithm (Pattern Search) produces the best results, as evidenced by the lowest final objective function value i.e., 0.7436 for spar and 3.2707 for barge. Furthermore, it requires fewer function evaluations compared to other methods. However, the computational time for Pattern Search, compared to SQP and NM, is the highest due to the extensive global search space exploration. In contrast, the local derivative-free algorithm (Nelder-Mead simplex) performs significantly faster, yielding results that are quite close in quality to the global optimiser. This makes it a more efficient choice when computational time is critical. However, the algorithm requires a higher number of iterations and reaches the solver's maximum function eval-

TABLE IV
PERFORMANCE METRICS OF SPAR-BUOY PARAMETER IDENTIFICATION PROCESS

	Nelder-Mead	SQP	Pattern Search
Iterations	1062	18	801
Objective Function	1.0762	347.9493	0.7436
Time [s]	1072.37	32.07	2294.45
Evaluations	16000	171	12817




Fig. 1. Example output plot for the spar-buoy model with tested algorithms.

uation limit, indicating a higher computational effort within the local search region. The local derivative-based algorithm (SQP) prematurely halts as it identifies a local minimum but cannot further improve the objective function in the gradient's direction. This limitation stems from its reliance on derivative information, which confines the search to a local region and prevents the exploration of potentially better solutions.

A similar performance pattern is observed in the example of the spar-buoy FOWT when considering hydrodynamic contributions, as detailed in Table IV. Once again, the global derivative-free algorithm achieves the best performance, delivering the most optimal results, with lower objective function value and a lower number of evaluations required, compared to NM and SQP methods (Figure 1). The local derivative-free algorithm produces acceptable results with a considerably shorter runtime, making it a practical alternative when computational resources are constrained. The local derivative-based algorithm, however, once again converges prematurely to a local minimum, failing to match the performance of the other methods.

V. CONCLUSIONS

In this work, a modelling framework for parameter identification as an inverse optimisation problem is presented, comparing three different optimisation algorithms. The selection between local derivative-free, local derivative-based, and global derivative-free optimisation algorithms depends on the problem being solved. Local derivative-free optimisation algorithms aim to identify the nearest local optimum. They focus on smaller search spaces and typically offer faster convergence. These methods are best suited for smooth, small-scale problems where finding a global solution is unnecessary. They are particularly advantageous in cases where derivatives are unavailable or unreliable and when computational resources or time are limited. If the objective is to explore the entire solution space and identify the global optimum, global

derivative-free optimisation algorithms are more appropriate. These methods excel at escaping local optima, making them valuable for problems where local optimisation might get trapped in suboptimal regions. Additionally, they are less sensitive to the initial starting point, allowing them to explore diverse regions of the search space effectively. This characteristic makes global derivative-free algorithms especially useful when little or no information about possible solutions is available. Local derivative-based algorithms, on the other hand, require gradient information, which introduces complexity into the identification process. They depend on the problem being smooth and differentiable, and they are sensitive to the initial guess. However, these algorithms are highly mature and leverage gradient information to achieve rapid convergence to a local optimum within a specific region. This makes them highly effective for problems where smoothness can be guaranteed, and local optima suffice.

In the context of FOWTs, local derivative-based optimisation methods are ideal when the system is well-behaved, derivative information is readily available, and a local optimum is sufficient. However, in practical scenarios, derivative information is often unavailable or too complex to derive. When the model is simple, either simplified or linearised, a local derivative-free optimiser can be an effective starting point for the identification process. This approach is computationally efficient, particularly when a global solution is not critical, and a local solution with a higher objective function is acceptable. For complex models, such as highly nonlinear systems, global derivative-free algorithms are typically a better choice. Local optimisers in these cases are more likely to get trapped in local minima, potentially yielding unrealistic solutions. Global optimisers employ advanced algorithms capable of thoroughly exploring the design space, making them better suited for handling function complexity. However, if gradient information becomes available during the process, derivative-based methods can replace derivative-free approaches to enhance efficiency. In instances where the model's smoothness or complexity is unknown, a hybrid methodology offers a practical solution. This two-step approach combines local and global derivative-free optimisers, balancing exploration with computational efficiency. Such hybrid methods ensure robustness in parameter identification tasks. For example, if global optimisers fail to converge due to model complexity, such as discontinuities or abrupt gradient changes, the simplicity of local algorithms can be leveraged to address these limitations. By integrating the strengths of both methods, a mixed-approach methodology provides a flexible and effective optimisation framework.

In conclusion, the choice of an optimisation method for parameter identification depends on several factors i.e., the nature of the system, the availability of derivative information, the complexity of the parameter space, and the computational resources available. Local derivative-free optimisation algorithms are well-suited for small-scale problems where computation time is critical, a close approximation is acceptable, or derivatives are unavailable or unreliable. Global derivative-

free optimisation algorithms, by contrast, are better suited for parameter identification in complex, multimodal landscapes where a global solution is essential. They are particularly advantageous when the objective function is expensive to evaluate or contains multiple local optima, reducing the risk of getting trapped.

REFERENCES

- [1] IEA, "Global energy review 2021," 2021.
- [2] G. W. E. Council, "Floating offshore wind- a global opportunity," 2022.
- [3] B. Spencer and M. K. Sain, "Controlling buildings: a new frontier in feedback," *IEEE Control Systems Magazine*, vol. 17, no. 6, pp. 19–35, 1997.
- [4] H. Adeli and A. Saleh, "Integrated structural/control optimization of large adaptive/smart structures," *International Journal of Solids and Structures*, vol. 35, no. 28-29, pp. 3815–3830, 1998.
- [5] H. Adeli, "Smart structures and building automation in the 21st century," in *International symposium on automation in construction*, vol. 25, 2008, pp. 5–10.
- [6] C.-L. Lee, Y.-T. Chen, L.-L. Chung, and Y.-P. Wang, "Optimal design theories and applications of tuned mass dampers," *Engineering structures*, vol. 28, no. 1, pp. 43–53, 2006.
- [7] C.-C. Lin and J.-F. Wang, "Optimal design and practical considerations of tuned mass dampers for structural control," in *Design Optimization of Active and Passive Structural Control Systems*. IGI global, 2013, pp. 126–149.
- [8] Y. Si, H. R. Karimi, and H. Gao, "Modeling and parameter analysis of the oc3-hywind floating wind turbine with a tuned mass damper in nacelle," *Journal of Applied Mathematics*, vol. 2013, 2013.
- [9] S. Sarkar and B. Fitzgerald, "Vibration control of spar-type floating offshore wind turbine towers using a tuned mass-damper-inerter," *Structural Control and Health Monitoring*, vol. 27, no. 1, p. e2471, 2020.
- [10] B. Fitzgerald, J. McAuliffe, S. Baisthakur, and S. Sarkar, "Enhancing the reliability of floating offshore wind turbine towers subjected to misaligned wind-wave loading using tuned mass damper inerters (tmdis)," *Renewable Energy*, vol. 211, pp. 522–538, 2023.
- [11] J. Jonkman, "Definition of the floating system for phase iv of oc3," National Renewable Energy Lab.(NREL), Golden, CO (United States), Tech. Rep., 2010.
- [12] 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.
- [13] J. M. Jonkman, *Dynamics modeling and loads analysis of an offshore floating wind turbine*. University of Colorado at Boulder, 2007.
- [14] 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.
- [15] 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.
- [16] 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.
- [17] M. A. Lackner and M. A. Rotea, "Passive structural control of offshore wind turbines," *Wind energy*, vol. 14, no. 3, pp. 373–388, 2011.
- [18] M. A. Lackner and M. A. Rotea, "Structural control of floating wind turbines," *Mechatronics*, vol. 21, no. 4, pp. 704–719, 2011.
- [19] 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.
- [20] G. M. Stewart, "Load reduction of floating wind turbines using tuned mass dampers," 2012.
- [21] 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.
- [22] J. C. Lagarias, J. A. Reeds, M. H. Wright, and P. E. Wright, "Convergence properties of the nelder–mead simplex method in low dimensions," *SIAM Journal on optimization*, vol. 9, no. 1, pp. 112–147, 1998.

DetECCIÓN DE ANOMALÍAS EN AEROGENERADORES MEDIANTE UNA RED NEURONAL MLP OPTIMIZADA CON UN ALGORITMO GENÉTICO

D. Coronel
Computer Science Faculty
Complutense University of Madrid
Spain, Madrid
dcoron01@ucm.es

C. Guevara
Quantitative Methods Department
CUNEF University
Spain, Madrid
cesar.guevara@cunef.edu

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

Resumen — La energía eólica es una fuente renovable clave para impulsar la transición hacia sistemas energéticos sostenibles. Sin embargo, se enfrenta a desafíos significativos de operación y mantenimiento (O&M), como fallos en componentes críticos que afectan la eficiencia. Este estudio propone un enfoque híbrido para la detección de anomalías en turbinas eólicas, utilizando una red neuronal perceptrón multicapa (MLP) combinada con un algoritmo genético para optimizar automáticamente sus parámetros. La arquitectura del MLP propuesta consta de tres capas, y la salida determina la clasificación de la señal en normal o anómala. Los parámetros del modelo MLP, como pesos y sesgos, fueron optimizados mediante un algoritmo genético (AG). El estudio se realizó con datos reales de vibración de un aerogenerador recopilados del proyecto Gearbox Reliability Collaborative (GRC) del National Renewable Energy Laboratory (NREL). Los datos provienen de sensores instalados en la caja de engranajes de las turbinas. Estos datos que fueron preprocesados y normalizados para posteriormente ser divididos en un conjunto de entrenamiento y prueba. Los resultados mostraron que el algoritmo logró una precisión global del 70% en la clasificación. Por lo tanto, esta estrategia tiene capacidad para identificar anomalías, especialmente en escenarios críticos para el mantenimiento preventivo. El enfoque propuesto demuestra ser confiable para reducir costes de mantenimiento y mejorar la eficiencia operativa al minimizar falsos positivos.

Keywords— Anomalías, Redes neuronales, Aerogeneradores, Algoritmo genético, Perceptrón multicapa

Abstract— Wind power is a pivotal renewable energy source driving the transition to sustainable energy systems. However, its widespread adoption is hindered by significant operational and maintenance (O&M) challenges, particularly failures in critical components that compromise efficiency. This study introduces a hybrid approach for wind turbine anomaly detection, integrating a multilayer perceptron (MLP) neural network with a genetic algorithm (GA) to optimize its parameters automatically. The MLP architecture comprises three layers, with the output classifying the signal as either normal or anomalous. Parameters such as weights and biases were fine-tuned using the GA to enhance model performance. The analysis utilized real-world vibration data from wind turbine gearboxes, sourced from the Gearbox Reliability Collaborative (GRC) project of the National Renewable Energy Laboratory (NREL). The dataset, collected via sensors installed in the turbine gearbox, underwent preprocessing and normalization before being divided into training and test sets. The proposed algorithm achieved an overall classification accuracy of 70%, demonstrating its ability to detect anomalies effectively, particularly in critical scenarios that support preventive maintenance. The proposed approach proves to be reliable in reducing maintenance costs and improving operational efficiency by minimizing false positives.

Keywords— Anomalies, Neural Networks, Wind Turbines, Genetic Algorithm, Multilayer Perceptron

I. INTRODUCTION

La energía eólica es una de las fuentes renovables más utilizada por todo el mundo. Este tipo de energía destaca por generar electricidad de manera eficiente, segura y sostenible [1]. En los últimos años ha avanzado rápidamente consolidándose como una de las fuentes de energía más utilizadas para reducir las emisiones de gases de efecto invernadero y mitigar el cambio climático [2].

Según la organización internacional Global Wind Energy Council (GWEC) en su informe "Global Offshore Wind Report 2024", ha habido un gran crecimiento en el sector eólico mundial durante el año 2023, con la instalación de 117 GW de nueva capacidad, lo que representa un aumento interanual del 50% respecto a 2022. Este crecimiento involucró a 54 países debido a la construcción de infraestructura eólica. América Latina destaca como la región de mayor crecimiento, con un 21%, impulsado principalmente por Brasil que añadió 4,8 GW a su capacidad instalada. A nivel global los principales mercados fueron China, Estados Unidos, Brasil, Alemania e India, reafirmando el papel fundamental de la energía eólica en la transición hacia sistemas energéticos más sostenibles [3].

A pesar de su madurez tecnológica, la energía eólica se enfrenta a desafíos significativos en sus operaciones y mantenimiento (O&M), que influyen a los costes y eficiencia en la generación de energía. Entre los principales problemas destacan los fallos en componentes críticos como sistemas eléctricos, generadores, palas, cajas de cambios y grupos hidráulicos. Estas fallas pueden reducir la producción del 10% al 15% en turbinas terrestres y hasta en un 25% en instalaciones marinas. Además las averías imprevistas generan pérdidas de hasta un 30%. Estos problemas se agravan debido a la ubicación de las turbinas, sobre todo las marinas, ya que son instaladas en entornos desafiantes como regiones de gran altitud o emplazamientos en alta mar, donde es difícil realizar las labores de mantenimiento [4]. En este escenario la aplicación de redes neuronales y técnicas computacionales avanzadas han demostrado ser herramientas eficaces para abordar problemas complejos [5], [6], [7], [8]. Estas tecnologías inspiran el desarrollo de modelos capaces de detectar anomalías en turbinas eólicas, permitiendo la identificación temprana de fallas.

En este contexto dinámico y complejo, este artículo propone un enfoque basado en dos técnicas de la IA para la detección de anomalías en aerogeneradores. Se utilizan datos de aceleración de vibraciones capturados por dos sensores

situados en los engranajes de la caja de cambios. Estos sensores reflejan el estado operativo del sistema permitiendo identificar patrones asociados a condiciones normales y anormales. Este enfoque combina una red neuronal de propagación hacia adelante (Feedforward Neural Network), específicamente un perceptrón multicapa (MLP), para modelar los patrones de las señales, y un algoritmo genético (AG) que optimiza de forma automática los parámetros del modelo para maximizar la precisión en la detección de anomalías y reducir las tasas de falsos positivos, minimizando mantenimientos innecesarios y costos asociados.

Este documento se estructura de la siguiente manera. En la SECCIÓN II se describen los trabajos relacionados, los cuales sirven como base fundamental para el desarrollo de la propuesta. En la SECCIÓN III se detallan los métodos y materiales empleados para llevar a cabo la investigación. En la SECCIÓN IV se describe la estrategia propuesta. En la SECCIÓN V se presentan los resultados obtenidos y se los compara con otros trabajos relevantes. Por último, en la SECCIÓN VI se exponen las conclusiones derivadas de la investigación y se plantean las posibles direcciones para futuros trabajos.

II. TRABAJOS RELACIONADOS

En esta sección se realizó un análisis bibliográfico de artículos relacionados con fallas en turbinas eólicas. La búsqueda se limitó a artículos publicados en los últimos cinco años, entre 2020 y 2024.

La investigación desarrollada por Dhiman [9], propone un método para la detección de anomalías de la caja de engranaje de turbinas eólicas utilizando máquinas de soporte vectorial gemelas (TWSVM) y umbrales adaptativos. Los datos empleados para esta investigación fueron obtenidos del sistema SCADA de turbinas eólicas en el Reino Unido. Entre las variables que analizaron incluye la temperatura del aceite de la caja de engranajes y de los cojinetes. Los resultados del estudio destacan una precisión del método de hasta el 95.94% con una tasa de fallos no detectados del 2.14% y falsos positivos del 2.11%.

El estudio publicado por Zhu [10], propone un método para la detección de anomalías y la monitorización de la condición de la caja de engranaje de turbinas eólicas. Este investigación combina la memoria a largo plazo, la síntesis difusa, agrupamiento (K-means) y aprendizaje por transferencia. Los datos utilizados para esta investigación provienen de registros históricos de SCADA y CMS de las turbinas No.13 y No.15 de un parque eólico en China. Las variables consideradas para este estudio fueron la temperatura del aceite, la velocidad del generador y la presión del lubricante. Los resultados obtenidos en esta investigación fueron satisfactorios, con una precisión mayor a 90% y errores de predicción (PE) inferiores al 10%.

El artículo publicado por Wang [11] propone un modelo para detectar fallas tempranas en la caja de engranajes de las turbinas eólicas. Este modelo combina mecanismos de autoatención (Transformer) con capas Long Short-Term Memory (LSTM). Los datos aplicados para esta investigación fueron datos SCADA de turbinas eólicas en funcionamiento ubicadas en tres regiones de China. Las variables consideradas en esta investigación fueron la temperatura del cojinete delantero y trasero, la temperatura de la góndola y la del buje. Los resultados del modelo evidenciaron un rendimiento bueno, que alcanzo un coeficiente de determinación del

96.56% y un error porcentual medio absoluto (MAPE) de 1.53%.

Xiang [12] propone un modelo detección de fallos y de monitoreo de condición en turbinas eólicas basado en redes convolucionales (CNN) combinadas con unidades recursivas bidireccionales (BiGRU) y un mecanismo de atención (AM). Este modelo utilizó datos SCADA de una granja eólica en China que incluyen periodos de operación normal y fallos. Las variables aplicadas en modelo fueron la temperatura del cojinete y del aceite de la caja de engranajes. Los resultados obtenidos destacan la efectividad del modelo con un coeficiente de determinación (R^2) del 99.2%.

Por último, el estudio publicado por Zhang [13] propone un método para la detección y diagnóstico de anomalías en turbinas eólicas basado en la integración de autoencoders apilados con supresión de ruido y memoria a corto y largo plazo (LSTM-SDAE) junto con el algoritmo XGBoost. Esta investigación usó datos de SCADA provenientes de una granja eólica situada en el noreste de China. Estos datos incluyeron 25 parámetros esenciales de los componentes claves del aerogenerador. Los resultados demostraron una precisión destacada en la clasificación de anomalías, alcanzando un 91.29%.

III. MÉTODOS Y MATERIALES

En esta sección se detallan los materiales utilizados, la base de datos empleada y los métodos aplicados para el desarrollo del sistema de detección de fallos en este estudio.

1) Materiales

Este estudio se utilizó un conjunto de datos del proyecto Gearbox Reliability Collaborative (GRC) del National Renewable Energy Laboratory (NREL) [14], recopiló mediciones de aceleración vibratoria mediante sensores instalados en la caja de cambio de diversas turbinas eólicas que operaban a una frecuencia de 40 kHz. Los sensores registraron datos en condiciones saludables y con daños. La base de datos comprende un total de 10 conjuntos de datos, cada uno representando una turbina eólica diferente con mediciones de 8 sensores. Cada sensor contiene aproximadamente 2,400,000 registros divididos en categorías de "Healthy" y "Damaged".

Para este estudio se procesaron y analizaron 4,000 registros obtenidos al seleccionar 1,000 registros por sensor en las categorías "Healthy" y "Damaged". Los sensores Ring Gear Radial 6 o'clock y 12 o'clock fueron elegidos por su proximidad física, lo que facilita un análisis detallado de vibraciones y correlaciones mecánicas; esto puede ser clave para identificar anomalías y patrones en las turbinas. La Tabla I proporciona un resumen detallado de los datos empleados en este estudio. Estos datos están organizados según el estado de la turbina, el sensor utilizado y el formato del dato registrado.

TABLE I. DATOS DE VIBRACIÓN DEL AEROGENERADOR

Estado	Sensor Ring Gear Radial	Tipo de dato	Ejemplo	Unidad
Healthy	6 o'clock	Entero 14 decimales	0.31985188105169	m/s ²
Healthy	12 o'clock	Entero 14 decimales	0.03496852062240	m/s ²

Damaged	6 o'clock	Entero	14 decimales	2.54546191442657	m/s ²
Damaged	12 o'clock	Entero	14 decimales	1.05875315601954	m/s ²

La Figura 1 muestra señales de aceleración vibratoria del sensor Ring Gear Radial (6 o'clock) en la caja de cambios del aerogenerador. La Figura 1a) representa condiciones normales en un rango de aproximadamente ± 3 m/s², mientras que la Figura 1b) refleja anomalías o fallas con un rango de aproximadamente ± 8 m/s².

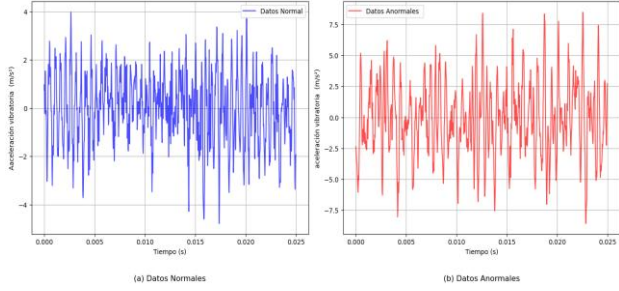


Fig. 1. Comparación de señales de aceleración vibratoria de la caja de cambios de un aerogenerador; condiciones normales (a) y anómalas (b).

2) Métodos

1) *Perceptrón multicapa (MLP)*: Un perceptrón multicapa es un tipo de red neuronal artificial compuesta por múltiples capas de nodos o neuronas organizadas en una arquitectura jerárquica. El MLP es utilizada en problemas de aprendizaje supervisado como clasificación y regresión. La estructura del MLP se compone de una capa de entrada, que actúa como receptor, las capas ocultas que procesan y transforman la información mediante funciones de activación, y la capa de salida que es la responsable de producir la predicción final, ya sea asignando una clase específica de clasificación o estimando valores continuos [10]. La Figura 2 muestra la estructura, componentes y el flujo de información entre las capas de un Perceptrón Multicapa (MLP).




Fig. 2. Estructura de un Perceptrón Multicapa (MLP).

2) *Algoritmo genético (AG)*: El algoritmo genético es una técnica de optimización basada en la selección natural y su proceso es similar la evolución de los seres biológicos, incluyendo mutación, cruce y selección. El algoritmo genético genera nuevas soluciones a partir de una población inicial, donde cada solución individual representada por cromosomas describe una posible respuesta. Las soluciones se evalúan mediante la aplicación de operadores genéticos e iteraciones

sucesivas que buscando converger hacia una solución óptima [11]. La Figura 3 muestra un diagrama de flujo que detalla el proceso y las etapas fundamentales del algoritmo genético.

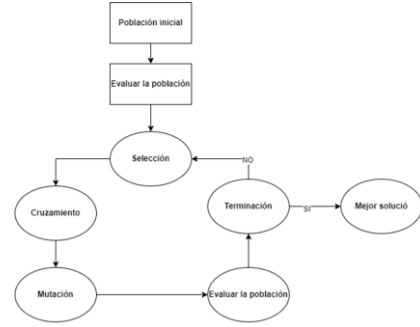


Fig. 3. Diagrama del Algoritmo Genético (AG)

IV. ALGORITMO DE DETECCIÓN DE ANOMALÍAS

El algoritmo de detección de anomalías emplea un modelo de perceptrón multicapa (MLP) diseñado para clasificar datos normales o anómalos, provenientes de los engranajes ring gear radial (6 y 12 o'clock). Este algoritmo utiliza características de vibración como variable principal y optimiza los pesos de la red neuronal mediante algoritmos genéticos. Este algoritmo se dividió en tres fases.

1) Fase 1: Normalización de datos

En esta etapa se lleva a cabo un procesamiento de datos para asegurar su correcta utilización en el modelo de aprendizaje. Específicamente, del conjunto de datos vibración de los engranajes en condiciones normales y anormales se generó un conjunto de datos estructurado como pares, como muestra la ecuación (1).

$$Data = \{(x_i, y_i)\} \quad (1)$$

Donde x_i son los valores numéricos de las señales, y y_i representa las clases que indican si la condición del engranaje es normal ($y = 0$) o anómala ($y = 1$). Esta estructura permite al modelo aprender a distinguir entre las dos condiciones del engranaje.

Adicionalmente, en esta fase se normalizan los datos usando un escalador estándar, como muestra la ecuación (2).

$$\hat{X} = \frac{X - \mu}{\sigma} \quad (2)$$

Donde μ es la media de X y σ la desviación estándar.

Finalmente los datos normalizados se dividen dos conjuntos. El primero con el 80% de los datos para el entrenamiento y el otro 20% para el conjunto de prueba.

2) Fase 2: Algoritmo Genético

El objetivo de esta fase es ajustar los pesos y los sesgos para maximizar la precisión en la clasificación mediante un AG. Para ello se define un individuo con la ecuación (3).

$$\theta = [W_{input-hidden}, W_{hidden-output}, b_{hidden}, b_{output}] \quad (3)$$

Donde $W_{input-hidden}$ es el peso de la entrada de la capa oculta, $W_{hidden-output}$ es el peso de salida de la capa oculta, b_{hidden} es el sesgo de la capa oculta, b_{output} es el sesgo de la capa de salida, y θ es el conjunto de parámetros.

A continuación, inicializamos una población aleatoria de N individuos. Seguidamente cada individuo se evalúa según su desempeño mediante la función de fitness que mide qué tan optima es la solución basándose en la ecuación (4).

$$Fitness(\theta) = \frac{1}{n} \sum_{i=1}^N \prod \prod (\text{argmax}(\hat{y}_i) = \text{argmax}(y_i)) \quad (4)$$

Donde \hat{y}_i es la predicción del modelo, y_i es la etiqueta real de la muestra y \prod es la función que devuelve 1 si la predicción es correcta y 0 en caso contrario.

Posteriormente se aplican operadores genéticos para generar nuevas soluciones a partir de las existentes. Empleando la operación de selección que elige los individuos más aptos de la población actual se aplica luego la operación de cruce, donde se combina dos individuos (padres) para producir uno o más descendientes siguiendo la ecuación (5).

$$\theta_{hijo} = \alpha \theta_{padre1} + (1 - \alpha) \theta_{padre2}, \alpha \in [0,1] \quad (5)$$

Donde θ_{padre1} y θ_{padre2} son los individuos padres seleccionados para el cruce y $\alpha \in [0,1]$ es el factor de mezcla que controla la contribución de cada padre al hijo.

Y la operación de mutación que introduce cambios aleatorios en un individuo para explorar nuevas soluciones conforme a la ecuación (6).

$$\theta' = \theta + N(\mu, \sigma^2) \quad (6)$$

Donde $N(\mu, \sigma^2)$ es el ruido gaussiano con media μ y desviación estándar σ .

Seguidamente, tras aplicar las operaciones genéticas, se genera una nueva población de individuos. Este proceso se repite iterativamente a lo largo de $N = 49$ generaciones en nuestro caso. Finalmente el individuo con el mayor fitness se selecciona como la mejor solución y sus valores de peso y sesgos se aplican al modelo para evaluar su desempeño.

3) Fase 3: Arquitectura de la Red Neuronal

En esta fase el objetivo es crear un modelo capaz de clasificar correctamente las señales normales y anómalas con la red neuronal. Se utiliza la capa de entrada, que recibe como entrada (X) las señales normalizadas, la capa oculta con 10 neuronas para detectar posibles patrones mediante la ecuación (7).

$$H = \tanh(XW_{input\ hidden} + b_{hidden}) \quad (7)$$

Donde la función de activación es \tanh , la tangente hiperbólica, $XW_{input\ hidden}$ son pesos que se conectan a las entradas con las neuronas de la capa oculta, y b_{hidden} son los sesgos asociados a cada neurona en la capa oculta.

Y la capa de salida que genera las predicciones finales del modelo para cada clase, en este caso normal y anómalo, como se indica en la ecuación (8).

$$n_{outputs} = 2 \text{ (normal / anómalo)} \quad (8)$$

Cada neurona combina las salidas de la capa oculta usando pesos y sesgos específicos y luego utiliza la función softmax para convertirlas en probabilidades. Estos peso y sesgos fueron determinados por Algoritmo Genético. Esta estructura

asegura que la red sea capaz de aprender patrones relevantes para clasificar señales como normales o anómalas.

V. RESULTADOS Y DISCUSIÓN

El estudio utilizó un total de 4,000 registros clasificados en las categorías "Healthy" y "Damaged," correspondientes a los sensores Ring Gear Radial 6 o'clock y 12 o'clock. La Tabla II muestra los resultados obtenidos con el algoritmo propuesto.

Las métricas utilizadas son: la precisión, que es la tasa de clasificaciones correctas; el recall o exhaustividad, que mide la proporción de casos positivos identificados correctamente en relación con el total de casos positivos reales. Y el F1-score, que es la media armónica (un tipo de promedio) entre precisión y recall.

TABLE II. RESULTADOS OBTENIDOS

Clase	Precision	Recall	F1-score	Support
Normales	0.83	0.51	0.63	403
Anormales	0.64	0.90	0.75	397

El algoritmo propuesto en la detección de datos normales alcanzó una precisión del 83%, lo que demuestra su capacidad para clasificar correctamente la mayoría de los casos identificados como normales. Sin embargo, el recall fue del 51%, lo que significa que sólo logró identificar un poco más de la mitad de los datos normales presentes en el conjunto de prueba. Por su parte el F1-score que es la media armónica entre precisión y Recall, alcanzo del 63%, lo que indica un desempeño moderado.

En la detección de datos anormales el algoritmo propuesto obtuvo una precisión del 64% clasificando correctamente como anormales una proporción moderada de los casos de prueba. Asimismo, obtuvo un recall del 90%, lo que evidencia una alta capacidad para identificar los datos anómalos existentes. Por último, el F1-score alcanzó un 75%, reflejando un buen equilibrio entre la precisión y sensibilidad en la detección.

La última columna, support, representa la cantidad de datos disponibles para evaluar el rendimiento del modelo para cada categoría del conjunto de pruebas. En este caso, 403 casos corresponden a la clase "normal" y 397 casos corresponden a la clase "anormal", lo que proporciona una base suficiente para calcular las métricas de evaluación del modelo.

La Figura 4 muestra la matriz de confusión del desempeño del algoritmo propuesto en la clasificación de datos normales y anómalos.




Fig. 4. Matriz de confusión

Esta matriz de confusión muestra que el algoritmo de clasificación propuesto realiza clasifica 204 datos como normal y 356 como anomalías. Sin embargo, también se observan errores de 199 datos normales clasificados como anormales y 41 anormales clasificados como normales.

Finalmente, el modelo alcanzó una precisión global del 70%, lo que representa la proporción de predicciones correctas en relación con el total de instancias evaluadas en el conjunto de prueba y una tasa de aprendizaje del 69.09%.

En comparación, el trabajo de Zhang [13] mostró una precisión del 91.29%, aunque sin proporcionar detalles sobre el recall. Los autores del artículo de Dhiman [9] lograron una precisión del 95.94%, pero con una tasa de fallos no detectados del 2.14%, ligeramente menos eficiente en la identificación de anomalías que nuestra propuesta. Aunque la precisión global de nuestro modelo es del 70%, por lo tanto inferior a la conseguida en esos trabajos, su alto recall lo hace especialmente idóneo en contextos donde la detección temprana y completa es prioritaria, lo cual resulta ventajoso en escenarios críticos de seguridad y mantenimiento preventivo. Esta menor precisión podría deberse a la limitada amplitud y variedad del conjunto de datos, así como a la complejidad de las características empleadas. Para mejorar el desempeño, se podrían considerar estrategias como ampliar y diversificar la base de datos, integrar el MLP con arquitecturas más sofisticadas, y aplicar técnicas adicionales de preprocesamiento, extracción de características o aprendizaje por transferencia, con el fin de capturar patrones más complejos y optimizar la capacidad de generalización del modelo.

VI. CONCLUSIONES

En esta investigación se propone un algoritmo para detectar anomalías en turbinas eólicas. El algoritmo combina una red neuronal, específicamente el perceptrón multicapa (MLP), para modelar las relaciones de las señales de vibración de una turbina. La red neuronal ha sido optimizada con un algoritmo genético que ajusta los parámetros del modelo.

La integración del algoritmo genético elimina la necesidad de realizar ajustes manuales de los hiperparámetros de peso, sesgo, y configuraciones de la red neuronal. Esto no solo reduce el tiempo de desarrollo, sino que también minimiza errores humanos permitiendo obtener configuraciones óptimas que mejoran el rendimiento general del modelo.

El algoritmo propuesto puede escalarse fácilmente para manejar datos de múltiples sensores o para adaptarse a nuevas configuraciones de las turbinas mediante el reentrenamiento del MLP con nuevas señales.

Aunque el algoritmo es confiable, como trabajos futuros podría mejorarse mediante la incorporación de técnicas adicionales de preprocesamiento de datos para mejorar la calidad de las señales de entrada, la evaluación de otras configuraciones de algoritmos evolutivos o híbridos, y el uso de redes neuronales más avanzadas, como redes recurrentes (RNN) o modelos basados en transformers, para capturar dependencias temporales en las señales.


ACKNOWLEDGMENT


This work was partially supported by the Spanish Ministry of Science, Innovation and Universities under MICIU/AEI/FEDER Project no. PID2021-123543OB-C21.


REFERENCES


- [1] P. B. Dao, T. Barszcz, and W. J. Staszewski, "Anomaly detection of wind turbines based on stationarity analysis of SCADA data," *Renew Energy*, vol. 232, p. 121076, Oct. 2024, doi: 10.1016/J.RENENE.2024.121076.
- [2] S. Lee, "Wind Energy Program in Republic of Korea: Present and Future BT - The Age of Wind Energy: Progress and Future Directions from a Global Perspective," pp. 283–292, 2020, Accessed: Nov. 23, 2024. [Online]. Available: https://doi.org/10.1007/978-3-030-26446-8_14
- [3] GWEC – Global Wind Energy Council, "GWEC - Consejo Mundial de Energía Eólica," 2023. Accessed: Nov. 16, 2023. [Online]. Available: <https://gvec.net/>
- [4] M. Beretta, J. J. Cárdenas, C. Koch, and J. Cusidó, "Wind fleet generator fault detection via SCADA alarms and autoencoders," *Applied Sciences (Switzerland)*, 2020, doi: 10.3390/app10238649.
- [5] D. Coronel, C. Guevara, and M. Santos, "Autoencoder Neural Networks for Anomaly Detection in Wind Turbines," 2025, pp. 279–289. doi: 10.1007/978-3-031-75010-6_28.
- [6] D. Coronel, C. Guevara, and M. Santos, "Anomaly Detection in the Uniaxial Vibration in Wind Turbines Applying Linear Regression and Z-score," *World Scientific Proceedings Series on Computer Engineering and Information Science*, 2024, doi: 10.1142/9789811294631_0022.
- [7] I. Garrido et al., "A Machine-Learning Approach for Prognosis of Oscillating Water Column Wave Generators," in *Proceedings - 27th International Conference on Circuits, Systems, Communications and Computers, CSCC 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 1–7. doi: 10.1109/CSCC58962.2023.00009.
- [8] F. M'zoughi, J. Lekube, A. J. Garrido, M. De La Sen, and I. Garrido, "Machine learning-based diagnosis in wave power plants for cost reduction using real measured experimental data: Mutriku Wave Power Plant," *Ocean Engineering*, vol. 293, Feb. 2024, doi: 10.1016/j.oceaneng.2023.116619.
- [9] H. Dhiman, D. Deb, S. M. Muyeen, and I. Kamwa, "Wind Turbine Gearbox Anomaly Detection Based on Adaptive Threshold and Twin Support Vector Machines," *IEEE Transactions on Energy Conversion*, 2021, doi: 10.1109/TEC.2021.3075897.
- [10] Y. Zhu, C. Zhu, J. Tan, Y. Tan, and L. Rao, "Anomaly detection and condition monitoring of wind turbine gearbox based on LSTM-FS and transfer learning," *Renew Energy*, 2022, doi: 10.1016/j.renene.2022.02.061.
- [11] Z. Wang et al., "Early anomaly detection of wind turbine gearbox based on SLFormer neural network," *Ocean Engineering*, 2024, doi: 10.1016/j.oceaneng.2024.118925.
- [12] L. Xiang, X. Yang, A. Hu, H. Su, and P. Wang, "Condition monitoring and anomaly detection of wind turbine based on cascaded and bidirectional deep learning networks," *Appl Energy*, 2022, doi: 10.1016/j.apenergy.2021.117925.
- [13] C. Zhang, D. Hu, and T. Yang, "Anomaly detection and diagnosis for wind turbines using long short-term memory-based stacked denoising autoencoders and XGBoost," *Reliab Eng Syst Saf*, vol. 222, Jun. 2022, doi: 10.1016/j.res.2022.108445.
- [14] National Renewable Energy Laboratory., "Wind Turbine Gearbox Condition Monitoring Vibration Analysis Benchmarking Datasets," 2024, doi: <https://dx.doi.org/10.25984/1844194>.


Quantification of power losses due to wake effect and yaw misalignment in a simulated wind farm

Lucia Garcia-Lado
dept. of Digitalization
University of Burgos
Burgos, Spain
lglado@ubu.es 

Samuel Martinez-Gutierrez
dept. of Digitalization
University of Burgos
Burgos, Spain
samuel.martinez@ubu.es 

Alejandro Merino-Gomez
dept. of Digitalization
University of Burgos
Burgos, Spain
alejandromg@ubu.es 

Daniel Sarabia-Ortiz
dept. of Digitalization
University of Burgos
Burgos, Spain
dsarabia@ubu.es 

Ruben Ruiz-Gonzalez
dept. of Digitalization
University of Burgos
Burgos, Spain
ruben.ruiz@ubu.es 

Abstract—When studying power generation in wind farms, both wake effect and yaw misalignment are limiting factors which significantly reduce the maximum power that can be generated. Indeed, these two factors interact one with another due to how wake effect is related to misalignment of the turbines. This article focuses on the quantification of these effects for a particular wind farm topology, using a simulation environment based on physical and mathematical models based on first principles. In order to accomplish this objective, all combinations of wind speeds (0 – 30 m/s, resolution: 0.5 m/s) and directions (0 – 360°, resolution: 1°) were simulated and the generated power in stationary state was calculated. Firstly, wake effect was analyzed separately by using for each combination data that meet the condition of having zero yaw misalignment for all turbines. Secondly, the effect of yaw misalignment was studied, comparing the maximum achievable power for each possible angle of misalignment with respect to the perfectly-aligned condition. Results showed that the topology of the turbines that make up the wind farm has a significant effect on how much power can be generated for each direction, observing how for the least favored direction the achievable power is almost half of the power for the most favored direction for slow wind speeds (5 m/s). By its part, yaw misalignment can produce a loss of around 10% for slow wind speeds too, being another important source of power loss when all turbines are misaligned.

Index Terms—modeling and simulation of wind farms, control of renewable energy resources, wake effect, yaw misalignment

Resumen—Al estudiar la generación de energía en parques eólicos, tanto el efecto sombra como el desalineamiento de orientación son factores limitantes que reducen significativamente la potencia máxima que se puede generar. De hecho, estos dos factores interactúan entre sí debido a cómo el efecto de estela se relaciona con el desalineamiento de las turbinas. Este artículo se centra en la cuantificación de estos efectos para una topología particular de un parque eólico, utilizando un entorno de simulación basado en modelos físicos y matemáticos basados en primeros principios. Para lograr este objetivo, se simularon todas las combinaciones de velocidades del viento (0 – 30 m/s, resolución: 0,5 m/s) y direcciones (0 – 360°, resolución: 1°) y se

midió la potencia generada en estado estacionario. En primer lugar, el efecto sombra se analizó por separado utilizando para cada combinación datos que cumplieran la condición de tener un desalineamiento nulo para todas las turbinas. En segundo lugar, se estudió el efecto del desalineamiento, comparando la potencia máxima alcanzable para cada posible ángulo de desalineamiento con respecto a la condición de alineación perfecta. Los resultados mostraron que la topología de las turbinas que componen el parque eólico tiene un efecto significativo en la cantidad de energía que se puede generar para cada dirección, observándose cómo para la dirección menos favorecida la potencia alcanzable es casi la mitad de la potencia para la dirección más favorecida, para velocidades de viento lentas (5 m/s). Por su parte, el desalineamiento puede producir una pérdida de alrededor del 10% también para velocidades de viento lentas, siendo otra fuente importante de pérdida de energía cuando todas las turbinas están desalineadas.

Palabras clave—modelado y simulación de parques eólicos, ingeniería de control para fuentes de energía renovables, efecto sombra, desalineamiento en la orientación

I. INTRODUCCIÓN

La predicción del agotamiento de los combustibles fósiles en un futuro próximo, unido al hecho del impacto negativo de su uso sobre el cambio climático y los ecosistemas, es una preocupación importante [1] que lleva actuando en las últimas décadas como fuerza motriz de la investigación y avances en busca de fuentes de energía renovables y menos contaminantes [2]. Dentro de éstas, la energía eólica aparece como una fuente fiable y muy extendida en la actualidad, con un despliegue incrementándose año tras año [3]. Este crecimiento se ha alcanzado mediante el diseño y construcción de parques eólicos formados por turbinas de alta potencia. Estos parques deben cooperar con otras plantas generadoras de electricidad para conseguir cumplir las demandas de los usuarios de la red eléctrica [4].

La generación de energía eólica presenta retos operativos debido a la alta variabilidad e incertidumbre del viento [5], tales como las dificultades en predecir la potencia que es

posible generar. Además, otros factores relacionados con la demanda eléctrica y la producción de otras fuentes de energía también entran en juego [6] y, como consecuencia, la gestión a alto nivel de los parques eólicos requiere para su operación óptima el uso de técnicas de optimización y modelos de simulación.

Dentro de este contexto, la generación de modelos precisos pero a su vez con una carga computacional reducida es crucial de cara a poder realizar predicciones rápidas que permitan tomar decisiones óptimas en tiempo real. La definición de modelos rigurosos y suficientemente precisos, pero sin necesidad de recurrir a simulaciones basadas en CFD y FEM, es, por tanto, una necesidad dentro de este contexto [7], [8].

Otro de los aspectos críticos dentro de la producción eléctrica de un parque eólico son las pérdidas producidas por el efecto sombra [9] y el desalineamiento de las turbinas con respecto a la dirección del viento [10]. Ambos aspectos son abordados y analizados en este trabajo. Además, aunque no es el foco de este trabajo y se deja como línea futura, ambos efectos tienen una relación entre sí, como se ha mostrado en la literatura previamente [11].

El presente trabajo analiza el comportamiento de un parque eólico concreto mediante un simulador de desarrollo propio. En particular, se analiza el impacto que tiene el efecto sombra sobre la potencia máxima producible ante diferentes condiciones del parque, así como el impacto que tiene en la potencia producida por el parque cuando se produce un desalineamiento de las turbinas del parque con respecto a la orientación del viento.

El resto del artículo se organiza de la siguiente manera. En la sección II se explica el modelo y parque eólico empleado, así como las simulaciones llevadas a cabo para estudiar el impacto del efecto sombra y desalineamiento. En la sección III se muestran y discuten los resultados obtenidos siguiendo la metodología descrita en la sección previa. Finalmente, en la sección IV se sintetizan las conclusiones extraídas del trabajo desarrollado.

II. MATERIALES Y MÉTODOS

La subsección II-A se centra en explicar el simulador propuesto, así como la topología del parque eólico bajo estudio. Las subsecciones II-B y II-C se centran en explicar el concepto del desalineamiento en la orientación de las turbinas y del efecto sombra, respectivamente, así como en explicar cómo se ha modelado dentro del simulador propuesto. Finalmente, la subsección II-D detalla metodológicamente cómo se ha llevado a cabo el estudio de pérdidas de potencia sufridas por el parque eólico debido a estos fenómenos.

A. Simulador de parques eólicos y datos del parque bajo estudio

El parque eólico estudiado es un parque ficticio, pero cuya topología se corresponde exactamente con la de un parque real (El Valle-ValdeNavarro) situado en Navarra, España. El parque simulado está formado por 14 turbinas, todas ellas consideradas de tipo NREL 5MW y parametrizadas de acuerdo

a los valores propuestos por Jonkman et al. [12] y resumidos en la Tabla I. Las turbinas consideradas operan a velocidad variable del rotor, actuando sobre el par electromagnético para extraer la máxima potencia y también limitan la potencia extraída a su valor nominal, actuando sobre el ángulo de pitch de las palas (β) cuando la velocidad del viento es elevada. La topología del parque se puede observar en la Fig. 1.

TABLA I
RESUMEN DE CARACTERÍSTICAS DE LAS TURBINAS NREL 5MW
EMPLEADAS EN EL SIMULADOR USADO EN ESTE TRABAJO.

Rating	5 MW
Rotor Orientation, Configuration	Upwind, 3 Blades
Control	Variable Speed, Collective Pitch
Drivetrain	High Speed, Multiple-Stage Gearbox (1:97)
Radius	63 m
Hub Diameter	3 m
Hub Height	90 m
Cut-In, Rated, Cut-Out Wind Speed	3 m/s, 11.4 m/s, 25 m/s
Cut-In, Rated Rotor Speed	6.9 rpm, 12.1 rpm
Rated generator speed	1173.7 rpm
Rated generator torque	43093.55 Nm
Rotor Mass	110,000 kg
Nacelle Mass	240,000 kg
Tower Mass	347,460 kg
Rotor Inertia	$3.544 \cdot 10^7 \text{ kg m}^2$
Generator Inertia	534.116 kg m^2
Electric Generator Efficiency	0.944




Fig. 1. Topología del parque eólico bajo estudio. Posición relativa de cada una de las 14 turbinas que constituyen el parque.

El simulador empleado en este artículo ha sido programado usando la herramienta de simulación y modelado dinámico de sistemas EcosimPro [13] e incluye el modelo de la turbina, los sistemas de control de velocidad de giro del rotor, control de potencia y de alineamiento al viento, así como la secuencia automática de parada cuando bien no hay suficiente viento, o el que hay es excesivo, además de su posterior arranque automático una vez que los valores de la velocidad del viento son los adecuados.

La turbina eólica ha sido modelada como un sistema de dos masas: una correspondiente a la sección de baja velocidad (palas y rotor) girando a ω_r y la otra asociada a la sección de alta velocidad (generador) girando a ω_g , incluyendo además el efecto de torsión entre ellas [14]. En cuanto a la potencia aerodinámica, se ha modelado de la manera habitual (1).

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

Donde ρ es la densidad del aire, R el radio de las palas, v la velocidad del viento y $C_p(\lambda, \beta)$ es el coeficiente de potencia que depende de la relación de velocidad punta ($\lambda = \omega_r R/v$) y el ángulo de pitch de las palas (β) y que se ha modelado como una función exponencial (2) y (3) de acuerdo al modelo de Heir de 1998, explicado en [15].

$$C_p(\lambda, \beta) = C_1(C_2/\lambda_i - C_3\beta - C_4\beta^{C_5} - C_6)e^{-C_7/\lambda_i} \quad (2)$$

$$\frac{1}{\lambda_i} = \left(\frac{1}{\lambda + C_8\beta} \right) - \left(\frac{C_9}{\beta^3 + 1} \right) \quad (3)$$

B. Modelo de desalineamiento de orientación de turbinas en el simulador

En el simulador empleado, se han contemplado las pérdidas de desalineamiento como la proyección del viento que incide de manera perpendicular a las palas de las turbinas, es decir, multiplicar la velocidad del viento incidente medida v_m por el coseno del ángulo formado por la dirección del viento d_m y la orientación de la turbina $\theta(t)$, (4).

$$v = v_m \cos(\delta(t)) = v_m \cos(d_m - \theta(t)) \quad (4)$$

De esta manera, la velocidad v en (1) se ve disminuida por el efecto del desalineamiento, reduciéndose, por tanto, la potencia producida.

Además, para incluir la dinámica de la orientación de la turbina $\theta(t)$ al viento, se ha modelado el servomecanismo de orientación como un sistema de primer orden (5) con una constante de tiempo τ_o , activándose dicho mecanismo sólo cuando el error de orientación absoluto, $|d_m - \theta(t)|$, es mayor que 10° .

$$\tau_o \frac{d\theta(t)}{dt} = d_m - \theta(t) \quad (5)$$

C. Modelo de efecto sombra en el simulador

El efecto sombra es un fenómeno por el cual las turbinas situadas detrás de otras respecto al frente de viento reducen su capacidad de producir energía debido a la pérdida de energía y aumento de las turbulencias que experimenta el viento cuando atraviesa una turbina. Se puede encontrar una revisión de este fenómeno en [16].

En el simulador se ha incorporado la versión más sencilla de este efecto, llamado modelo de Jensen para múltiples sombras o modelo de Katic [17] cuyo desarrollo para sombras parciales puede encontrarse en [18] y [9].

Si la turbina i -ésima recibe una velocidad v_0 sin perturbar y genera una sombra parcial (y no total) sobre otra turbina j , la velocidad efectiva sobre la turbina j será v_{ij} (6).

$$v_{ij} = v_0 \left(1 - \left(1 - \sqrt{1 - C_T} \right) \left(\frac{r_i}{r_i(x_{ij})} \right)^2 \frac{A_{sh,i}}{A_j} \right) \quad (6)$$

Donde C_T es el coeficiente de empuje, $A_{sh,i}$ es el área de sombra de solape del aerogenerador i sobre el j , A_j es el área de barrido de las aspas del aerogenerador j , $r_i(x_{ij})$ es el radio de la estela de la turbina i a la altura de la turbina j (afectada por la sombra) que puede calcularse mediante la expresión dada en (7) que representa la propagación de la sombra como un cono dependiente del coeficiente de disminución de estela k y del radio de la turbina i , r_i .

$$r_i(x_{ij}) = r_i + kx_{ij} \quad (7)$$

El área de solape de cualquier turbina i delante de la turbina j se calcularía como:

- Si el área de barrido está completamente fuera del área de sombra, o la turbina i está parada, entonces $A_{sh,i} = 0$.
- Si el área de barrido está completamente contenida dentro del área de sombra y la turbina i está en marcha, entonces $A_{sh,i} = A_j$.
- Si el área de barrido está parcialmente contenida dentro del área de sombra y la turbina i está en marcha entonces, $A_{sh,i}$ se calcula como la superficie común en la Fig. 2.




Fig. 2. Esquema de la sombra parcial $A_{sh,i}$ que genera una turbina i sobre otra j situada detrás.

Finalmente, una turbina j puede estar afectada por sombras de múltiples turbinas situadas delante de ella, en este caso se ha asumido que el déficit de energía cinética en la turbina j debido a una mezcla de sombras respecto del viento sin perturbar v_0 , es igual a la suma de los déficits de energía cinética en la turbina j debido a cada sombra individual del resto de turbinas i respecto del viento sin perturbar v_0 , tal y como se muestra en (8).

$$(v_0 - v_j)^2 = (v_0 - v_{1j})^2 + (v_0 - v_{2j})^2 + \dots = \sum_{i=1}^n (v_0 - v_{ij})^2 \quad (8)$$

Sustituyendo (6) en (8) se puede despejar la velocidad del viento v_j para una turbina j afectada por varias estelas de otras turbinas i , (9).

$$v_j = v_0 \left(1 - \sqrt{\sum_{i=1}^n (1 - \sqrt{1 - C_T})^2 \left(\frac{r_i}{r_i(x_{ij})} \right)^4 \left(\frac{A_{sh,i}}{A_j} \right)^2} \right) \quad (9)$$

Este modelo simplista no es del todo preciso y se está trabajando en incorporar un modelo más realista a la hora de modelar este fenómeno, así como incorporar su efecto en la dirección del cono de sombra que produce una turbina en el resto de las turbinas del parque.

D. Cuantificación de pérdidas de potencia por efecto sombra y desalineamiento

Para poder cuantificar las pérdidas de potencia debidas al efecto sombra, así como por el desalineamiento de las turbinas con respecto a la dirección del viento, en este trabajo se han analizado ambos efectos de manera aislada en el entorno de simulación anteriormente comentado en la subsección II-A.

Con el objetivo de poder explorar el comportamiento del parque en todas las diferentes direcciones y velocidades del viento, se generaron datos sintéticos cubriendo todas las posibles combinaciones de velocidades de viento (0 – 30 m/s, resolución de 0.5 m/s) y direcciones de viento (0 – 360°, resolución de 1°). Se ha dejado en las simulaciones un tiempo suficiente (10 minutos) entre saltos para garantizar que siempre se alcance el régimen estacionario. Para no tener ninguna limitación de potencia en el parque, se ha fijado el setpoint del mismo a 75 MW, por encima de la potencia nominal del parque (70 MW).

De cara a poder estudiar el impacto del efecto sombra en el parque, se analizaron los datos a diferentes velocidades de viento (5, 10 y 15 m/s) para todas las direcciones de incidencia del viento.

De cara a poder estudiar el impacto del desalineamiento en la orientación de las turbinas en el parque, se analizaron los datos para diferentes ángulos de desalineamiento entre turbina y dirección del viento (0°, 5° y 10°) para todas las direcciones de incidencia del viento y para diferentes velocidades de viento (5, 10 y 15 m/s). Hay que recordar que el sistema de orientación de las turbinas se activa cuando el error de orientación es mayor que 10°, pero para errores más pequeños,

las turbinas pueden mantenerse desorientadas durante períodos largos de tiempo.

III. RESULTADOS Y DISCUSIÓN

En esta sección se analizan tanto las pérdidas de potencia debidas al efecto sombra (subsección III-A) como por desalineamiento de las turbinas (subsección III-B).

A. Pérdidas de potencia por efecto sombra

Como se puede observar en la Fig. 3, Fig. 4 y Fig. 5, la potencia generada para las diferentes direcciones no es la misma para velocidades de viento bajas y moderadas, poniendo de relieve la influencia del efecto sombra en la topología del parque seleccionada. Este mismo efecto se observa con independencia del desalineamiento de las turbinas con respecto a la dirección del viento. No obstante, para velocidades de viento por encima de 15 m/s, el efecto sombra deja de influir en la potencia generada, obteniéndose el mismo valor para cualquier dirección de viento, exactamente la potencia nominal del parque 70 MW ($7 \cdot 10^7$ W). Esto se debe a que la curva de potencia de las turbinas utilizadas alcanza su valor nominal a una velocidad de viento de 11.4 m/s. Es decir, la turbina genera su máxima potencia a partir de esa velocidad. Por lo tanto, cuando el viento alcanza los 15 m/s, las posibles pérdidas causadas por las sombras quedan compensadas gracias al sistema de control de potencia de las turbinas, que mantiene la generación en el valor de potencia nominal.




Fig. 3. Diagrama circular con la potencia generada por el parque para distintas velocidades de viento para todas las posibles direcciones del viento, con alineamiento perfecto en la orientación de las turbinas respecto a la dirección del viento.

Comparando para velocidades de viento moderadas (5 y 10 m/s), la diferencia porcentual entre la dirección del viento en la que más potencia con respecto de aquella dirección en la que menos potencia se genera, es de un 45% y 14%, respectivamente. Esto indica que el efecto sombra es mucho más acusado a bajas velocidades del viento y, a medida que la velocidad del viento aumenta, su efecto se aprecia de manera menos notable. Este efecto se explica porque, a bajas




Fig. 4. Diagrama circular con la potencia generada por el parque para distintas velocidades de viento para todas las posibles direcciones del viento, con desalineamiento de 5° en la orientación de las turbinas con respecto a la dirección del viento.




Fig. 5. Diagrama circular con la potencia generada por el parque para distintas velocidades de viento para todas las posibles direcciones del viento, con desalineamiento de 10° en la orientación de las turbinas con respecto a la dirección del viento.

velocidades de viento, el efecto sombra reduce la velocidad efectiva del viento que incide sobre algunas turbinas, llegando a ser inferior a la velocidad de corte (*cut-in*). Como resultado, estas turbinas se detienen, lo que provoca una disminución significativa en la potencia generada por el parque eólico.

De acuerdo a la topología del parque mostrada en la Fig. 1 las direcciones del viento de 315° y de 135° son en las que más efecto sombra se produce, dado que en esa dirección se alinean el mayor número de turbinas que en otras direcciones. Dicho resultado se pone de manifiesto en la potencia producida mostrada para esas direcciones en la Fig. 6 y Fig. 7. Además, puede observarse cómo, para el modelo de sombras utilizado, existe simetría en las potencias generadas entre una dirección y su opuesta a 180°.

B. Pérdidas de potencia por desalineamiento

Como se puede observar en la Fig. 6 y Fig. 7, la potencia generada se reduce a medida que aumenta el desalineamiento entre las turbinas y la dirección del viento, poniendo de relieve el impacto significativo de este efecto.

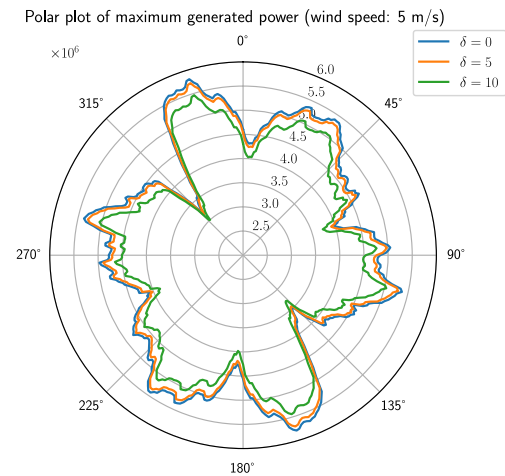


Fig. 6. Diagrama circular con la potencia generada por el parque para distintos ángulos de desalineamiento para todas las posibles direcciones del viento, con una velocidad de viento de 5 m/s.

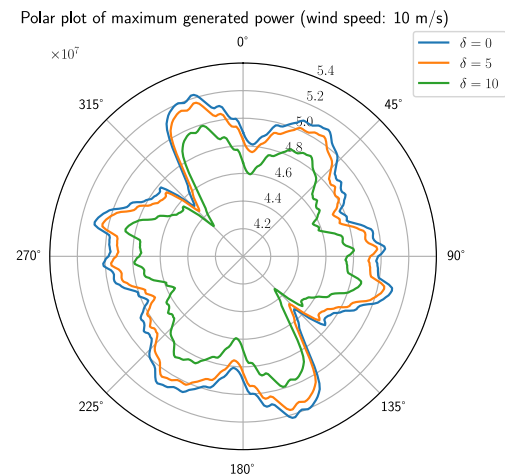


Fig. 7. Diagrama circular con la potencia generada por el parque para distintos ángulos de desalineamiento para todas las posibles direcciones del viento, con una velocidad de viento de 10 m/s.

Nuevamente, al igual que sucedía con el efecto sombra, este efecto se observa únicamente para velocidades del viento bajas y moderadas (5 y 10 m/s), siendo imperceptible para velocidades superiores a 15 m/s (Fig. 8). En concreto, cuando el desalineamiento es de 10°, se aprecian unas pérdidas de potencia estables cercanas al 8% para velocidades de 5 m/s, mientras que las pérdidas rondan el 5% para la velocidad de viento de 10 m/s. Para este caso son válidas las mismas justificaciones realizadas para el caso de las pérdidas de

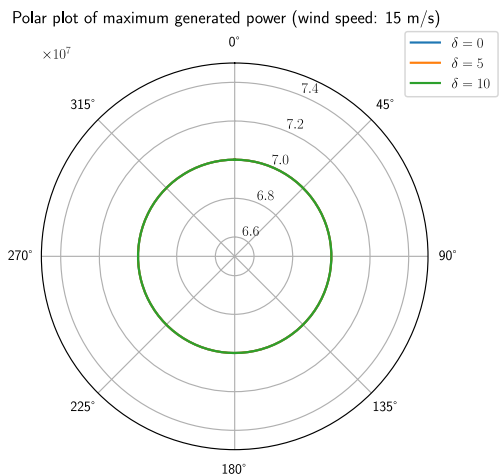


Fig. 8. Diagrama circular con la potencia generada por el parque para distintos ángulos de desalineamiento para todas las posibles direcciones del viento, con una velocidad de viento de 15 m/s.

potencia debidas al efecto sombra, relacionadas con el trabajar por encima de la velocidad de viento nominal o por debajo de la potencia *cut-in*.

El efecto del desalineamiento es mucho menos acusado para desalineamientos de 5°, donde se observan pérdidas de potencia estables cercanas al 2% para velocidades de 5 m/s, mientras que las pérdidas rondan el 1% para la velocidad de viento de 10 m/s.

IV. CONCLUSIONES

Como se puede observar en los resultados, las pérdidas por efecto sombra en un parque eólico son apreciables para velocidades de viento moderadas, siendo despreciable su efecto a altas velocidades de viento. Sucede lo mismo con respecto al desalineamiento de las turbinas. Comparativamente, el efecto del desalineamiento de las turbinas tiene un efecto menos significativo en las pérdidas con respecto al efecto sombra, aunque su impacto es uniforme para todas las direcciones del viento, mientras que el impacto del efecto sombra aparece principalmente en direcciones del viento muy concretas. En trabajos futuros se plantea abordar la modificación del modelo de sombras para contemplar un modelo más realista en el que el desalineamiento de las turbinas modifica las sombras producidas.

AGRADECIMIENTOS

The paper is part of the project ‘Optimal real-time management under uncertainty for digital twins (OptiDit)’, PID2021-123654OB-C33, funded by MCIN and by the European Union ‘FEDER’.

REFERENCES

[1] M. Höök and X. Tang, “Depletion of fossil fuels and anthropogenic climate change—A review,” *Energy Policy*, vol. 52, pp. 797–809, 2013. Special Section: Transition Pathways to a Low Carbon Economy.

[2] T.-Z. Ang, M. Salem, M. Kamarol, H. S. Das, M. A. Nazari, and N. Prabakaran, “A comprehensive study of renewable energy sources: Classifications, challenges and suggestions,” *Energy Strategy Reviews*, vol. 43, p. 100939, 2022.

[3] J. K. Kaldellis, “Overview of wind turbines time evolution,” in *Encyclopedia of Electrical and Electronic Power Engineering* (J. García, ed.), pp. 388–412, Oxford: Elsevier, 2023.

[4] X. Kan, L. Reichenberg, and F. Hedenus, “The impacts of the electricity demand pattern on electricity system cost and the electricity supply mix: A comprehensive modeling analysis for Europe,” *Energy*, vol. 235, p. 121329, 2021.

[5] X.-Y. Ma, Y.-Z. Sun, and H.-L. Fang, “Scenario generation of wind power based on statistical uncertainty and variability,” *IEEE Transactions on Sustainable Energy*, vol. 4, pp. 894–904, Oct 2013.

[6] P. S. Moura and A. T. de Almeida, “The role of demand-side management in the grid integration of wind power,” *Applied Energy*, vol. 87, no. 8, pp. 2581–2588, 2010.

[7] H. Dong, J. Xie, and X. Zhao, “Wind farm control technologies: from classical control to reinforcement learning,” *Progress in Energy*, vol. 4, no. 3, p. 032006, 2022.

[8] S. Boersma, B. M. Doekemeijer, P. M. O. Gebraad, P. A. Fleming, J. Annoni, A. K. Scholbrock, J. A. Frederik, and J.-W. van Wingerden, “A tutorial on control-oriented modeling and control of wind farms,” in *Proceedings of the 2017 American Control Conference (ACC)*, pp. 1–18, 2017.

[9] F. González-Longatt, P. Wall, and V. Terzija, “Wake effect in wind farm performance: Steady-state and dynamic behavior,” *Renewable Energy*, vol. 39, no. 1, pp. 329–338, 2012.

[10] M. T. van Dijk, J.-W. van Wingerden, T. Ashuri, Y. Li, and M. A. Rotea, “Yaw-misalignment and its impact on wind turbine loads and wind farm power output,” *Journal of Physics: Conference Series*, vol. 753, p. 062013, sep 2016.

[11] D. van der Hoek, S. Kanev, J. Allin, D. Bieniek, and N. Mittelmeier, “Effects of axial induction control on wind farm energy production - A field test,” *Renewable Energy*, vol. 140, pp. 994–1003, 2019.

[12] 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*, 2009.

[13] E. A. Internacional, “EcosimPro – Modelling and simulation software.” <https://www.ecosimpro.com/products/ecosimpro/>, Sep 2024.

[14] B. Boukhezzer, L. Lupu, H. Siguerdidjane, and M. Hand, “Multivariable control strategy for variable speed, variable pitch wind turbines,” *Renewable Energy*, vol. 32, no. 8, pp. 1273–1287, 2007.

[15] T. Ackermann, *Wind Power in Power Systems*. John Wiley & Sons, 2005.

[16] F. Porté-Agel, M. Bastankhah, and S. Shamsoddin, “Wind-turbine and wind-farm flows: A review,” *Boundary-Layer Meteorology*, vol. 174, no. 1, pp. 1–59, 2020.

[17] I. Katic, J. Højstrup, and N. Jensen, “A simple model for cluster efficiency,” in *EWEC’86. Proceedings* (P. W. and S. E., eds.), vol. 1, pp. 407–410, 1987.

[18] R. Shakoob, M. Y. Hassan, A. Raheem, and Y. K. Wu, “Wake effect modeling: A review of wind farm layout optimization using Jensen’s model,” *Sustainable Energy Reviews*, vol. 58, pp. 1048–1059, 2016.

Estabilización de Voltaje y Energía Compartida en Microrredes Aisladas

Tahereh Bagheri Rouch
Automatic Control Group-ACG,
Department of Automatic Control and
Systems Engineering,
Faculty of Engineering of Bilbao, The
University of the Basque Country-
UPV/EHU
Bilbao, Spain
tahereh.bagheri@ehu.eus

Fares Mzoughi
Automatic Control Group-ACG,
Department of Automatic Control and
Systems Engineering,
Faculty of Engineering of Bilbao, The
University of the Basque Country-
UPV/EHU
Bilbao, Spain
fares.mzoughi@ehu.eus

Payam Aboutalebi
Automatic Control Group-ACG,
Department of Automatic Control and
Systems Engineering,
Faculty of Engineering of Bilbao, The
University of the Basque Country-
UPV/EHU
Bilbao, Spain
payam.aboutalebi@ehu.eus

Irfan Ahmad
Automatic Control Group-ACG,
Department of Automatic Control and
Systems Engineering,
Faculty of Engineering of Bilbao, The
University of the Basque Country-
UPV/EHU
Bilbao, Spain
irfanahmad.irfan@ehu.eus

Aitor J. Garrido
Automatic Control Group-ACG,
Department of Automatic Control and
Systems Engineering,
Faculty of Engineering of Bilbao, The
University of the Basque Country-
UPV/EHU
Bilbao, Spain
aitor.garrido@ehu.eus

Izaskun Garrido
Automatic Control Group-ACG,
Department of Automatic Control and
Systems Engineering,
Faculty of Engineering of Bilbao, The
University of the Basque Country-
UPV/EHU
Bilbao, Spain
Izaskun.garrido@ehu.eus

Abstract—This article proposes an optimized control strategy for islanded DC microgrids, incorporating a voltage controller based on mixed H_2/H_∞ state feedback with linear matrix inequalities (LMI) and a power controller that follows droop characteristics. A polytopic modeling approach is used to address the system's uncertainties and nonlinearities. The controller is designed to stabilize the system, mitigate disturbances, evenly distribute power among distributed generation units (DGUs), and reduce energy consumption. Simulation results highlight the controller's ability to effectively manage load fluctuations and DGU disconnections, with a comparative analysis against a H_∞ controller providing additional insights into system performance.

Keywords—DC islanded microgrids, voltage controller, power controller, distributed generation units, polytopic approach

Resumen—Este artículo propone una estrategia de control optimizada para microrredes de CC aisladas, que incorpora un controlador de voltaje basado en retroalimentación de estado mixta H_2/H_∞ con desigualdades matriciales lineales (LMI) y un controlador de potencia que sigue las características de caída de tensión. Se utiliza un método de modelado politópico para abordar las incertidumbres y no linealidades del sistema. El controlador está diseñado para estabilizar el sistema, mitigar las perturbaciones, distribuir de manera equitativa la potencia entre las unidades de generación distribuida (DGUs) y reducir el consumo de energía. Los resultados de simulación destacan la capacidad del controlador para gestionar de manera efectiva las fluctuaciones de carga y las desconexiones de DGUs, con un análisis comparativo frente a un controlador H_∞ que proporciona más información sobre el rendimiento del sistema.

Keywords—Microrredes aisladas de CC, controlador de voltaje, controlador de potencia, unidades de generación distribuida, enfoque politópico

I. INTRODUCCIÓN

Las energías renovables y los sistemas de generación distribuida, como la eólica, mareomotriz y solar, han ganado atención como alternativas sostenibles a las fuentes tradicionales, proporcionando energía limpia y abundante para reducir las emisiones y mitigar el cambio climático. Sin embargo, la intermitencia de la producción energética representa desafíos para la estabilidad de la red [1]. Los sistemas de almacenamiento de energía en baterías (BESS) se utilizan para suavizar las fluctuaciones, almacenando energía excedente y liberándola durante períodos de alta demanda o baja producción [2]. Su integración mejora la estabilidad de la red y acelera la transición hacia un sistema energético más limpio [3]. Las microrredes permiten un control y distribución localizados, optimizando el uso de recursos renovables según las condiciones y demanda [4]. Los sistemas de almacenamiento integrados almacenan energía renovable excedente para su uso posterior, mejorando la fiabilidad y resiliencia [5]. Tecnologías avanzadas de gestión optimizan el flujo de energía, reduciendo costos [6]. Un desafío clave en microrredes aisladas es mantener la estabilidad y gestionar perturbaciones [7]. En [8], se utiliza un enfoque de desigualdades matriciales lineales para un control LQR robusto en un convertidor buck con incertidumbres en la carga. En [9], se diseñó un controlador robusto descentralizado para gestionar el voltaje en una microrred de CC con un convertidor boost, enfrentando demandas variables e incertidumbres, basado en control deslizante de orden superior. En [10], se propone un controlador no lineal robusto con superficie deslizante y PWM para abordar inestabilidades de impedancia negativa en sistemas de convertidores. En [11], se simplifica la gestión de voltaje y distribución de potencia en convertidores CC/CC a un sistema único aplicable en modos centralizados o descentralizados. En [12], se usa LMI para diseñar un control

robusto para un convertidor boost considerando un politopo convexo. En [13], se introduce un controlador H_2/H_∞ con LMI para una microrred aislada con tres DGUs, integrando control de voltaje robusto mixto H_2/H_∞ y control de potencia basado en droop, modelado mediante politopos para manejar dinámicas inciertas. El objetivo principal es garantizar robustez frente a perturbaciones de carga y desconexiones de DGUs, al tiempo que se optimizan los esfuerzos de control. Para evaluar su desempeño, se examinan dos escenarios y se realiza una comparación con un controlador robusto H_∞ en términos de mitigación de perturbaciones de carga y respuesta ante la desconexión de DGUs. Este trabajo presenta un modelo politópico para una microrred con múltiples DGUs, adapta un enfoque multimodelo para abordar numerosos parámetros indeterminados del sistema, y resuelve desafíos de optimización multiobjetivo integrando métricas H_∞ y H_2 para mitigar incertidumbres, minimizar el esfuerzo de control y garantizar una distribución adecuada de potencia entre las DGUs.

La estructura del artículo comienza con la presentación del modelo dinámico de la microrred en la Sección II, seguida por una explicación detallada de los principios de diseño del controlador propuesto en la Sección III. La Sección IV detalla el diseño y la comparación del controlador propuesto con un controlador robusto H_∞ , mientras que la Sección V presenta los resultados de simulación. Finalmente, la Sección VI ofrece las conclusiones.

II. PRESENTACIÓN MATEMÁTICA DE UNA MICRORRED AUTÓNOMA

Este artículo presenta una microrred con tres DGUs idénticas, cada una con una fuente de voltaje de corriente continua (CC), un convertidor de fuente de voltaje (VSC) y una carga desconocida en la Fig. 1. La Fig. 2 muestra una señal PWM de frecuencia fija que regula la señal binaria (U_b) para activar o desactivar el interruptor, con frecuencia de conmutación $1/T_s$. Las no linealidades del modelo del convertidor introducen incertidumbres, lo que requiere un control robusto. El sistema se lineariza mediante la técnica de promediado en espacio de estados [12].




Fig. 1. Diagrama Esquemático de un Circuito DGU

A. Enfoque de Linealización en Espacio de Estados

El circuito convertidor elevador DC-DC mostrado en la Fig. 2 opera en dos modos según el estado de U_b . La señal binaria, controlada por la modulación por ancho de pulso (PWM) de frecuencia fija, activa o desactiva el interruptor. El

primer modo ocurre cuando el interruptor está encendido o $U_b = 1$, mientras que el segundo modo ocurre cuando el interruptor está apagado o $U_b = 0$. Los convertidores utilizan el ciclo de trabajo para lograr el control por retroalimentación de voltaje o corriente.

La Ecuación (1) describe la relación entre el tiempo de encendido (T_{on}) y la duración total del ciclo (T_s). El ciclo de trabajo (D_D) está compuesto por un término de corriente continua (D_d) y una pequeña fluctuación de corriente alterna (d_d) alrededor del punto de operación.

La ecuación $v_o = V_g/(1 - D)$ muestra la relación entre el voltaje de entrada (V_g) y el voltaje de salida (v_o), donde D es el ciclo de trabajo. Considerando los modos del convertidor y la Ecuación (1), el modelo promedio en espacio de estados del sistema puede representarse como la Ecuación (2).




Fig. 2. Diagrama del Circuito de Convertidor Boost DC-DC

$$D = \frac{T_{on}}{T_s} = \frac{T_{on}}{T_{on} + T_{off}} \quad (1)$$

Donde T_s , T_{on} y T_{off} son el período de conmutación, el tiempo de encendido y el tiempo de apagado, respectivamente.

$$\begin{cases} \begin{pmatrix} \dot{i}_L \\ \dot{v}_o \end{pmatrix} = \begin{pmatrix} 0 & -(1 - D_d) \\ \frac{(1 - D_d)}{C} & \frac{L}{RC} \end{pmatrix} \begin{pmatrix} i_L \\ v_o \end{pmatrix} \\ + \begin{pmatrix} \frac{V_g}{L(1 - D_d)} \\ -\frac{V_g}{(1 - D_d)^2 RC} \end{pmatrix} d_d \\ y = (0 \quad 1) \begin{pmatrix} i_L \\ v_o \end{pmatrix} \end{cases} \quad (2)$$

El vector de estado $x = [i_L \ v_o]^T$ incluye la corriente del inductor (i_L) y el voltaje de salida (v_o). La señal de entrada $u = [d_d]$ controla el convertidor, y la salida es $y = [v_o]$. El punto de operación es D_D , el voltaje de entrada es V_g . R , L , y C representan la resistencia, inductancia y capacitancia del convertidor elevador.

B. Modelos de Espacio de Estados Indeterminado y Politépicos

El comportamiento dinámico de un sistema se describe con un modelo de espacio de estados, que puede involucrar parámetros indeterminados o variar con el tiempo [14]. Este modelo incierto representa un sistema multimodelo de forma politópica, donde el parámetro $1 - D_d$ se reemplaza por D'_d . Los parámetros inciertos están limitados dentro de un rango específico, formando una caja paramétrica con 2^N vértices, donde N es el número de parámetros indeterminados dentro de los intervalos definidos [15-17]. δ es un parámetro que representa el rango inverso de D' and β es un parámetro que representa el rango inverso de D'^2 and R. Donde $R \in [R_{\min}, R_{\max}]$, $D'_d \in [D'_{d\min}, D'_{d\max}]$, $\delta \in \left[\frac{1}{D'_{d\max}}, \frac{1}{D'_{d\min}} \right]$, and $\beta \in \left[\frac{1}{D'_{d\max}{}^2 R_{\max}}, \frac{1}{D'_{d\min}{}^2 R_{\min}} \right]$.

Por lo tanto, las transiciones multimodelo del sistema abarcan 16 modelos distintos en espacio de estados. El objetivo del modelo incierto es determinar una ganancia de retroalimentación de estado K ($u = Kx$) que mantenga de manera efectiva la incertidumbre dentro de los intervalos predefinidos.

III. MARCO TEÓRICO EL DISEÑO DEL CONTROLADOR

Este artículo profundiza en los métodos de control robusto empleados en la gestión de una microrred de CC aislada, utilizando un controlador de retroalimentación de estado que integra las características H_2 y H_∞ , facilitado por la técnica de las LMIs.

A. Síntesis de Realimentación de Estado Multiobjetivo

Las especificaciones de diseño para control incluyen estabilidad robusta, rechazo de perturbaciones y rendimiento de seguimiento, abordados mediante algoritmos de optimización. La síntesis multiobjetivo resuelve las limitaciones de los controladores H_2 y H_∞ , combinando sus rendimientos con especificaciones de colocación de polos usando LMI. El sistema de lazo cerrado se representa con la retroalimentación de estado $u=Kx$ en la ecuación (3).

$$\begin{cases} \dot{x} = (A + B_2K)x + B_1w \\ z_\infty = (C_1 + D_{12}K)x + D_{11}w \\ z_2 = (C_2 + D_{22}K)x \end{cases} \quad (3)$$

Donde x es el vector de estado y w es una perturbación externa que consiste en perturbaciones externas, ruido de medición e incertidumbres del modelo. La salida z_∞ está limitada por el controlador H_∞ y z_2 está restringida por el controlador H_2 .

B. Rendimiento H_∞

La función de transferencia de w a z_∞ en el sistema en lazo cerrado alcanzará estabilidad y una norma infinita menor que γ solo si las LMIs en la ecuación (4) son factibles. Esta formulación LMI comprende una matriz simétrica X_{cl} , una matriz identidad (I) con las dimensiones adecuadas, y un valor positivo definido γ [15-18].

$$\begin{cases} \begin{pmatrix} M_{11} & B_1 & M_{13} \\ B_1^T & -I & D_{11}^T \\ (C_1 + D_{12}K)X_{cl} & D_{11} & -\gamma^2 I \end{pmatrix} < 0 \\ X_{cl} = X_{cl}^T > 0 \end{cases} \quad (4)$$

Donde $M_{11} = (A + B_2K)X_{cl} + X_{cl}(A + B_2K)^T$ and $M_{13} = X_{cl}(C_1 + D_{12}K)^T$.

C. Rendimiento H_2

La estabilidad del sistema en bucle cerrado y la restricción de la función de transferencia de w a z_2 a un valor menor que v están garantizadas solo si la condición descrita en la LMI (5) es factible. Es importante destacar que tanto X_{cl} como Q son matrices simétricas, y se garantiza un valor definido positivo para v ($v > 0$) [15-18].

$$\begin{cases} \begin{pmatrix} (A + B_2K)X_{cl} + X_{cl}(A + B_2K)^T & B_1 \\ B_1^T & -I \end{pmatrix} < 0 \\ \begin{pmatrix} Q & (C_2 + D_{22}K)X_{cl} \\ X_{cl}(C_2 + D_{22}K)^T & X_{cl} \end{pmatrix} > 0 \\ Trace(Q) < v^2 \\ X_{cl} = X_{cl}^T > 0 \end{cases} \quad (5)$$

D. Controlador de Retroalimentación de Estado Mixto H_2/H_∞

El controlador K integra las metodologías de control H_2 y H_∞ . La resolución del problema de minimización se facilita mediante el uso del toolbox LMI de MATLAB.

$$\begin{cases} \begin{pmatrix} N_{11} & B_1 & X_{cl}C_1^T + Y^T D_{12}^T \\ B_1^T & -I & D_{11}^T \\ C_1 X_{cl} + D_{12} Y & D_{11} & -\gamma^2 I \end{pmatrix} < 0 \\ \begin{pmatrix} Q & C_2 X_{cl} + D_{22} Y \\ X_{cl} C_2^T + Y^T D_{22}^T & X_{cl} \end{pmatrix} > 0 \\ Trace(Q) < v_0^2 \\ \gamma^2 < \gamma_0^2 \end{cases} \quad (6)$$

Donde $N_{11} = AX_{cl} + X_{cl}A^T + B_2Y + Y^T B_2^T$.

Debido al término no lineal X_{cl} en las ecuaciones (4) y (5), se requiere un cambio de variable $Y := KX_{cl}$. La viabilidad de las LMI en (6) depende de un problema de optimización, minimizando $\alpha\gamma^2 + \beta\text{Tr}(Q)$ con respecto a X_{cl} , Q, Y y γ^2 , cumpliendo con la formulación de LMI del problema de retroalimentación de estado multiobjetivo [18]. Además, para asegurar un buen rendimiento, se utiliza un método de estado integral en el diseño del controlador, que ajusta el parámetro óptimo minimizando el error.

IV. ESTRATEGIA DE DISEÑO DEL CONTROLADOR

Esta sección presenta un enfoque de control dual para una microrred autónoma de CC: un controlador de voltaje optimizado por LMI y un controlador de potencia basado en caída de tensión (droop). Se incluye un controlador robusto para un análisis comparativo con la solución propuesta.

A. Diseño de Controlador de Voltaje de Retroalimentación de Estado H_2/H_∞ Multi-modelo

El controlador de voltaje es un controlador H_2/H_∞ multimodelo, diseñado con el enfoque LMI y restricciones en la ubicación de polos. Se introduce un nuevo estado, x_3 , como la integral de la discrepancia entre la referencia V_{ref} y el voltaje de salida v_o , mejorando la funcionalidad del controlador. El desempeño z_∞ se asigna al voltaje de salida, y z_2 se introduce para minimizar el esfuerzo de control, resumido en la ecuación (7).

B. Controlador de Distribución de Potencia

La unidad de control de distribución de potencia está diseñada para distribuir equitativamente la potencia entre las DGUs aprovechando sus características de caída de tensión. Para garantizar una distribución efectiva de la potencia, la fluctuación de voltaje se limita dentro de un rango definido, lo que se logra seleccionando cuidadosamente el coeficiente de caída adecuado [19].

$$\begin{cases} \begin{pmatrix} \dot{i}_L \\ \dot{v}_o \\ \dot{x}_3 \end{pmatrix} = \begin{pmatrix} 0 & \frac{-(1-D_d)}{L} & 0 \\ (1-D_d) & \frac{-1}{RC} & 0 \\ \frac{C}{0} & \frac{-1}{RC} & 0 \end{pmatrix} \begin{pmatrix} i_L \\ v_o \\ x_3 \end{pmatrix} \\ + \begin{pmatrix} 0 & 0 \\ \frac{-1}{C} & 0 \\ 0 & 1 \end{pmatrix} w + \begin{pmatrix} \frac{V_g}{L(1-D_d)} \\ \frac{-V_g}{(1-D_d)^2 RC} \\ 0 \end{pmatrix} d_d \end{cases} \quad (7)$$

$$\begin{aligned} z_\infty &= v_o \\ z_2 &= u \end{aligned}$$

C. Controlador de Distribución de Potencia

La unidad de control distribuye la potencia equitativamente entre las DGUs, limitando la fluctuación de voltaje dentro de un rango definido al seleccionar un coeficiente de caída adecuado [19].

D. Evaluación con la Técnica H_∞

La eficacia del controlador propuesto, comparado con un H_∞ de [12], muestra una norma H_∞ inferior a 2.89, reduciendo perturbaciones en el voltaje de salida. Sus parámetros se detallan en la ecuación (8).

$$K = [-0.2837 \quad -0.2891 \quad 86.5211] \quad (8)$$

V. RESULTADOS DE SIMULACIÓN

Esta sección presenta los resultados de la simulación para el controlador propuesto implementado en una microrred de CC con tres DGUs. Se investigan dos escenarios, la perturbación de carga y la desconexión de DGUs, para ilustrar el rendimiento del controlador bajo diferentes condiciones de operación. Las simulaciones se realizan utilizando MATLAB/Simulink, con los parámetros de la microrred de CC listados en la TABLA I.

A. Análisis de Perturbación de Carga

En este escenario, evaluamos el controlador propuesto frente a perturbaciones de carga: un aumento de 5Ω a 12Ω en $t=0.2s$ y una disminución a 8Ω en $t=0.4s$. La Fig. 3 muestra cómo el controlador mitiga rápidamente las variaciones de voltaje, logrando que el error de seguimiento converja a cero. Se observa una distribución uniforme de potencia entre las tres DGUs en la Fig. 4(a), y la Fig. 4(b) muestra la potencia de una unidad. El control de la señal, representado en la Fig. 5(a), se mantiene dentro del rango permitido. La frecuencia de esta señal de control se mide utilizando el bloque de Fase Bloqueada (PLL), con la frecuencia mostrada en la Fig. 5(b) siendo notablemente más baja que la frecuencia de conmutación del convertidor (200 kHz).

TABLA I. PARÁMETROS DE MICRORRED

Nombre del parámetro	Símbolo del parámetro	Valor del parámetro
Inductancia	L	310 μ H
Capacitancia	C	600 μ F
Carga	R	[10 – 50] Ω
Ensi3n del bus DC	V_{ref}	24 V
Potencia nominal por cada DG	P	[11.52 – 57.6] W
Frecuencia portadora PWM	F_s	200 kHz
ensi3n del bus DC	V_{dc}	24 V
Resistencia de línea	R_t	0.05 Ω
Inductancia de línea	L_t	1.8 μ H
Punto de operaci3n del convertidor	D'_d	[0.3 – 1]
Coefficiente de ca3da	R_{Droop}	0.001
Frecuencia de corte del filtro pasa-bajos	ω_c	10 rad/s
Constante de tiempo del convertidor	T_s	5 μ s




Fig. 3. Escenario de perturbaci3n de carga: (a) voltaje de carga, (b) voltaje de salida de DGU1




Fig. 4. Escenario de perturbación de carga: (a) potencia total y potencia de las DGUs

Para evaluar el rendimiento del controlador, se calcularon el Error Cuadrático Medio (RMSE) y el Error Cuadrático (QE). El RMSE considera solo la señal de error, mientras que el QE incluye el error de voltaje y el esfuerzo de control, ofreciendo una evaluación más completa. Ambos se calculan mediante las ecuaciones (9) y (10).




Fig. 5. Escenario de perturbación de carga: (a) señal de control de DG, (b) frecuencia de la señal de control

$$\text{RMSE} = \sqrt{\frac{1}{T} \int_0^T (E^2(t)) dt} \quad (9)$$

$$\text{QE} = \int_0^T (E^2(t) + U^2(t)) dt \quad (10)$$

Los resultados de la TABLA II muestran que el controlador H_2/H_∞ tiene un RMSE menor (0.00071) y un QE más bajo (0.1826) en comparación con el controlador H_∞ (RMSE: 0.001462, QE: 0.208), indicando una estabilización más rápida y un menor esfuerzo de control.

TABLA II. ÍNDICE NUMÉRICO PARA EL ESCENARIO DE PERTURBACIÓN DE CARGA

Índice numérico	H_2/H_∞	H_∞
RMSE	0.00071	0.001462
QE	0.1826	0.208

B. Desconexión de una Unidad de Generación Distribuida

Un controlador robusto para una microrred autónoma debe gestionar situaciones críticas, como la desconexión de una unidad. En la Fig. 6, a los 0.2 s, DG3 se desconecta, causando una desviación inicial del voltaje, pero el controlador propuesto compensa rápidamente, con DG1 y DG2 asumiendo la carga. La Fig. 7 muestra las variaciones de potencia de las tres DGUs, evidenciando que, tras la desconexión de DG3, DG1 y DG2 incrementan sus potencias para satisfacer la demanda de carga.

En la Fig. 8, el controlador regula eficazmente la microrred aislada de CC con una señal de control implementable (a), manteniendo la frecuencia (b) muy por debajo de la de conmutación del convertidor. La Tabla I muestra la constante de tiempo del convertidor ($5 \mu\text{s}$) y la frecuencia de la señal de control ($\sim 39,3 \text{ Hz}$). La TABLA III muestra índices numéricos que evidencian una estabilización más rápida con menor esfuerzo de control.




Fig. 6. Escenario de desconexión de DGU: (a) voltaje de carga, (b) voltaje de salida de DG1




Fig. 7. Escenario de desconexión de DGU: (a) potencia total y potencia de los DGUs




Fig. 8. Escenario de desconexión de DGU: (a) Señal de control de DGU, (b) Frecuencia de la señal de control

TABLA III. ÍNDICE NUMÉRICO PARA EL ESCENARIO DE DESCONEXIÓN DE DGU

Índice numérico	H_2/H_∞	H_∞
RMSE	0.002326	0.003643
QE	0.09526	0.1101

VI. CONCLUSION

El artículo propone un controlador robusto óptimo para una microrred de CC aislada basado en un modelo politópico. Combina un controlador de caída de potencia y un controlador H_2/H_∞ multimedillo optimizado con desigualdades matriciales lineales. Las simulaciones muestran que supera al controlador H_2/H_∞ en perturbaciones de carga y desconexión de DGUs, destacando su excelente desempeño en 16 casos del modelo.

AGRADECIMIENTOS

Los autores desean agradecer al Gobierno Vasco por financiar parcialmente su trabajo de investigación a través de la subvención IT1555-22. Agradecen también al MICIU/AEI/10.13039/501100011033 y al FEDER/UE por financiar parcialmente su trabajo de investigación mediante las subvenciones PID2021-123543OB-C21 y PID2021-123543OB-C22, así como a través de la beca predoctoral PRE2022-101853, financiada por el MICIU/AEI/10.13039/501100011033 y por el FSE+.

REFERENCIAS

[1] García AM, Gallagher J, Díaz JA, McNabola A. An economic and environmental optimization model for sizing a hybrid renewable energy and battery storage system in off-grid farms. *Renewable Energy*. 2024 Jan 1;220:119588.

[2] Bulut M, Özcan E. How to build a state-of-the-art battery energy storage market? Challenges, opportunities, and future directions. *Journal of Energy Storage*. 2024 May 1;86:111174.

[3] Razif AS, Ab Aziz NF, Ab Kadir MZ, Kamil K. Accelerating energy transition through battery energy storage systems deployment: A review on current status, potential and challenges in Malaysia. *Energy Strategy Reviews*. 2024 Mar 1;52:101346.

[4] Basati A, Bazmohammadi N, Guerrero JM, Vasquez JC. Real-time estimation in cyber attack detection and mitigation framework for dc microgrids. In 2023 23rd International Scientific Conference on Electric Power Engineering (EPE) 2023 May 24 (pp. 1-6). IEEE.

[5] Wu J, Guerrero JM, Basati A, Vasquez JC, Li S. Kalman filter-based power compensation strategy for Microgrids under uncertain disturbance. In 2022 International Conference on Smart Energy Systems and Technologies (SEST) 2022 Sep 5 (pp. 1-5). IEEE.

[6] Basati A, Guerrero JM, Vasquez JC, Fakharian A, Johansson KH, Golestan S. Robust internal model-based voltage control for DC microgrids: An LMI based H_∞ control. *Sustainable Energy, Grids and Networks*. 2023 Sep 1;35:101094.

[7] Sun W, Lin X, Huang L, Mu D, Zhang H. Distributed sliding mode control for reactive power sharing in an islanded microgrid. *Electric Power Systems Research*. 2024 Jun 1;231:110342.

[8] Doliya D, Bhandari M. An LMI approach for robust LQR control of PWM buck converter with parasitics. In 2017 7th International Conference on Communication Systems and Network Technologies (CSNT) 2017 Nov 11 (pp. 103-108). IEEE.

[9] Cucuzzella M, Lazzari R, Trip S, Sandroni C, Ferrara A. Robust voltage regulation of boost converters in DC microgrids. In 2018 European Control Conference (ECC) 2018 Jun 12 (pp. 2350-2355). IEEE.

[10] Shuai Z, He D, Fang J, Shen ZJ, Tu C, Wang J. Robust droop control of DC distribution networks. *IET Renewable Power Generation*. 2016 Jul;10(6):807-14.

[11] Baranwal M, Askarian A, Salapaka S, Salapaka M. A distributed architecture for robust and optimal control of DC microgrids. *IEEE Transactions on Industrial Electronics*. 2018 Jun 4;66(4):3082-92.

[12] Olalla C, Leyva R, El Aroudi A, Garcés P, Queinnee I. LMI robust control design for boost PWM converters. *IET Power Electronics*. 2010 Jan 1;3(1):75-85.

[13] Kaviani K, Menhaj MB, Fakharian A. Mixed H_2/H_∞ State-Feedback Control for Islanded DC Microgrids: An LMI Based Approach. In 2018 Smart Grid Conference (SGC) 2018 Nov 28 (pp. 1-6). IEEE.

[14] Gahinet P. LMI Control Toolbox. The Math Works Inc. 1994.

[15] Chilali M, Gahinet P. H_∞ design with pole placement constraints: an lmi approach. *IEEE Transactions on automatic control*. 1996 Mar;41(3):358-67.

[16] Bagheri Rouch T, Fakharian A. Robust control of islanded DC microgrid for voltage regulation based on polytopic model and load sharing. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*. 2022 Mar;46(1):171-86.

[17] Rouch TB, M'Zoughi F, Aboutalebi P, Ahmad I, Garrido AJ, Garrido I. Voltage and power control for distributed generation units in islanded microgrids. In *Innovations in Renewable Energies Offshore 2024* (pp. 519-525). CRC Press.

[18] Emam M, Fakharian A. Attitude tracking of quadrotor UAV via mixed H_2/H_∞ controller: An LMI based approach. In 2016 24th Mediterranean Conference on Control and Automation (MED) 2016 Jun 21 (pp. 390-395). IEEE.

[19] Chen F, Burgos R, Boroyevich D, Zhang W. A nonlinear droop method to improve voltage regulation and load sharing in DC systems. In 2015 IEEE First International Conference on DC Microgrids (ICDCM) 2015 Jun 7 (pp. 45-50). IEEE.

Control Inteligente del ángulo de palas de un aerogenerador mediante aprendizaje por refuerzo

Inazio Cavero
National Distance Education
University (UNED)
Zaragoza, Spain
n.cavero.juste@gmail.com

Matilde Santos
Technological Knowledge Institute,
Complutense University of Madrid
Madrid, Spain
msantos@ucm.es

J. Enrique Sierra-García
Department of Electromechanical
Engineering, University of Burgos
Burgos, Spain
jesierra@ubu.es

Abstract—In this work, reinforcement learning has been used to train a wind turbine pitch controller. The selected algorithm has been DDPG, and it was implemented in a simulation environment. The controller generates collective pitch angle references, to obtain a smooth rotor speed. Preliminary results are presented, which demonstrate the potential of this approach to solve the pitch control problem.

Index Terms—Reinforcement Learning, Deep Learning, Intelligent Control, Wind Turbine

I. INTRODUCCIÓN

Las turbinas eólicas generan electricidad a partir del viento. Esta fuente de energía es tremendamente variable, lo que hace difícil obtener una salida de energía estable, además de provocar grandes esfuerzos mecánicos en la estructura. Para solventar estos problemas, es necesario un sistema de control que maximice la extracción de energía, mientras evita superar los límites mecánicos y eléctricos del aerogenerador.

Desde el punto de vista de control, el aerogenerador es un sistema altamente no lineal, multivariable [1] y multiobjetivo. Controladores tradicionales han tenido éxito en realizar esta tarea, dividiendo el problema en distintos modos de operación en función de la velocidad del viento (Figura 1), con controladores específicos para cada región de trabajo. En la región (i) la turbina permanece parada. En (ii), con carga parcial, el objetivo es maximizar la producción de energía. El ángulo de palas permanece fijo y se actúa sobre el par del rotor para seguir los puntos de velocidad óptimos (algoritmos MPPT (Maximum Power Point Tracking)). En (iv) región nominal o a plena carga, se debe conseguir que el generador trabaje a su potencia nominal, variando el ángulo de palas para regular el par de entrada. Finalmente, en la región (vi), el viento es demasiado alto y la turbina se frena para evitar averías. El controlador propuesto en este trabajo, es un control de ángulo de palas para la región de trabajo nominal (iv).

Lo más habitual es utilizar un controlador PID del error de velocidad para comandar el ángulo de palas. No obstante, se han propuesto métodos de control más modernos, tales como controladores robustos y adaptativos, control predictivo [2], o técnicas de control inteligente, como el control fuzzy




Fig. 1. Modos de operación del control del aerogenerador.

o basado en redes neuronales, mediante aprendizaje no supervisado [3], o aprendizaje por refuerzo [4], [5].

Desarrollar controladores clásicos basados en modelos para sistemas no lineales y/o multivariables como el control de un aerogenerador es una tarea compleja, y su comportamiento está limitado por las hipótesis tomadas durante su diseño. Por otro lado, las aproximaciones basadas en datos prometen ser una alternativa útil, superando estas hipótesis al aprender directamente en base a datos reales del sistema. De entre las distintas aproximaciones de aprendizaje automático, el aprendizaje por refuerzo no parte de un conjunto de datos estático, sino que recopila los datos mediante prueba y error entre un agente y el entorno, automáticamente actualizando el modelo en función de la calidad de los resultados. Esta técnica es especialmente útil para problemas de control y será la empleada en este trabajo.

II. ESTADO DEL ARTE: APRENDIZAJE POR REFUERZO

El aprendizaje por refuerzo [6] es un área del aprendizaje automático inspirado en la psicología constructivista. Plantea resolver problemas de control mediante agentes interactuando con el entorno, mejorando sucesivamente su comportamiento en base a las recompensas obtenidas en el proceso.

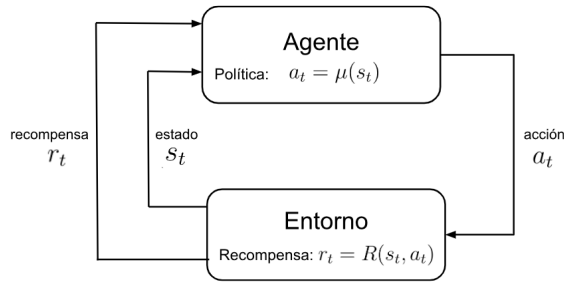


Fig. 2. Representación de los elementos básicos en Aprendizaje por Refuerzo.

El esquema básico del aprendizaje por refuerzo se muestra en la Figura 2. El agente, en el tiempo t y en el estado s_t , escoge realizar una acción a_t en función de la política $\gamma(s_t)$. La calidad de realizar esa acción, para ese estado, se evalúa mediante la recompensa r_t . En base a esas recompensas se deberá actualizar la política.

El objetivo final del controlador, no es maximizar la recompensa en cada paso, sino la recompensa total de la trayectoria ($\tau = (s_0, a_0, s_1, a_1, \dots)$):

$$R(\tau) = \sum_{t=0}^T r_t \quad (1)$$

Como antes de finalizar la trayectoria no es posible conocer la recompensa, es útil estimar la esperanza de recompensa al comenzar en un estado dado y aplicando cierta política. A esta estimación se le denomina "On-Policy Action-Value Function" $Q^\mu(s, a)$.

$$Q^\mu(s, a) = E_{\tau \sim \mu} [R(\tau) | s_0 = s, a_0 = a] \quad (2)$$

A partir del concepto de optimalidad de Bellman, se puede formular dicho valor en dos términos, la recompensa inmediata, y la recompensa futura (La Q-function comenzando en el estado siguiente (s') obtenido de aplicar la política), descontada con un factor γ :

$$Q^\mu(s, a) = E[r(s, a) + \gamma E[Q^\mu(s', a')]] \quad (3)$$

De entre las Q-functions, la óptima es la que maximiza la esperanza de recompensa. En los algoritmos de Q-learning, se denomina Crítico al componente que calcula la estimación de este valor de recompensa.

$$Q^*(s, a) = E[r(s, a) + \gamma \max_{a' \sim \mu} Q^*(s', a')] \quad (4)$$

Para conseguir esa recompensa máxima, la acción óptima es la que maximiza dicha Q-function. En los algoritmos basados en el cálculo de la política, se suele denominar Actor, al componente que calcula la acción.

$$a^*(s) = \operatorname{argmax}(Q^*(s, a)) \quad (5)$$

A partir de esta formulación del problema, existen algoritmos que intentan aprender los distintos elementos, o

en ocasiones varios de ellos. Ordenados de más bajo a alto nivel, se puede aprender:

- **La política (Actor):** El actor calcula directamente la acción óptima.
- **La estimación de la recompensa (Q-learning, Crítico).** Conocido el valor de la recompensa, en un sistema discreto, se pueden probar todas las acciones posibles hasta dar con la óptima. En un sistema continuo, puede resolverse un problema de optimización que encuentre las acciones óptimas.
- **El modelo del entorno.** Conocido el modelo del entorno puede resolverse un problema de optimización para encontrar la política óptima, mediante técnicas como control predictivo basado en modelo (MPC).

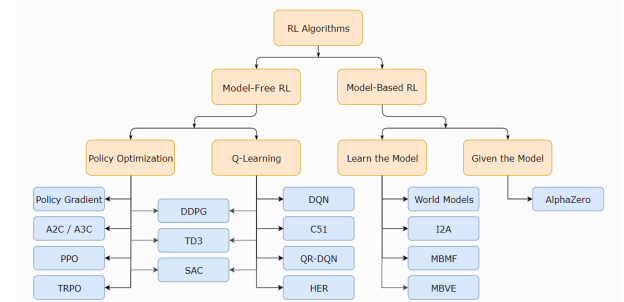


Fig. 3. Clasificación de algoritmos de aprendizaje por refuerzo. Fuente: [12].

De entre estos algoritmos, se ha seleccionado DDPG [7]. Fue el primer algoritmo de tipo Actor-crítico, para variables continuas. Es decir, combina ambos métodos, ya que tiene un Actor que calcula directamente la acción, pero también tiene un crítico cuyo valor se utiliza para optimizar la política. Para adaptarlo a variables continuas, tanto el actor como el crítico están formados por redes neuronales.

Después de DDPG, surgieron otros algoritmos más robustos basados en la misma filosofía, como TD3 [8] y SAC [9], pero según la literatura son más complicados de calibrar, por lo que se recomienda comenzar en nuevos problemas con DDPG [10].

En concreto, se ha utilizado la implementación de Stable-Baselines 3 [13] adaptado al problema de control del aerogenerador.

III. MODELO DE AEROGENERADOR

Realizar el entrenamiento en un aerogenerador real es inviable, debido al riesgo de dañarlo, y al elevado número de horas de recopilación de datos que requeriría. Por ese motivo, se ha implementado un modelo de aerogenerador basado en [3].

La turbina se modela cómo un rotor con inercia J , sujeto al par del viento T_m , el par electromagnético del generador T_{em} y fricción K_f :

$$J \frac{d\omega}{dt} = T_m - T_{em} - K_f \cdot \omega \quad (6)$$

El par electromagnético T_{em} se calcula mediante el modelo de un generador de corriente continua, definido por los parámetros: R_a (Resistencia de armadura), L_a (Inductancia de armadura), K_g (constante adimensional del generador), K_{phi} (constante de flujo electromagnético):

$$T_{em} = K_g \cdot K_{\phi} \cdot I_a \quad (7)$$

$$L_a \frac{dI_a}{dt} = E_a - V - R_a I_a \quad (8)$$

$$E_a = K_g \cdot K_{\phi} \cdot \omega \quad (9)$$

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

Y por otro lado, el par aerodinámico T_m (ec.11) se calcula partiendo de la potencia máxima del viento en la sección A barrida por el aerogenerador, reducida en un factor de eficiencia C_p . Este puede modelarse mediante expresiones empíricas (ecs. 13, 14) en función del ángulo de palas θ y del ratio de velocidad en punta λ (ec. 12).

$$T_m = \frac{C_p(\lambda, \theta) \rho A v^3}{2\omega} \quad (11)$$

$$\lambda = \frac{\omega R}{v} \quad (12)$$

$$\lambda_i(\lambda, \theta) = \left[\left(\frac{1}{\lambda + c_8} \right) - \left(\frac{c_9}{\theta^3 + 1} \right) \right] \quad (13)$$

$$C_p(\lambda_i, \theta) = c_1 [c_2 / \lambda_i - c_3 \theta - c_4 \theta_5^c - c_6] e^{c_7 / \lambda_i} \quad (14)$$

Por último, la única modificación del modelo implementado respecto al artículo de referencia, está en el modelo de la dinámica de las palas, implementado mediante un primer orden con saturación en la derivada, para tener en cuenta las no limitaciones no lineales.

$$\dot{\theta} = \max(-\dot{\theta}_{max}, \min(\dot{\theta}_{max}, \frac{1}{\tau_{\theta}} (\theta_{ref} - \theta))) \quad (15)$$

Este modelo, se ha implementado con la interfaz estándar de Open AI Gym [11]. Esto permite utilizarlo con algoritmos de aprendizaje por refuerzo genéricos.

Los parámetros del modelo, son los de una turbina de 7 kW, y se muestran en la tabla I.

TABLE I
PARÁMETROS DE MODELO DE TURBINA DE 7 kW

Parámetro	Valor
L_a	13.5mH
K_g	23.31
K_{phi}	0.264 V/rad/s
R_a	0.275 Ω
R_L	8 Ω
J	6.53 Kgm^2
R	3.2m
ρ	1.223 Kg/m^3
K_f	0.025 Nm/rad/s
$[c_1, c_2, c_3, c_4, c_5, c_6, c_7, c_8, c_9]$	[0.73, 151, 0.58, 0.002, 2.14, 13.2, 18.4, -0.02, -0.03]
τ	2
θ_{max}	0.087 rad/s (5°/s)

IV. ARQUITECTURA DEL ENTORNO DE APRENDIZAJE POR REFUERZO, ENTRENAMIENTO Y RESULTADOS

En la Figura 4 se representa la arquitectura de aprendizaje por refuerzo implementada para entrenar el controlador de ángulo de palas (pitch) del aerogenerador. Como se ha explicado en la Sección II, se ha utilizado el algoritmo DDPG, del tipo Actor-Crítico.

El entorno está comprendido por los bloques verdes: Modelo del aerogenerador, cálculo de la recompensa y el crítico. El crítico se modela mediante una red neuronal multicapa de 2 capas de 32 neuronas cada una.

Por otro lado, el controlador está formado por los bloques amarillos, compuestos principalmente por el agente, que calcula la acción incremental de pitch; y la conversión a referencia de pitch. La política también está modelada por una red neuronal multicapa de 2 capas de 32 neuronas cada una.

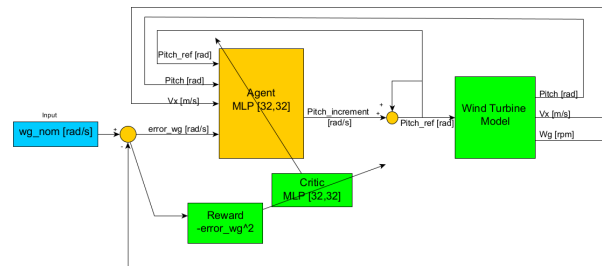


Fig. 4. Arquitectura del Entorno de aprendizaje por refuerzo del controlador de ángulo de palas.

Las variables de estado del agente son:

- Error de velocidad del rotor ($error_{wg}$) [rad/s]
- Velocidad del viento (V_x) [m/s]
- Ángulo de palas real ($pitch$) [rad]
- Referencia de ángulo de palas ($pitch_{ref}$) [rad]

La acción del agente es el Pitch incremental normalizado en el rango [-1,1]. Posteriormente, se convierte a rad/s y

se acumula la referencia de pitch como acción del controlador.

La recompensa es el error de velocidad acumulado en cada paso de control:

$$R = -(error_{wg})^2 \quad (16)$$

A. Entrenamiento

Los hiperparámetros utilizados del modelo DDPG durante el entrenamiento se muestran en la tabla II:

TABLE II
PARÁMETROS DE DDPG DURANTE EL ENTRENAMIENTO

Parámetro	Valor	Descripción
learning_rate	1e-3	Tasa de aprendizaje del optimizador ADAM
buffer_size	1e5	Tamaño del replay buffer
learning_starts	500	Nº pasos recopilando experiencias antes entrenar
batch_size	256	Minibatch para cada actualización del gradiente
gamma	0.98	Factor de descuento de recompensas futuras
train_freq	1	Actualización del modelo cada <i>train_freq</i> pasos
gradient_steps	1	Nº de actualizaciones de gradiente cada <i>train_freq</i>
action_noise	0.1	Ruido de la acción para explorar

Se establece un tiempo de ciclo del controlador de 200 ms. Se ha realizado un entrenamiento de 8000s de tiempo de simulación, donde cada episodio tiene un tiempo máximo de 100s. El tiempo de computación de dicho entrenamiento ha sido de 29m 22s.

En un primer paso, se ha entrenado con viento constante de 12.3 m/s; y una referencia de velocidad fija de 40 m/s.

En la Figura 5 se observa la evolución de la recompensa media de los episodios durante el entrenamiento, que tiene una evolución constante.

En la Figura 6 se muestra la evolución de la función de coste del actor. Va disminuyendo progresivamente, conforme produce mejores resultados.

En las siguientes figuras se observa la evolución de la recompensa media de cada episodio (Figura 5) y el coste del agente (Figura 6).




Fig. 5. Recompensa media de los episodios durante el entrenamiento.




Fig. 6. Coste del actor.

B. Resultados

Finalmente, se realiza una simulación de validación con la política entrenada en el paso anterior. Los resultados se observan en las siguientes gráficas:

El primer segundo de simulación corresponde a la estabilización de las condiciones iniciales del modelo, y el controlador no empieza a actuar hasta pasado ese segundo.

En la Figura 7 se observa cómo el controlador lleva el rotor a una velocidad cercana a la de referencia sin sobreoscilaciones. Para ello, observamos en las Figuras 8 y 9, cómo aumenta la referencia de pitch, pero antes de alcanzar la velocidad de referencia, ya comienza a realizar acciones negativas para reducir la referencia de pitch, y llegar al ángulo de palas estacionario que permite llevar la velocidad del rotor deseada para la velocidad de viento dada.




Fig. 7. Velocidad del rotor. Referencia 40 rad/s.




Fig. 8. Acción del agente. Pitch incremental.




Fig. 9. Referencia de ángulo de palas, y ángulo de palas real.

C. Inspección de la política

Cómo este primer entrenamiento se ha realizado con viento constante, hay 2 variables de estado con mayor influencia, que son el error de velocidad y el ángulo de palas. De modo que podemos representar la política realizando un barrido del espacio de esas dos variables.




Fig. 10. Inspección de la política.

En la Figura 10, se observa cómo la acción tiene sentido contrario al error de velocidad, con una pequeña rampa de transición. Esta zona es muy escalonada porque la acción máxima es muy pequeña, por lo que el controlador tiende a realizar acciones máximas, como ya se observaba en la simulación (Figura 8).

V. CONCLUSIONES Y TRABAJOS FUTUROS

En este trabajo se ha desarrollado un entorno para el entrenamiento de un controlador de ángulo de palas de una turbina eólica mediante aprendizaje por refuerzo. Se ha demostrado que los resultados preliminares son positivos, siendo posible realizar acciones de control estables para el problema dado, en un tiempo de entrenamiento corto.

Los siguientes pasos, deben ser continuar el entrenamiento del mismo modelo con viento cambiante, y con referencias de velocidad diversas, para demostrar su utilidad en condiciones más realistas. Además, deberá compararse su comportamiento con un controlador PID de referencia, para demostrar las bondades del controlador propuesto.

Por último, si los resultados intermedios son positivos, se puede realizar un segundo paso, validando el controlador frente a un simulador de mayor fidelidad, como OpenFAST; para emular la transferibilidad del algoritmo de control, de simulación a la realidad.

REFERENCES

- [1] González, Miguel E., et al. "Multivariable centralized control with decoupling and feedforward compensation for residential wind turbine." IFAC Proceedings Volumes 44.1 (2011): 557-562.
- [2] Lio, Wai Hou, J. A. Rossiter, and Bryn L. Jones. "A review on applications of model predictive control to wind turbines." 2014 Ukacc international conference on control (control). IEEE, 2014.
- [3] Sierra-García, J. Enrique, and Matilde Santos. "Performance analysis of a wind turbine pitch neurocontroller with unsupervised learning." Complexity 2020.1 (2020): 4681767.
- [4] Sierra-García, J. E., and M. Santos. "Redes neuronales y aprendizaje por refuerzo en el control de turbinas eólicas." Revista Iberoamericana de Automática e Informática industrial 18.4 (2021): 327-335.
- [5] Schena, L., et al. "Control of a Wind-Turbine via Machine Learning techniques." arXiv preprint arXiv:2207.06206 (2022).
- [6] Sutton, Richard S., and Andrew G. Barto. Reinforcement learning: An introduction. MIT press, 2018.
- [7] Lillicrap, T. P. "Continuous control with deep reinforcement learning." arXiv preprint arXiv:1509.02971 (2015).
- [8] Fujimoto, Scott, Herke Hoof, and David Meger. "Addressing function approximation error in actor-critic methods." International conference on machine learning. PMLR, 2018.
- [9] Haarnoja, Tuomas, et al. "Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor." International conference on machine learning. PMLR, 2018.
- [10] Reinforcement Learning Agents, Mathworks. [Online] Available: <https://es.mathworks.com/help/reinforcement-learning/ug/create-agents-for-reinforcement-learning.html>
- [11] Brockman, G. "OpenAI Gym." arXiv preprint arXiv:1606.01540 (2016).
- [12] OpenAI Spinning Up Reinforcement Learning, 2020. [Online] Available: <https://spinningup.openai.com/en/latest/index.html>
- [13] Raffin, Antonin, et al. "Stable-baselines3: Reliable reinforcement learning implementations." Journal of Machine Learning Research 22.268 (2021): 1-8.

Control de flujo de aire basado en ANFIS de turbinas eólicas marinas híbridas flotantes con columna de agua oscilante para mitigación de vibraciones

1st Fares M'zoughi

*Automatic Control Group-ACG,
Institute of Research and Development of
Processes-IIDP, Department of Automatic
Control and Systems Engineering,
Faculty of Engineering of Bilbao-EIB/BIE,
University of the Basque Country-UPV/EHU,
Po Rafael Moreno no3, 48013 Bilbao, Spain*

2nd Payam Aboutalebi

*Automatic Control Group-ACG,
Institute of Research and Development of
Processes-IIDP, Department of Automatic
Control and Systems Engineering,
Faculty of Engineering of Bilbao-EIB/BIE,
University of the Basque Country-UPV/EHU,
Po Rafael Moreno no3, 48013 Bilbao, Spain*

3rd Irfan Ahmad

*Automatic Control Group-ACG,
Institute of Research and Development of
Processes-IIDP, Department of Automatic
Control and Systems Engineering,
Faculty of Engineering of Bilbao-EIB/BIE,
University of the Basque Country-UPV/EHU,
Po Rafael Moreno no3, 48013 Bilbao, Spain*

4th Tahereh Bagheri Rouch

*Automatic Control Group-ACG,
Institute of Research and Development of
Processes-IIDP, Department of Automatic
Control and Systems Engineering,
Faculty of Engineering of Bilbao-EIB/BIE,
University of the Basque Country-UPV/EHU,
Po Rafael Moreno no3, 48013 Bilbao, Spain*

5th Izaskun Garrido

*Automatic Control Group-ACG,
Institute of Research and Development of
Processes-IIDP, Department of Automatic
Control and Systems Engineering,
Faculty of Engineering of Bilbao-EIB/BIE,
University of the Basque Country-UPV/EHU,
Po Rafael Moreno no3, 48013 Bilbao, Spain*

6th Aitor J. Garrido

*Automatic Control Group-ACG,
Institute of Research and Development of
Processes-IIDP, Department of Automatic
Control and Systems Engineering,
Faculty of Engineering of Bilbao-EIB/BIE,
University of the Basque Country-UPV/EHU,
Po Rafael Moreno no3, 48013 Bilbao, Spain*

Abstract—This paper introduces a novel approach to model and stabilize a Floating Offshore Wind Turbine (FOWT) by employing Oscillating Water Columns (OWC) as an active structural control system. The innovative concept involves designing a new floating barge-like platform with integrated OWCs on opposite sides of the platform to mitigate undesired oscillations of the system. These OWCs counteract the bending forces caused by wind on the tower and waves on the barge platform. To synchronize the opposing forces with the system's tilting, a proposed Adaptive Neuro-Fuzzy Inference System-based airflow control strategy is employed. Through manipulation of the barge platform's pitch angle, the ANFIS airflow control system adjusts the valves on either side, opening one and closing the other accordingly. Simulation results, compared with a standard FOWT demonstrate the effectiveness of the ANFIS airflow control. It is shown to be superior in reducing platform pitching and the fore-aft translation of the tower top.

Keywords—ANFIS, Airflow Control, Air Valve, Barge Platform, Floating Offshore Wind Turbine, Oscillating Water Column, Active Structural Control.

Resumen—Este artículo presenta un nuevo enfoque para modelar y estabilizar una turbina eólica marina flotante (FOWT) mediante el empleo de columnas de agua oscilantes (OWC) como un sistema de control estructural activo. El concepto innovador implica el diseño de una nueva plataforma flotante similar a una barcaza con columnas de agua oscilantes integradas en lados opuestos de la plataforma para mitigar las oscilaciones no deseadas del sistema. Estas OWC contrarrestan las fuerzas de flexión causadas por el viento en la torre y las olas en la plataforma de la barcaza. Para sincronizar las fuerzas opuestas con la inclinación del sistema, se emplea una estrategia de control

de flujo de aire basada en el sistema de inferencia neurodifusa adaptativa propuesta. A través de la manipulación del ángulo de inclinación de la plataforma de la barcaza, el sistema de control de flujo de aire ANFIS ajusta las válvulas en ambos lados, abriendo una y cerrando la otra en consecuencia. Los resultados de la simulación, comparados con un FOWT estándar, demuestran la eficacia del control de flujo de aire ANFIS. Se demuestra que es superior en la reducción del cabeceo de la plataforma y la traslación de proa a popa de la parte superior de la torre.

Palabras claves— ANFIS, control de flujo de aire, válvula de aire, plataforma de barcaza, turbina eólica marina flotante, columna de agua oscilante, control estructural activo.

I. INTRODUCCIÓN

Se espera que la industria eólica marina desempeñe un papel importante en su consecución del objetivo de triplicar la capacidad de energía renovable en todo el mundo para 2030. Turbinas más grandes, instalaciones en aguas más profundas y avances tecnológicos podrían permitir que los parques eólicos marinos capturen enormes cantidades de energía sostenible frente a las costas del mundo. Para satisfacer la creciente demanda de energía y diversificar la combinación energética, esta expansión es esencial. La industria mundial de la energía eólica marina ayuda a cumplir los objetivos globales para mitigar el cambio climático y garantizar un futuro más limpio y verde mediante la utilización del poder de los vientos marinos fuertes y constantes (Kaldellis, 2013). Como resultado, las emisiones de carbono se reducen significativamente. La incorporación de 8,8 gigavatios de nueva energía eólica marina a la red, lo que refleja una disminución del 58% con respecto a los notables logros de 2021, marcó 2022 como el segundo año

más alto registrado para instalaciones eólicas marinas (Bagheri Rouch, 2022). A pesar de esta disminución, las instalaciones recientes contribuyen a una capacidad global de energía eólica marina de 64,3 GW, lo que demuestra un crecimiento interanual del 16% y representa el 7% del total acumulado de instalaciones eólicas marinas en el mundo (Pérez-Collazo, 2015).

A medida que la energía eólica se desplaza cada vez más hacia tecnologías marinas, los investigadores e inversores han abogado por la adopción de plataformas multipropósito. Estas plataformas están diseñadas para aprovechar múltiples recursos energéticos simultáneamente. Uno de los conceptos más estudiados es el de plataforma eólica, que integra turbinas eólicas (TE) con convertidores de energía de las olas para aprovechar tanto la energía de las olas como la eólica (Hu, 2020), (Ahmad, 2022), (Ahmad, 2023), (Aboutalebi, 2023), (Aboutalebi, 2024). Estudios anteriores han explorado la integración del WEC con turbinas eólicas marinas flotantes, arrojando resultados prometedores. Por ejemplo, en (Kluger, 2017), se emparejó una matriz WEC con un FOWT tipo mástil OC3-Hywind, mientras que (Slocum, 2019) investigó WEC de agitación tanto externa como interna en OC3-Hywind. Además, (Kamarlouei, 2020) concluyó que las vibraciones de la plataforma durante el movimiento vertical y el cabeceo se reducen con una matriz WEC. Sin embargo, estos estudios aún no han explorado el uso de OWC en plataformas de barcazas. El objetivo de este artículo es integrar un OWC con un FOWT para aprovechar tanto la energía de las olas como la eólica. Además, el estudio se centra en el uso de OWC para estabilizar el FOWT y reducir las vibraciones estructurales. El FOWT considerado en este estudio es la turbina eólica NREL de 5MW montada en una plataforma de barcaza de ITI Energy (Vijfhuizen, W.J.M.J., 2006). El control de los OWC se logrará a través de un control de flujo de aire del Sistema Adaptativo de Inferencia Neuro-Fuzzy (ANFIS), que regulará la apertura y el cierre de las válvulas de aire para controlar el flujo de aire y la presión dentro de cada cámara de aire (M'zoughi, 2018), (M'zoughi, 2020).

Las secciones restantes del documento están organizadas de la siguiente manera: La Sección 2 detalla el modelo OWC-FOWT desarrollado basado en las fuerzas adicionales de los OWC. En la Sección 3, se presenta el control de flujo de aire ANFIS diseñado. La Sección 4 presenta los resultados de la simulación obtenidos para la nueva estructura e incluye un estudio comparativo que analiza su comportamiento estructural frente a un FOWT estándar. Finalmente, la Sección 5 concluye el artículo con algunas observaciones finales.

II. MATERIALES Y MÉTODOS

A diferencia de las turbinas eólicas terrestres, que experimentan principalmente desplazamientos de adelante hacia atrás y de lado a lado debido a los momentos de flexión en la torre, las turbinas eólicas marinas flotantes enfrentan desafíos adicionales como el desplazamiento de la parte superior de la torre, los modos de rotación y los modos de traslación. Estos factores contribuyen a una mayor vibración e inestabilidad de la estructura. El FOWT estudiado es la turbina eólica marina de referencia NREL de 5 MW montada en barcaza de ITI Energy,

comúnmente utilizado para analizar interacciones de carga y probar nuevos conceptos para FOWT por J. Jonkman et al. en (Jonkman, 2007).

Estudios anteriores han demostrado que los cambios en el ángulo de inclinación de la plataforma contribuyen significativamente a la flexión de la torre (Jonkman, 2008), (Lackner, 2011). Además, debido a que la flexión de la torre causada por el cabeceo de la barcaza afecta los desplazamientos de la parte superior de la torre, el modo longitudinal también es importante para la estabilidad FOWT. Por lo tanto, el modelo FOWT en este estudio se centra en estos dos modos: ángulo de inclinación de la plataforma y flexión de la torre hacia adelante y hacia atrás. Además, este manuscrito de investigación explora la dinámica de vibración de las turbinas eólicas marinas flotantes, particularmente en relación con las interacciones de las olas. Para lograr un modelo matemático dinámico lineal y desarrollar una estrategia de control estructural activo adecuada para la estabilización de la plataforma, se ha ignorado la influencia de los vientos sobre la turbina.

A. Modelado matemático del híbrido OWC-FOWT

Como se mencionó anteriormente, el ángulo de inclinación de la plataforma y el desplazamiento de la torre hacia adelante y hacia atrás son los grados de libertad más críticos que afectan la estabilidad de la plataforma del FOWT. Por lo tanto, el modelo desarrollado en este estudio se centrará en describir estos dos grados de libertad para diseñar un modelo matemático dinámico de orden reducido. Este modelo, ilustrado en el diagrama de la Fig. 1 (adoptado de (Stewart, 2013), (Hu, 2017)), capturará la dinámica esencial del sistema.

Se supone que la torre TE está conectada a la plataforma a través de un resorte rotacional, caracterizado por la rigidez k_t , y un amortiguador denominado amortiguación d_t . La constante de resorte k_p representa la rigidez de las líneas de amarre, los momentos de restauración hidrostáticos y las propiedades de amortiguación hidrodinámicas que interactúan con la plataforma de la barcaza. El coeficiente de amortiguación d_p tiene en cuenta las propiedades viscosas y la radiación de las ondas. Las propiedades estructurales del FOWT estudiado se resumen en la Tabla 1.

La estructura de plataforma híbrida de ondas de viento propuesta tiene como objetivo reducir el ángulo de inclinación de la plataforma y el desplazamiento de la torre hacia adelante y hacia atrás.

Tabla 1: Parámetros de la estructura FOWT

Torre	
Parámetro	Valor
Rigidez	$k_t = 9.7990 \cdot 10^9$ (N m rad ⁻¹)
Amortiguación	$d_t = 2.1032 \cdot 10^7$ (N m s rad ⁻¹)
Inercia	$I_t = 1.8217 \cdot 10^9$ (kg m ²)
Plataforma de barcaza	
Parámetro	Valor
Rigidez	$k_p = 1.4171 \cdot 10^9$ (N m rad ⁻¹)
Amortiguación	$d_p = 3.6374 \cdot 10^7$ (N m s rad ⁻¹)
Inercia	$I_p = 1.6945 \cdot 10^9$ (kg m ²)

Para lograrlo, se integraron dos OWC en la plataforma de la barcaza, ubicados en la parte delantera y trasera de la torre eólica.




Fig. 1. Esquema del concepto OWC-FOWT híbrido propuesto.

Las ecuaciones de Euler-Lagrange de un sistema no conservativo con n coordenadas generalizadas se describen mediante (1) y (2):

$$\frac{d}{dt} \left(\frac{\partial L}{\partial \dot{q}_i} \right) - \frac{\partial L}{\partial q_i} = Q_i \quad (i=1,2,\dots,n) \quad (1)$$

$$L = T - V \quad (2)$$

donde T y V son la energía cinética total y la energía potencial total del sistema, respectivamente. L es el operador de Lagrange.

La energía cinética total y la energía potencial total de la turbina eólica flotante tipo barcaza se pueden expresar como:

$$T = \frac{1}{2} I_t \dot{\theta}_t^2 + \frac{1}{2} I_p \dot{\theta}_p^2 \quad (3)$$

$$V = \frac{1}{2} k_t (\theta_t - \theta_p)^2 + \frac{1}{2} k_p \theta_p^2 + m_t g R_t \cos \theta_t - m_p g R_p \cos \theta_p \quad (4)$$

donde k es el coeficiente de rigidez del resorte equivalente, θ es el ángulo de rotación alrededor del eje horizontal, I es el momento de inercia alrededor del centro de masa, m es la masa, g es la aceleración gravitacional y R es la distancia desde el centro de masa hasta la sujeción de la torre. Los subíndices p y t representan la plataforma y la torre, respectivamente.

Las fuerzas generalizadas consisten en la fuerza de amortiguación y las cargas de viento y oleaje externas expresadas como:

$$\begin{cases} Q_{\theta_t} = -d_t (\dot{\theta}_t - \dot{\theta}_p) + M_{wind} \\ Q_{\theta_p} = -d_p \dot{\theta}_p + d_t (\dot{\theta}_t - \dot{\theta}_p) + M_{wave} - R_{owc1} f_{owc1} + R_{owc2} f_{owc2} \end{cases} \quad (5)$$

donde d es el coeficiente de amortiguamiento equivalente, M_{wind} y M_{wave} son los momentos flectores causados por el viento externo y las cargas de las olas que actúan sobre la base de la torre y la parte superior de la plataforma, respectivamente. Las fuerzas f_{owc1} y f_{owc2} son las fuerzas inducidas por las presiones en las cámaras de captura de OWC1 y OWC2, respectivamente.

Sustituyendo (3)-(5) en (1) y (2) y considerando aproximaciones de ángulo pequeño porque ninguna de los ángulos excede los 10 grados de inclinación, incluso en las cargas de viento y oleaje más fuertes y asumiendo que ambos OWC están a la misma altura desde la bisagra de la torre ($R_{OWC1} = R_{OWC2}$) el modelo dinámico no lineal de contacto de la turbina eólica flotante de barcaza se expresa por (6).

$$\begin{cases} I_p \ddot{\theta}_p - k_t (\theta_t - \theta_p) + m_p g R_p \theta_p + k_p \theta_p = -d_p \dot{\theta}_p + d_t (\dot{\theta}_t - \dot{\theta}_p) + M_{wave} - R_{owc} (f_{owc1} - f_{owc2}) \\ I_t \ddot{\theta}_t + k_t (\theta_t - \theta_p) - m_t g R_t \theta_t = -d_t (\dot{\theta}_t - \dot{\theta}_p) + M_{wind} \end{cases} \quad (6)$$

El viento y las olas interactúan con la estructura FOWT de una manera aeroelástica e hidroelástica compleja. Además, existe un acoplamiento inherente entre las respuestas estructurales inducidas por el viento y las olas (Hu, 2018).

B. Fuerzas de columnas de agua oscilantes

Suponiendo que la superficie libre interna dentro de la cámara se comporta como un pistón y la presión es uniforme, la fuerza se puede definir como (M'zoughi, 2021):

$$f_{OWCi} = -p_i(t) S \quad (i=1,2) \quad (7)$$

donde $p_i(t)$ es la presión de la cámara y S es la superficie libre interna de la cámara, que es la misma para ambos OWC. El subíndice $i=1,2$ se refiere a OWC1 o OWC2.

Considerando el aire como un gas ideal y el sistema es adiabático y las transformaciones son lo suficientemente lentas como para ser reversibles, pueden entonces considerarse isentrópicas y la densidad del aire se define como:

$$\rho_i(t) = \rho_a \left(\frac{p_i(t)}{p_a} \right)^{\frac{1}{\gamma}} \quad (i=1,2) \quad (8)$$

donde p_a y ρ_a son la presión atmosférica y la densidad, γ es la proporción de calor.

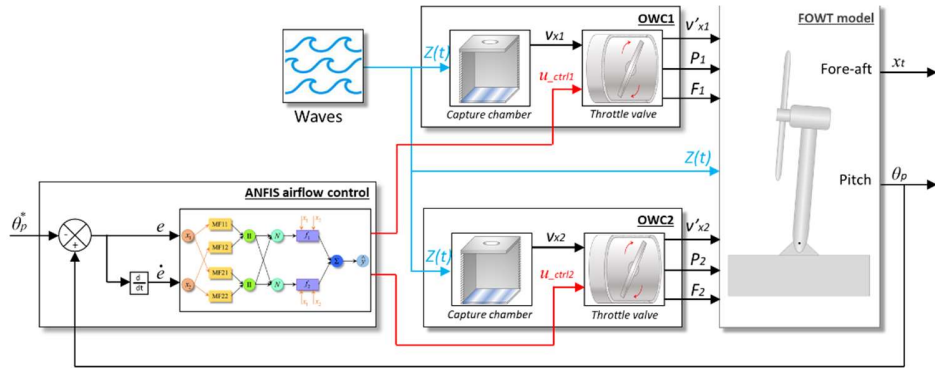


Fig. 2. Control de flujo de aire ANFIS propuesto para la estabilización FOWT.

La linealización de la transformación isentrópica produce la derivada de la densidad del aire:

$$\dot{\rho}_i(t) = \frac{\rho_a}{p_a \gamma} \dot{p}_i(t) \quad (i = 1, 2) \quad (9)$$

El caudal másico dentro de las cámaras de captura de los OWC se puede escribir como:

$$\dot{m}_i(t) = \frac{\rho_a V_0}{p_a \gamma} \dot{p}_i(t) + \rho_a \dot{V}_{OWC_i}(t) \quad (i = 1, 2) \quad (10)$$

donde V_0 es el volumen de aire en la cámara y $V_{OWC}(t)$ es el volumen de aire instantáneo.

El volumen de aire oscilante $V_{OWC}(t)$ depende de la geometría de las cámaras de captura OWC y se define como:

$$V_{OWC_i}(t) = V_0 - S Z_i(t) \quad (11)$$

donde $S = l_c w_c$ es la superficie libre interior de la cámara y Z_i es el desplazamiento vertical del agua en forma de pistón, que aumenta en dirección ascendente.

Por tanto, la presión dentro de las cámaras depende del caudal de masa y del volumen de aire oscilante (M'zoughi, 2022), (M'zoughi, 2023):

$$\dot{p}_i(t) = \frac{p_a \gamma}{\rho_a V_0} \dot{m}_i(t) - \frac{p_a \gamma}{V_0} \dot{V}_i(t) \quad (i = 1, 2) \quad (12)$$

III. CONTROL DE FLUJO DE AIRE PROPUESTO ANFIS

Para ayudar a estabilizar la estructura FOWT, se han incorporado un par de OWC a la estructura de la plataforma de barcasas ITI Energy. Ambos OWC son idénticos y se han colocado a ambos lados de la torre (delante y detrás) a distancias iguales para mantener la simetría. Al controlar las válvulas de aire de cada OWC a través de una estrategia de control del flujo de aire para ajustar el flujo de aire y la presión

dentro de las cámaras de captura, los OWC pueden ayudar a contrarrestar algunas de las fuerzas hidrodinámicas.

El sistema de control de flujo de aire propuesto utiliza un ANFIS para gestionar eficazmente la apertura y el cierre de válvulas de aire en función del ángulo de paso θ_p , como se ilustra en la figura 2.

El controlador ANFIS toma el error del ángulo de paso de la plataforma y su derivada e y \dot{e} como entradas, produciendo las señales de control para las válvulas de aire, concretamente U_{ctrl1} y U_{ctrl2} , como salidas. A medida que las ondas oscilan, la apertura y el cierre de las válvulas regulan la liberación o atrapamiento de aire, induciendo la compresión o descompresión dentro de las cámaras. En consecuencia, se generan fuerzas en las cámaras para contrarrestar las fuerzas hidrodinámicas que actúan sobre la plataforma de la barcaza.

IV. RESULTADOS Y DISCUSIÓN

A. Rendimiento del entrenamiento del modelo ANFIS

Los datos utilizados en este experimento constan de un total de 10357 muestras. Las muestras se normalizaron, barajaron y dividieron al 70 % para el entrenamiento (7250 muestras) y al 30 % para la prueba (3107 muestras).

En primer lugar, utilizando los datos de entrenamiento de la Fig. 3.a., el modelo de controlador ANFIS obtenido arrojó los errores de entrenamiento de la Fig. 3.b.

Después de la fase de entrenamiento, se han utilizado los datos de prueba para validar los modelos de controlador ANFIS entrenados. Los datos de prueba se muestran en la Figura 4.a. El modelo de controlador ANFIS resultante produjo los errores de prueba de la Figura 4.b.




Fig. 3. Datos de entrenamiento del modelo ANFIS. a) Datos objetivo y salida prevista. b) Error de entrenamiento.




Fig. 4. Datos de prueba del modelo ANFIS. a) Datos objetivo y resultado previsto. b) Error de prueba.

B. Simulación del control ANFIS del OWC-FOWT

Para evaluar la respuesta estructural del híbrido FOWT-OWC propuesto y evaluar la eficiencia del control de flujo de aire ANFIS desarrollado, se realizó una simulación utilizando la frecuencia de resonancia de la estructura híbrida propuesta. Utilizando la frecuencia de resonancia, se introdujo una entrada de onda con una amplitud de 1 m y un periodo de 11,6 s en el modelo numérico del híbrido OWC-FOWT como se muestra en la Figura 5. El ángulo de inclinación de la plataforma de la barcaza y el desplazamiento de proa a popa de la parte superior de la torre (TTD_{FA}) se obtienen y presentan en la Fig. 6 y la Fig. 7, respectivamente.

La figura 6 muestra el ángulo de inclinación de la plataforma de la barcaza cuando se utiliza el OWC-FOWT controlado por flujo de aire ANFIS en comparación con el ángulo de inclinación de un FOWT tipo barcaza estándar. Con referencia

a estos resultados, los sistemas controlados por ANFIS regulan eficazmente las válvulas en función de la inclinación de la plataforma, lo que da como resultado una reducción notable en la inclinación de la plataforma. Específicamente, el ángulo de inclinación disminuye de $8,304^\circ$ en una barcaza estándar a $3,214^\circ$ en la barcaza basada en OWC controlada por ANFIS.

El desplazamiento longitudinal de la parte superior de la torre (TTD_{FA}) logrado por el OWC-FOWT controlado por el ANFIS se compara con el TTD_{FA} de un FOWT estándar, como se ilustra en la Figura 7. Al igual que el ángulo de inclinación, es evidente que el FOWT controlado con ANFIS ha reducido eficazmente el TTD_{FA} en condiciones de onda resonante. Específicamente, en un FOWT estándar el TTD_{FA} es de 1,3913 m y disminuye a 0,5451 m en el OWC-FOWT con un control ANFIS.




Fig. 5. Entrada de onda elegida $Z(t)$ con el periodo de onda resonante.




Fig. 6. Ángulo de inclinación de la plataforma en estructuras FOWT estándar y basadas en OWC con control ANFIS.




Fig. 7. Desplazamiento longitudinal de la parte superior de la torre (TTD_{FA}) en estructuras FOWT estándar y basadas en OWC con control ANFIS.

V. CONCLUSIONS

Este artículo presenta un concepto novedoso de control estructural activo mediante la integración de los OWC en una plataforma de barcaza de ITI Energy para un FOWT. Este enfoque innovador se basa en las contrafuerzas generadas por las presiones acumuladas dentro de las cámaras de aire de las columnas de agua oscilantes. Estas contrafuerzas tienen como objetivo mitigar las cargas hidrodinámicas que actúan sobre la estructura, reduciendo así las oscilaciones indeseables en el ángulo de inclinación de la plataforma y el desplazamiento de proa a popa de la torre, mejorando en última instancia la estabilidad general de la estructura.

Se desarrolló un modelo dinámico de orden reducido para el concepto propuesto de FOWT híbrido viento-olas, centrándose en el ángulo de inclinación de la plataforma y la flexión de proa a popa de la torre. Este modelo matemático incorpora la presión y las contrafuerzas de los OWC para analizar su impacto en las cargas hidrodinámicas opuestas que actúan sobre la plataforma. Los OWC están controlados por un sistema de control de flujo de aire, que monitorea la inclinación de la plataforma. El error de inclinación sirve como entrada para los controladores ANFIS, cuyas salidas regulan las señales de control de las válvulas. Como resultado, los controladores ajustan la presión dentro de las cámaras para mitigar el ángulo de inclinación de la plataforma y los movimientos de proa a popa de la torre.

Los resultados obtenidos demuestran que el modelo ANFIS entrenado ofrece un rendimiento excelente y revela mejoras significativas en comparación con los sistemas propuestos en el FOWT estándar. El OWC-FOWT con un control ANFIS reduce eficazmente las vibraciones de inclinación de la plataforma.

AGRADECIMIENTO

Este trabajo fue financiado en parte por el proyecto IT1555-22 financiado por el Gobierno Vasco y los proyectos PID2021-123543OB-C21 y PID2021-123543OB-C22 financiados por MCIN/AEI/10.13039/501100011033/FEDER, UE y a través de la beca Maria Zambrano MAZAM22/15 financiada por UPV-EHU/MIU/Next Generation, UE.

REFERENCIAS

- Aboutalebi, P., Garrido, A.J., Garrido, I., Nguyen, D.T. and Gao, Z. 2024. Hydrostatic stability and hydrodynamics of a floating wind turbine platform integrated with oscillating water columns: A design study. *Renewable Energy* 221, 119824. DOI: 10.1016/j.renene.2023.119824
- Aboutalebi, P., M'zoughi, F., Garrido, I. and Garrido, A.J. 2023. A control technique for hybrid floating offshore wind turbines using oscillating water columns for generated power fluctuation reduction. *Journal of Computational Design and Engineering* 10(1), 250-265. DOI: 10.1093/jcde/qwac137
- Ahmad, I., M'zoughi, F., Aboutalebi, P., Garrido, I. and Garrido, A.J. 2023. 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* 13(1), 1499. DOI: 10.1038/s41598-023-28703-z
- Ahmad, I., M'zoughi, F., Aboutalebi, P., Garrido, I. and Garrido, A. 2022. A Machine-Learning Approach for the Development of a FOWT Model Integrated with Four OWCs. In *2022 26th International Conference on Circuits, Systems, Communications and Computers (CSCC)*. pp. 72-76. Crete, Greece. IEEE. DOI: 10.1109/CSCC55931.2022.00023
- Bagheri Rouch, T., Fakharian, A. 2022. Robust control of islanded DC microgrid for voltage regulation based on polytopic model and load sharing. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering* 46(1), 171-186. DOI: 10.1007/s40998-021-00462-5
- Hu, J., Zhou, B., Vogel, C., Liu, P., Willden, R., Sun, K., Zang, J., Geng, J., Jin, P., Cui, L. and Jiang, B. 2020. Optimal design and performance analysis of a hybrid system combining a floating wind platform and wave energy converters. *Applied energy* 269, 114998. DOI: 10.1016/j.apenergy.2020.114998
- Hu, Y. and 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
- Hu, Y., Wang, J., Chen, M.Z., Li, Z. and Sun, Y. 2018. Load mitigation for a barge-type floating offshore wind turbine via inerter-based passive structural control. *Engineering Structures* 177, 198-209. DOI: 10.1016/j.engstruct.2018.09.063
- Jonkman, J., 2008, January. Influence of control on the pitch damping of a floating wind turbine. In *46th AIAA aerospace sciences meeting and exhibit*. pp. 1-15, Reno, NV, USA. DOI: 10.2514/6.2008-1306
- Jonkman, J.M., 2007. *Dynamics modeling and loads analysis of an offshore floating wind turbine*. Doctoral's Dissertation, Department of Aerospace Engineering Sciences, University of Colorado, Colorado, USA.
- Kaldellis, J.K., Kapsali, M. 2013. Shifting towards offshore wind energy-Recent activity and future development. *Energy policy* 53, 136-148. DOI: 10.1016/j.enpol.2012.10.032
- Kamarlouei, M., Gaspar, J.F., Calvario, M., Hallak, T.S., Mendes, M.J., Thiebaut, F., Soares, C.G., 2020. Experimental analysis of wave energy converters concentrically attached on a floating offshore platform. *Renewable Energy* 152, 1171-1185. DOI: 10.1016/j.renene.2020.01.078
- Kluger, J.M., Slocum, A.H. and Sapsis, T.P. 2017. A first-order dynamics and cost comparison of wave energy converters combined with floating wind turbines. In *27th International Ocean and Polar Engineering Conference*, San Francisco, California, USA. ISBN: 978-1-880653-97-5
- Lackner, M.A. and Rotea, M.A. 2011. Structural control of floating wind turbines. *Mechatronics*, 21(4), 704-719. DOI: 10.1016/j.mechatronics.2010.11.007
- M'zoughi, F., Aboutalebi, P., Ahmad, I., Garrido, I. and Garrido, A.J., 2022, July. Dual Airflow Control Strategy for Floating Offshore Wind Turbine Stabilization Using Oscillating Water Columns. In *APCA International Conference on Automatic Control and Soft Computing*. 428-438. Cham: Springer International Publishing. DOI: 10.1007/978-3-031-10047-5_38
- M'zoughi, F., Aboutalebi, P., Garrido, I., Garrido, A.J. and 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
- M'zoughi, F., Garrido, I. and Garrido, A.J. 2020. Symmetry-breaking for airflow control optimization of an oscillating-water-column system. *Symmetry* 12(6), 895. DOI: 10.3390/sym12060895
- M'zoughi, F., Garrido, I., Garrido, A.J. and De La Sen, M. 2023. Fuzzy airflow-based active structural control of integrated oscillating water columns for the enhancement of floating offshore wind turbine stabilization. *International Journal of Energy Research*, 2023. DOI: 10.1155/2023/4938451
- M'zoughi, F., Garrido, A.J., Garrido, I., Bouallègue, S. and Ayadi, M., 2018, June. Sliding mode rotational speed control of an oscillating water column-based wave generation power plants. In *2018 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*. pp. 1263-1270. Amalfi, Italy. IEEE. DOI: 10.1109/SPEEDAM.2018.8445229
- Pérez-Collazo, C., Greaves, D., Iglesias, G. 2015. A review of combined wave and offshore wind energy. *Renewable and sustainable energy reviews* 42, 141-153. DOI: 10.1016/j.rser.2014.09.032
- Slocum, A., Kluger, J. and Mannai, S. 2019, July. Energy harvesting and storage system stabilized offshore wind turbines. In *2019 Offshore Energy and Storage Summit (OSES)*. pp. 1-6. BREST, France. IEEE. DOI: 10.1109/OSES.2019.8867345
- Stewart, G. and Lackner, M. 2013. Offshore wind turbine load reduction employing optimal passive tuned mass damping systems. *IEEE Transactions on Control Systems Technology* 21(4), 1090-1104. DOI: 10.1109/TCST.2013.2260825
- Vijfhuizen, W.J.M.J., 2006. Design of a Wind and Wave Power Barge. Master's Dissertation, Department of Naval Architecture and Mechanical Engineering, Universities of Glasgow and Strathclyde, Glasgow, Scotland

First Wind Power Prototype Response for System Behavior Analysis

Eduardo Muñoz-Palomeque
Departamento de Arquitectura de
Computadores y Automática
Universidad Complutense de Madrid
Madrid, España
ORCID 0000-0001-8994-3459

David Sanz
Universidad Complutense de Madrid
Madrid, España
davsan13@ucm.es

Lía García-Pérez
Departamento de Arquitectura de
Computadores y Automática
Universidad Complutense de Madrid
Madrid, España
ORCID 0000-0002-6519-9108

Abstract— This article covers the initial analysis of the characterization of a scale wind turbine. The study of the wind system in a prototype that replicates the behavior of a real model is important to understand and experimentally test its operation, allowing for further study in the design and improvement of its components and subsystems. The analysis is carried out based on experimental measurements where the simplified and scaled prototype of a wind turbine is subjected to different wind speed conditions. As a result, the rotation speed and generated power curves are obtained, which describe the dynamic response of the turbine to changes in wind conditions. They show a behavior trend that resembles the theoretical response of a wind turbine.

Keywords—wind turbine, characterization, prototype, turbine speed.

Resumen—El presente artículo cubre la realización de un análisis inicial de la caracterización de una turbina eólica a escala. El estudio del sistema eólico en un prototipo que replique el comportamiento de un modelo real es importante para entender y probar de manera experimental su funcionamiento, permitiendo profundizar en el diseño y mejora de sus componentes y subsistemas. El análisis se realiza en función de mediciones experimentales donde el prototipo simplificado y a escala de una turbina eólica es sometido a diferentes condiciones de velocidad de viento. Como resultado, se obtienen las curvas de velocidad de rotación y potencia generada, que describen la respuesta dinámica de la turbina para cambios de las condiciones de viento. Los resultados muestran una tendencia de comportamiento que se asemeja a la respuesta teórica de un aerogenerador.

Palabras clave—turbina eólica, caracterización, prototipo, velocidad de la turbina.

I. INTRODUCCIÓN

La energía eólica, y las tecnologías que permiten su aprovechamiento, se han convertido, a lo largo de las últimas décadas, en una de las fuentes más importantes dentro del marco de las energías renovables [1], [2]. Su bajo impacto ambiental ha contribuido a su uso como uno de los reemplazos a los combustibles fósiles [3].

En este marco de aplicación, y por la importancia dentro de la producción de energía, el entendimiento de su modo de operación y modelado del sistema implican un paso fundamental para el perfeccionamiento del aerogenerador y sus elementos constitutivos. De esta manera, la caracterización de un aerogenerador comprende una tarea de alta fiabilidad para estudiar el modelo con mayor precisión en su diseño, orientado a la labor de predicción y optimización en la generación de potencia [4].

En este marco de estudio, el uso de modelos de turbina a escala y pruebas en túneles de viento han sido desarrolladas con múltiples objetivos, como el análisis de los efectos estructurales, de diseño de las palas, o el rendimiento del modelo [5], [6].

Siguiendo esta línea, se pueden ejemplificar algunos casos experimentales. Por ejemplo, en [7] los autores desarrollan experimentos en un túnel de viento para medir las cargas sobre un modelo de aerogenerador a pequeña escala y estudiar el número de Reynolds y el rendimiento del sistema. En [8], se utiliza también un modelo de turbina a escala para la medición del coeficiente de empuje C_t en experimentos desarrollados en un túnel de viento, con el propósito de caracterizar el rendimiento de dos rotores.

Fundamentado en las ventajas y el amplio campo de estudio con prototipos de turbinas eólicas, en este trabajo se presentan las principales mediciones de un modelo a escala de un aerogenerador terrestre. El objetivo es estudiar la respuesta del sistema físico como primer paso en el proceso de caracterización. Esto permitirá comprender el comportamiento del aerogenerador en un prototipo que interactúa con el mundo real, en contraposición a una representación computacional aproximada. De esta manera, el modelo del aerogenerador puede ser utilizado como un dispositivo para un posterior análisis del sistema y control.

Con este estudio se verifica la viabilidad de utilizar un prototipo a escala como modelo representativo de un aerogenerador real. Para ello, se han medido las variables físicas más importantes involucradas en el proceso de generación de energía, considerando tres velocidades de viento diferentes.

La estructura de este artículo se divide de la siguiente manera. En la Sección II, se explican brevemente los principios del aerogenerador. El modelo físico del aerogenerador utilizado para el estudio se describe en la Sección III. La Sección IV presenta los resultados del experimento con el aerogenerador. Finalmente, la Sección V resume los principales hallazgos de este trabajo y los pasos futuros en su estudio.

II. FUNDAMENTOS DE LA TURBINA EÓLICA

La operatividad de un sistema eólico está regido por la velocidad de viento que fluye hacia la turbina e impacta sobre las palas. Durante su funcionamiento, se distinguen dos etapas principales: la región de seguimiento del punto de máxima potencia (MPPT), y la región de control de ángulo pitch, denominadas Región II y Región III de operación, respectivamente, tal como se ilustra en la Fig. 1.

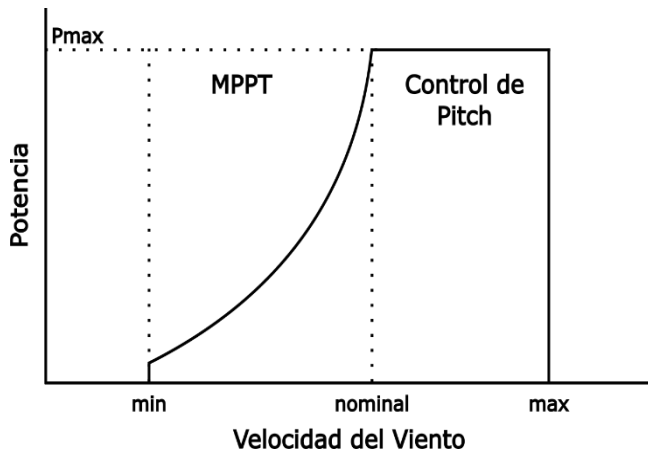


Fig. 1. Regiones de operación de una turbina eólica

Se observa que en la región MPPT, cuando el ángulo de pitch se fija en el valor mínimo óptimo, la potencia adquiere un comportamiento no lineal creciente a medida que la velocidad de viento aumenta, siendo la máxima potencia posible que puede ser generada frente a cada entrada de viento. Esta condición hace posible el máximo aprovechamiento de la energía del viento.

Por otra parte, la región de control de pitch mantiene la potencia constante en su valor nominal, por lo que el ángulo de rotación de las palas se ajusta para permitir el aumento o decremento de la cantidad de viento que llega al aerogenerador.

Matemáticamente, la energía disponible en el viento (1) se expresa en función de su velocidad V_w y densidad ρ , así como del radio de la turbina R , medido desde el eje de rotación hasta el punto más alejado de las palas.

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

Sin embargo, la energía capturada por el sistema eólico se ve determinado por su eficiencia en el proceso de conversión, influido por su diseño aerodinámico, el generador, y demás mecanismos que constituyen el aerogenerador. De esta manera, la potencia capturada se representa en (2) con la introducción del coeficiente de potencia C_p .

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

El coeficiente de potencia indica esa efectividad en la conversión de energía, que se expresa como una relación determinada por el ángulo de pitch y la relación de velocidad en la punta de las palas (TSR). Este último parámetro, descrito en (3), se calcula como el cociente entre la velocidad tangencial en la punta de las palas y la velocidad del viento incidente.

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

en esta expresión, ω_r es la velocidad angular del rotor.

III. Experimentación con Modelo Físico de la Turbina Eólica

La representación física de un sistema de energía eólica puede resultar complicada debido a la compleja integración entre los sistemas mecánicos, aerodinámicos, eléctricos y de control. Al trabajar con un modelo físico a escala, el sistema se ve sometido a los efectos de las condiciones ambientales reales con cambios en el comportamiento de los fenómenos y la respuesta del sistema. Por lo tanto, la representación real del sistema podría proporcionar información extensa sobre cómo funcionan todos los componentes y cómo interactúan entre sí y con el entorno.

Este primer modelo se elaboró específicamente para abordar el estudio de la caracterización del sistema de generación de energía eólica. La representación del aerogenerador es una estructura de componentes impresos en ácido poliláctico (PLA) con las características especificadas en la Tabla 1. Consiste en una representación genérica de la tecnología de un aerogenerador que imita los principios de su construcción. El modelo de energía eólica de 3 palas está fijado sobre una plataforma y conectado a un motor de 12V de corriente continua en modo generador, con un encoder incorporado para recuperar la velocidad de rotación del aerogenerador.

Las mediciones de las variables asociadas al sistema eólico se realizan mediante el uso de una placa Arduino Mega. El software Matlab está vinculado a la placa física para una comunicación interactiva en tiempo real desde un ordenador.

TABLA I. CARACTERÍSTICAS FÍSICAS DEL AEROGENERADOR

Parámetro	Valor
Tipo	Onshore wind turbine
Número de blades	3
Longitud de los blades	0.17 m
Esperor máximo del blade	0.04 m
Voltaje del Motor	12 V
Rango de ángulo Pitch	8 – 26 deg
Relación de la Caja de Engranajes	1:1

Para realizar el experimento se utiliza una fuente de viento de 3 velocidades para transmitir la masa de viento al centro del rotor del aerogenerador, cubriendo el área barrida por las palas. La velocidad en la posición del rotor se mide con un anemómetro, obteniendo el valor estable de los modos de baja, media y alta velocidad de la fuente antes de realizar los experimentos.

Durante las pruebas se coloca la fuente de viento adaptable a tres velocidades diferentes frente al modelo de aerogenerador, proporcionando el flujo de viento para probar el comportamiento del sistema bajo velocidades de viento constantes.

Además, se configura una placa Arduino Mega para tomar datos del aerogenerador en tiempo real, como la velocidad del generador, el ángulo de paso y la señal de voltaje del generador. Una vez finalizado el ensayo, los datos adquiridos se procesan y analizan mediante el software Matlab. La Fig. 2 muestra este proceso.




Fig. 2. Adquisición y procesamiento de datos

Durante los experimentos y para cada velocidad de viento utilizada, se realizan numerosas pruebas ajustando el ángulo de paso de las palas a un valor distinto, cubriendo todo el rango disponible de variación de paso del prototipo de aerogenerador.

Después de la adquisición, las mediciones de voltaje y velocidad son filtradas utilizando un filtro de promedio móvil, obteniendo la base de datos con la cual se analiza el comportamiento del sistema eólico.

Haciendo uso de los parámetros de la turbina eólica y los datos adquiridos de los experimentos, se calcula la potencia de salida y las señales TSR. Además, se extraen los valores medios correspondientes de los datos procesados para representar algunas curvas características de la turbina eólica.

La potencia de salida con el prototipo de turbina eólica utilizado en este estudio se calcula en términos de la señal de

voltaje eléctrico medida del generador, utilizando la expresión (4).

$$P = V \cdot I = \frac{V^2}{R} \quad (4)$$

Por otro lado, la variable TSR se determina empleando la ecuación (3), donde también son necesarias las características del aerogenerador, como el radio del rotor, además de la medición de la velocidad de viento con la que se realizan los experimentos.

IV. RESULTADOS EXPERIMENTALES

Se ha medido la respuesta del sistema considerando tres velocidades de viento distintas: 3.73, 4.6 y 5.7 m/s, y ocho ángulos de pala diferentes: 9°, 12°, 14°, 15°, 18°, 21°, 24° y 27°. Cada una de las posiciones de pitch se evalúan frente a cada condición de viento. No se han podido emplear ángulos menores o mayores debido a que el mecanismo de sujeción de las palas en el prototipo de la turbina eólica limita su giro en ese rango.

Con las medidas efectuadas, es posible verificar la respuesta cinemática del rotor, cuyo comportamiento depende únicamente de la velocidad de viento que incide sobre las aspas y ocasiona su movimiento. La Fig. 3 muestra el conjunto de señales de velocidad angular para cada combinación de ángulo pitch y velocidad de viento.




Fig. 3. Respuesta de Velocidad del generador para diferentes ángulos de pitch, frente a tres velocidades de viento: 3.73 m/s (línea azul), 4.6 m/s (línea roja) y 5.7 m/s (línea amarilla)

Se observa que para cada caso, la velocidad que adquiere el generador se incrementa proporcionalmente con la velocidad de viento. Esta primera consideración contribuye a una verificación inicial de que el modelo de turbina, y la aerodinámica de las palas, responden a la tendencia de comportamiento esperado del sistema.

Analizando los resultados para valores intermedios del ángulo pitch, entre 12° y 18°, la velocidad del rotor es superior, coincidiendo con el rango de máxima superficie de impacto

de las palas con el viento. Fuera de este rango, con un aumento o disminución del ángulo de pitch, la velocidad del aerogenerador disminuye.

Este efecto se observa con mayor claridad en la Fig. 4, que muestra la velocidad del aerogenerador en función de los distintos ángulos de pitch. De esta gráfica se puede establecer el ángulo óptimo de operación en 14°, que corresponde con los valores máximos de velocidad alcanzada por el

aerogenerador: 70.35, 187.85 y 268.87 rpm, para las velocidades de viento baja, media y alta, respectivamente.

Extendiendo el análisis, el TSR para el modelo de turbina utilizado en el experimento se ilustra en la Fig. (5). Se muestra como este factor de relación de velocidades se incrementa con el correspondiente aumento del flujo de viento, llegando a los máximos, aproximadamente, con la posición de las palas fijas en 14°. Para el rango de viento utilizado en estos experimentos, el TSR oscila entre 0.3 y 0.9.




Fig. 4. Respuesta de velocidad a cambios de ángulo pitch

La Fig. 6 presenta la potencia promedio generada en cada caso de estudio con diferente ángulo de las palas. La respuesta del sistema en la generación de energía es análoga a la velocidad. La potencia producida es cada vez mayor a medida que la velocidad del viento crece en magnitud. Del mismo modo, el rango de producción máxima, considerando la configuración probada en los experimentos, se mantiene

cuando el pitch se fija alrededor de los 14°. Por lo tanto, se determina este ángulo como el óptimo para la máxima captura de energía de esta turbina eólica, logrando una extracción de 0.29W a la mayor velocidad de viento probada.

Sin embargo, es importante destacar la falta de continuidad en la respuesta eléctrica del modelo. En este sentido, se observan picos o variaciones irregulares en la señal que interfieren en el proceso ideal de caracterización del sistema, afectando la descripción de su comportamiento óptimo.

Con estos resultados, el ángulo de pitch de 14°, es la opción más viable como punto de configuración del modelo para máxima generación de energía en este prototipo, evidenciado los altos valores de potencia y velocidad de generador. A partir de esta consideración, se tiene una referencia de la manera en que el sistema eólico reacciona a la entrada de viento. Es decir, se identifican puntos importantes para su caracterización.

La respuesta general del aerogenerador indica, por tanto, la posibilidad de identificar aspectos claves del sistema. En primer lugar, el perfil aerodinámico de las palas del modelo se orienta al viento con una mayor área cuando el ángulo de pitch se encuentra ligeramente rotado respecto al plano frontal del aerogenerador.

Con las condiciones de viento utilizadas en las pruebas, se ha visto que a medida que la posición angular de los blades aumenta respecto a su valor óptimo identificado, la velocidad del generador disminuye. Entonces, la superficie de contacto con el viento se reduce y deja pasar el flujo de aire sin ejercer un trabajo sobre las palas. Además, la velocidad de viento de 5.7 m/s produce una respuesta más estable del sistema a diferentes ángulos de pitch, con lo que el efecto de las alteraciones de la señal de voltaje del generador se reduce, al incrementar su velocidad y evitar la aparición de los picos de corriente generados por el movimiento del rotor.

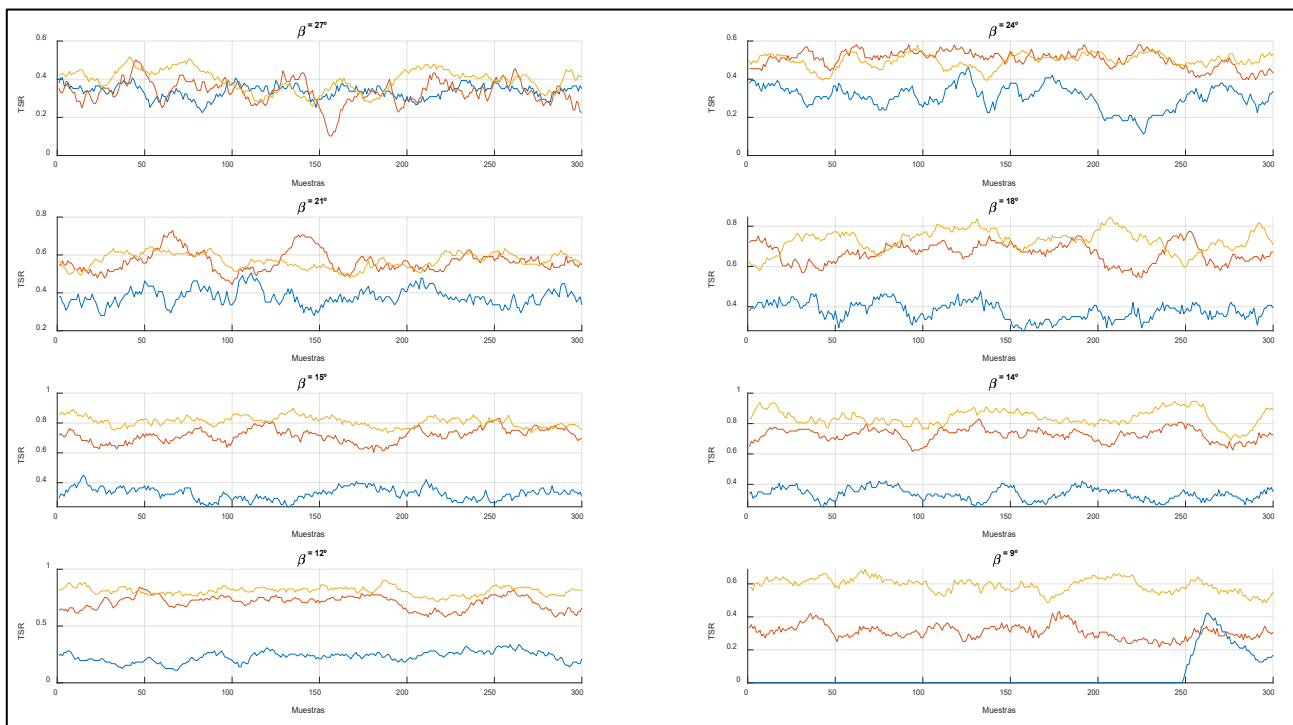


Fig. 5. Respuesta de TSR para diferentes ángulos de pitch, frente a tres velocidades de viento: 3.73 m/s (línea azul), 4.6 m/s (línea roja) y 5.7 m/s (línea amarilla)

Sin embargo, la respuesta del sistema queda limitada a una interpretación a bajas velocidades de viento. El aerogenerador podría trabajar a mayores velocidades para cubrir el rango total de operación, completando y saliendo de la región MPPT, y logrando una completa caracterización del modelo.




Fig. 6. Respuesta de potencia a cambios de ángulo pitch

V. CONCLUSIONES

El modelo físico del aerogenerador utilizado para la experimentación en este estudio demostró que puede utilizarse como punto de partida para una representación factible de un sistema real. Las variables medidas con este dispositivo se ajustan inicialmente a la tendencia de comportamiento de un sistema eólico común.

Los cambios en el ángulo de paso modifican la respuesta, velocidad y potencia del aerogenerador, capturando distinta cantidad de energía del viento en función del ángulo de ataque utilizado en cada caso. Con estos comportamientos, el TSR correspondiente y la relación entre variables proporciona una idea general para caracterizar el prototipo del aerogenerador.

Se ha evidenciado que el tipo de motor DC con escobillas utilizado como generador de energía en este prototipo, ocasiona la aparición de picos de voltaje que afectan a la apropiada generación de la curva de potencia, especialmente a bajas velocidades.

En trabajos futuros, se optimizará el modelo físico en términos mecánicos, eléctricos y de adquisición de datos, para obtener una mejor representación de un aerogenerador real y realizar una caracterización completa del sistema para

aplicaciones prácticas. Además, se estudiará la mejora del perfil de las palas. Se optimizará su diseño para ampliar el rango de ataque de las palas, desde un ángulo menor, para aprovechar un mayor espectro de variación y ajuste cuando la velocidad de viento se incremente. Con esto, se estudiará la mejora del diseño aerodinámico del aerogenerador.

Por último, es importante probar el dispositivo frente a un rango más amplio de velocidades de viento, para determinar la potencia de extracción máxima a los 14° que los resultados indican ser los óptimos de pitch en MPPT. Con esta información se pretende verificar cuál sería el óptimo TSR, donde la eficiencia en generación de energía también se incremente.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación de España, enmarcado en el proyecto MCI/AEI/FEDER No. PID2021-123543OB-C21.

REFERENCIAS

- [1] M. Elgendi, M. AlMallahi, A. Abdelkhalig, and M. Y. E. Selim, "A review of wind turbines in complex terrain," *International Journal of Thermofluids*, vol. 17, p. 100289, Feb. 2023. doi:10.1016/j.ijft.2023.100289
- [2] Z. Maheshwari, K. Kengne, and O. Bhat, "A comprehensive review on wind turbine emulators," *Renewable and Sustainable Energy Reviews*, vol. 180, p. 113297, Jul. 2023. doi:10.1016/j.rser.2023.113297
- [3] T. Wilberforce, A. G. Olabi, E. T. Sayed, A. H. Alalmi, and M. A. Abdelkareem, "Wind turbine concepts for domestic wind power generation at low wind quality sites," *Journal of Cleaner Production*, vol. 394, p. 136137, Mar. 2023. doi:10.1016/j.jclepro.2023.136137
- [4] F. Carbajo Fuertes, C. D. Markfort, and F. Porté-Agel, "Wind turbine wake characterization with nacelle-mounted wind lidars for analytical wake model validation," *Remote Sensing*, vol. 10, no. 5, p. 668, Apr. 2018. doi:10.3390/rs10050668
- [5] Y. Hou, L. Zhang, J. Jia, T. Qiu, and J. Wang, "Characterization of wind turbine blade deformation and wake flow field with different numbers of lay-up layers," *Applied Sciences*, vol. 14, no. 23, p. 11149, Nov. 2024. doi:10.3390/app142311149
- [6] H. Zhang, Y. Hu, and W. Wang, "Wind Tunnel Experimental Study on the aerodynamic characteristics of straight-bladed vertical axis wind turbine," *International Journal of Sustainable Energy*, vol. 43, no. 1, Feb. 2024. doi:10.1080/14786451.2024.2305035
- [7] M. A. Miller, J. Kiefer, C. Westergaard, and M. Hultmark, "Model wind turbines tested at full-scale similarity," *Journal of Physics: Conference Series*, vol. 753, p. 032018, Sep. 2016. doi:10.1088/1742-6596/753/3/032018
- [8] F. Cuzzola, S. Aubrun, and B. Leitl, "Characterization of a wind turbine model for wake aerodynamics studies," *Journal of Physics: Conference Series*, vol. 555, p. 012023, Dec. 2014. doi:10.1088/1742-6596/555/1/012023

Experimentos de relajación de un prototipo de FOWT

Segundo Esteban San Román
Dept. Arquitectura de Computadores y Automática
Faculty of Physics
Universidad Complutense de Madrid
28040-Madrid, España
sesteban@ucm.es

Tahereh Bagheri-Rouch
Instituto de Investigación y Desarrollo de Procesos- IIDP
Faculty of Engineering of Bilbao,
University of the Basque Country UPV/EHU
48013, Bilbao, Spain
tahereh.bagheri@ehu.eus

Eduardo Muñoz-Palomeque
Departamento de Digitalización
Universidad de Burgos
09006-Burgos, España
emp1016@alu.ubu.es

Payam Aboutalebi
Instituto de Investigación y Desarrollo de Procesos- IIDP
Faculty of Engineering of Bilbao,
University of the Basque Country UPV/EHU
48013, Bilbao, Spain
payam.aboutalebi@ehu.eus

Abstract— This article describes different experimental tests that have been carried out with UCM's small-scale floating wind turbine prototypes and the UPV/EHU's barges with moonpools. The natural dynamics of the barge-type floating wind turbine anchored to the bottom by four lines are analyzed and identified. This dynamic is compared in different situations, with open, closed and controlled oscillating moonpools. The stabilization capacity of a gyroscopic actuator is also analyzed.

Resumen—En este artículo se describen diferentes pruebas experimentales que se han realizado con prototipos de aerogeneradores flotantes a escala reducida de la UCM con las barcasas con columna oscilante de la UPV/EHU. Se analiza la dinámica natural del aerogenerador flotante de tipo barcaza anclado al fondo mediante cuatro líneas. Se compara esta dinámica con el comportamiento en diferentes situaciones, con columnas de agua oscilante abiertas, cerradas y controladas. También se analiza la capacidad de estabilización de la barcaza utilizando un actuador giroscópico.

Keywords— *Floating Offshore Wind Turbine; Moonpools; Gyroscopic Damping; Experimental Test.*

I. INTRODUCCIÓN

Tras el desarrollo de diferentes prototipos de aerogeneradores en la UCM y el diseño de prototipos de barcasas con columnas de agua oscilantes en la UPV/EHU, dentro del proyecto de investigación conjunto [1], se plantea la necesidad de confluír en pruebas experimentales con los prototipos. Se han realizado experimentos con prototipos de FOWT (Floating Offshore Wind Turbine) a escala reducida en el canal de olas de la UPV/EHU. Esta confluencia presenta una gran complejidad, es necesario trabajar con sistemas aerodinámicos, hidrodinámicos, eléctricos y mecánicos. Además, es necesario excitar estos sistemas con oleajes y vientos y monitorizarlos y controlarlos.

En la UCM se han desarrollado diferentes prototipos de aerogeneradores y sus sistemas de monitorización [2-4]. Algunos de estos han sido adaptados para su montaje en barcasas flotantes para poder ser utilizados en estos experimentos.

Se probaron dos tipos de barcaza, ancladas mediante cuatro líneas al fondo del canal, como muestra la Fig. 1. Como sistema de anclaje se utilizaron ventosas, pues el fondo del canal es de metacrilato. También se probaron diferentes longitudes de cadenas, hasta dar con un comportamiento elástico equivalente al que se pueden encontrar en los sistemas reales, que permitiese cierto grado de libertad.




Fig. 1. Barcaza anclada al fondo mediante cuatro líneas.

Sobre los dos tipos de barcaza se montaron los prototipos de aerogeneradores instrumentados, como se muestra en la Fig. 2. Se puede observar en la figura que las columnas de agua están posicionadas en la proa y en la popa de la barcaza, estando abiertas en este caso. Se probaron dos configuraciones de FOWT:

1. Aerogenerador forzado y barcaza con columnas de agua (MP) abiertas o cerradas.
2. Aerogenerador con estabilizador giroscópico y barcaza con columnas de agua controlables.

El estabilizador giroscópico consiste en un disco de inercia alineado con el mástil del aerogenerador que añade estabilidad giroscópica a todo el sistema.

Se han realizado una amplia gama de experimentos: relajación con columnas abiertas, con columnas cerradas y con columnas controladas.

- Con y sin viento.
- Con giróscopos estabilizadores activos y sin ellos.




Fig. 2 Prototipos de FOWT instrumentados. La imagen izquierda es un aerogenerador forzado sobre barcaza de columnas de agua abiertas o cerradas. La imagen derecha es un aerogenerador libre, sobre barcaza con estabilizador giroscópico y columnas de agua controlables.

II. MODELADO MATEMÁTICO

Aunque existen modelos matemáticos de turbinas con mayor detalle [5], para poder identificar el efecto de los diferentes subsistemas se modela la dinámica del grado de libertad de cabeceo o “pitch”, ϕ , mediante una ecuación diferencial lineal de segundo orden (1). Esto permitirá extraer los parámetros principales del comportamiento del sistema.

$$I \cdot \ddot{\phi}(t) + D \cdot \dot{\phi} + K \cdot \phi = T_{actuador} \quad (1)$$

Donde:

- I es el momento de inercia principal respecto al grado de libertad de cabeceo. Este depende de la distribución de masas del sistema y del centro de giro del sistema, que a su vez es función del centro de flotación del sistema.
- D es el factor de amortiguamiento. Este depende principalmente de la hidrodinámica de la barcaza y del comportamiento aerodinámico del aerogenerador.
- K es el factor de restauración. Este valor depende principalmente de la hidrodinámica de la barcaza y de las características de las líneas de anclaje.
- $T_{actuador}$ representan los pares de control que podemos generar a través de los diferentes actuadores, como pueden ser: Columnas de agua, Actuadores giroscópicos y Control del paso de aspas.

Se puede normalizar la ecuación diferencial dividiendo momento de inercia, para no tener que identificar este valor. De esta forma se trabajaría con pares perturbaciones normalizados respecto a la inercia del sistema.

III. DINÁMICA CON COLUMNAS DE AGUA

A. Columnas de agua pasivas

Se realizaron pruebas de respuesta de relajación para identificar la dinámica del sistema sin perturbar, es decir sin oleaje y sin viento. Para ello, se forzó al sistema a un pitch inicial hundiendo la proa o la popa de la barcaza varias veces, obteniéndose los comportamientos registrados en Fig. 3.

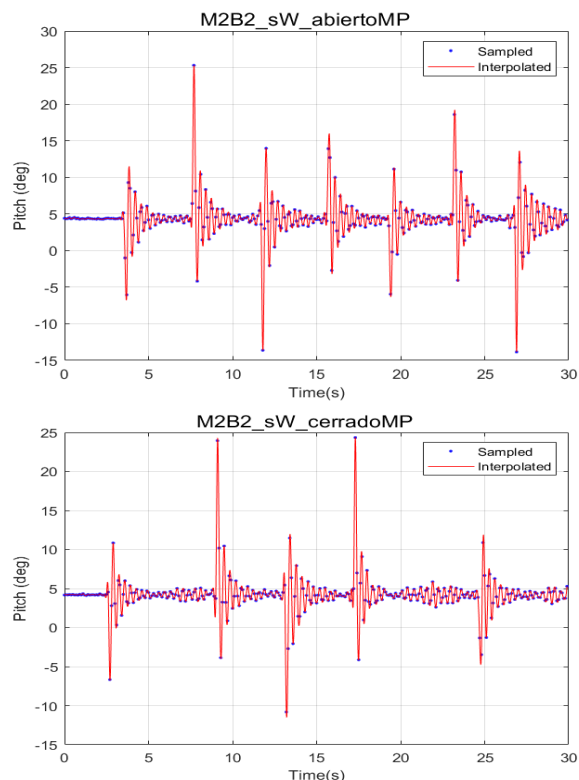


Fig. 3. Experimentos de relajación del sistema sin oleaje ni viento, con columnas de agua abiertas, cerradas y controladas.

El muestreo de datos se realizó con un periodo de 0.1 segundos. Tras analizar la rápida respuesta del sistema, se concluye que es necesario trabajar con un periodo más fino, por lo que se han interpolado los datos mediante splines con un periodo de 0.01s.

A partir de los datos interpolados se ha seleccionado uno de los experimentos de relajación para identificar el modelo matemático. En Fig. 4 se muestran la validación temporal de los modelos matemáticos identificado. En esta validación se puede verificar que los modelos capturan adecuadamente la frecuencia natural del sistema, pero no ocurre lo mismo con el amortiguamiento. El amortiguamiento del sistema presenta un comportamiento no lineal, pues es mucho más agresivo cuando hay grandes cambios de pitch que cuando estos cambios son más pequeños. Este comportamiento se puede deber a las masas añadidas de agua que también son desplazadas, las cuales no pueden considerarse en un modelo lineal.

En la tabla 1 se presentan los polos del modelo identificado. Los modelos para los casos de columnas de agua abiertas y columnas de agua cerradas son muy similares. Parece que el efecto de tenerlas abiertas o cerradas no es muy representativo en la dinámica natural del sistema.

TABLA 1 PARÁMETROS IDENTIFICADOS COLUMNAS ESTÁTICAS.

Poles	Damping	Frequency (rad/seconds)	Time Constant (seconds)
Columnas abiertas			
-3.48e+00 + 1.73e+01i	1.97e-01	1.77e+01	2.88e-01
-3.48e+00 - 1.73e+01i	1.97e-01	1.77e+01	2.88e-01
Columnas cerradas			
-3.29e+00 + 1.72e+01i	1.88e-01	1.75e+01	3.04e-01
-3.29e+00 - 1.72e+01i	1.88e-01	1.75e+01	3.04e-01




Fig. 4. Identificación de la identificación de la dinámica natural del sistema: con columnas de agua cerradas y abiertas.

B. Columnas de agua activas

Se realizaron experimentos, mostrados en Fig. 5, en los cuales se controlaban las columnas de agua de forma activa. En un primer enfoque el control consistía en abrir o cerrar las columnas de agua en función del signo de la velocidad angular de pitch.




Fig. 5. Experimento de relajación del sistema sin oleaje ni viento, con columnas de agua controladas.

En este caso, las columnas de agua capturan agua y lo sueltan en otro momento, añadiendo un efecto de masas añadidas al modelo, que equivale a un sistema con más inercia. Esto se traduce en una frecuencia de oscilación más baja y amortiguamiento inferior como se puede apreciar en la Fig. 6 y en la Tabla 2.

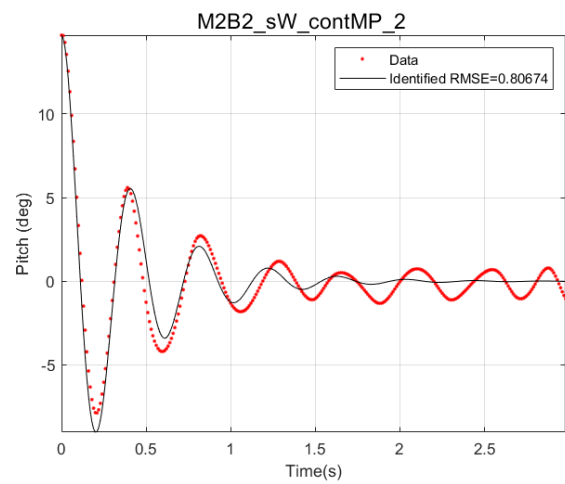


Fig. 6. Identificación de la identificación de la dinámica natural del sistema: con columnas de agua controlada.

TABLA 2 PARÁMETROS IDENTIFICADOS COLUMNAS CONTROLADAS.

Pole	Damping	Frequency (rad/seconds)	Time Constant (seconds)
Columnas controladas			
-2.40e+00 + 1.55e+01i	1.53e-01	1.56e+01	4.17e-01
-2.40e+00 - 1.55e+01i	1.53e-01	1.56e+01	4.17e-01

IV. DINÁMICA CON ESTABILIZADORES GIROSCÓPICOS

Se realizaron experimentos activando y desactivando el actuador giroscópico. El actuador giroscópico consiste en un motor con un disco de inercia, donde el eje de rotación está alineado con el mástil del aerogenerador. Cuando el actuador giroscópico tiene suficiente momento angular, éste genera pares cruzados a los pares perturbadores de pitch, generando un movimiento de precesión sobre el aerogenerador que distribuye la energía entre los diferentes grados de libertad. Fig. 7 muestra los resultados registrados en los experimentos. En este caso los experimentos tienen un tiempo de estabilización mayor, que se debe a que las líneas de anclaje son más largas, permitiendo que la dinámica de flotabilidad gane más peso. Por ello, en la identificación del sistema que se muestra en la Fig. 8, ya se aprecia un comportamiento más lineal y el tiempo de estabilización es mayor, como se puede ver en la Tabla 3.

TABLA 3 PARÁMETROS IDENTIFICADOS CON GIRÓSCOPOS.

Poles	Damping	Frequency (rad/seconds)	Time Constant (seconds)
Giróscopo inactivo			
-1.40e+00 + 8.98e+00i	1.54e-01	9.09e+00	7.14e-01
-1.40e+00 - 8.98e+00i	1.54e-01	9.09e+00	7.14e-01
Giróscopo activo			
-1.32e+00 + 8.96e+00i	1.46e-01	9.06e+00	7.59e-01
-1.32e+00 - 8.96e+00i	1.46e-01	9.06e+00	7.59e-01

Comparando los experimentos con actuador giroscópico y sin él, el efecto del giróscopo pasa prácticamente desapercibido. Esto se debe a que es un sistema extremadamente subactuado, donde el efecto de la flotabilidad y las líneas de anclaje predominan sobre otros actuadores.



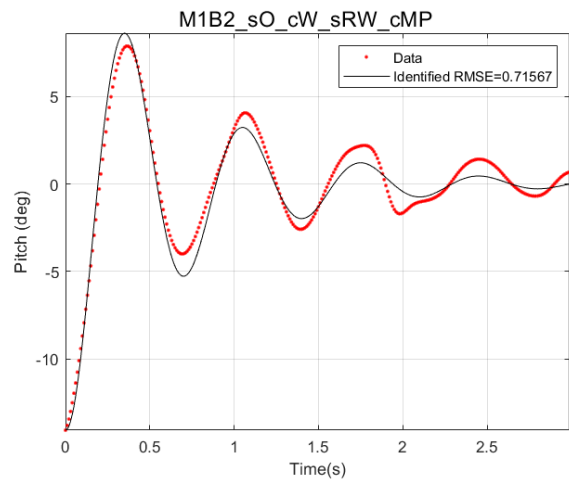



Fig. 7. Experimentos de relajación del sistema: sin giróscopo y con giróscopo.

Fig. 8. Identificación de la dinámica natural del sistema: sin giróscopo y con giróscopo.

V. CONCLUSIONES Y TRABAJOS FUTUROS

Se han integrados los prototipos de aerogeneradores de la UCM con las barcasas con columnas oscilantes de agua de la UPV/EHU. Se han realizado experimentos preliminares para evaluar la viabilidad de identificar modelos dinámicos que contemplen estos actuadores, para en un futuro diseñar sistemas de control.

Se han detectado algunos problemas en el uso del instrumento de medida, un Arduino Mega [6]. La programación del sistema de toma de muestras se realizaba sobre Matlab, lo que limitaba el periodo de muestreo a 0.1s. Debido a la rápida dinámica del sistema es necesario trabajar con periodos de muestreo más finos, en el orden de 0.01s. Esto se puede conseguir programando directamente en C los microcontroladores encargados de tomar los datos.

Los experimentos de relajación muestran un comportamiento no lineal. Se han identificado modelos lineales, pero para ser más precisos sería necesario realizar una identificación de modelos no lineales o modelos lineales con parámetros variables. Se pone de manifiesto la relevancia del sistema de anclaje en la dinámica del sistema, por lo que es muy importante fijar ésta para todos los experimentos.

En los experimentos de relajación se ha detectado muy poco efecto por parte de las columnas de agua oscilante y por parte de los actuadores giroscópicos. Esto se puede deber a que los prototipos de OSWT son demasiado estables, convirtiéndose en un problema subactuado, donde cualquier actuador manifiesta muy poco efecto respecto a la constante restauradora del sistema, que es proporcionada por el sistema de anclaje y la flotabilidad de la barcaza. Es necesario ser más realistas en esta faceta. Esto se puede conseguir subiendo el centro de gravedad del sistema y utilizando líneas de anclaje más largas.

Actualmente se está mejorando el sistema experimental en las líneas que se han descrito. Se realizarán nuevos experimentos en los que se esperan obtener resultados más realistas y que permitan cuantificar la capacidad de los diferentes tipos de actuadores para estabilizar el sistema.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación de España, con el proyecto MCI/AEI/FEDER número PID2021-123543OBC21.

REFERENCIAS

- [1] WEB Proyecto. <https://www.floatingwindturbineucm.com/>
- [2] Aimara, G. A., & San Román, S. E. (2022). Modelo a Escala de Aerogenerador para Control. In *Irakaskuntzaren berrikuntza kontrol ingeniarietan itsas energian* (pp. 53-58).

- [3] Universidad Complutense de Madrid. (n.d.). Arquitectura Hardware para el Control Remoto de Turbinas Eólicas Offshore. Retrieved November 23, 2024, from <https://docta.ucm.es/entities/publication/96ce92db-a401-48d4-bbf8-54f9408284d9>
- [4] Dialnet. (2024). Digital Twins and Wind Turbine Monitoring: Challenges and Solutions. Retrieved November 23, 2024, from <https://dialnet.unirioja.es/servlet/articulo?codigo=9537007>
- [5] M. Tomás-Rodríguez, and M. Santos. "Modelado y control de turbinas eólicas marinas flotantes." *Revista iberoamericana de automática e informática industrial* 16, no. 4 (2019): 381-390.
- [6] Arduino. (n.d.). *Arduino Mega 2560 Rev3*. Recuperado de <https://www.arduino.cc/en/Main/ArduinoBoardMega2560>

Experimentos con oleaje y viento de un prototipo de FOWT

Eduardo Muñoz-Palomeque
Departamento de Digitalización
Universidad de Burgos
09006-Madrid, España
emp1016@alu.ubu.es

Tahereh Bagheri-Rouch
Instituto de Investigación y Desarrollo de Procesos- IIDP
Faculty of Engineering of Bilbao,
University of the Basque Country UPV/EHU
48013, Bilbao, Spain
tahereh.bagheri@ehu.es

Segundo Esteban San Román
Dept. Arquitectura de Computadores y Automática
Faculty of Physics
Universidad Complutense de Madrid
28040-Madrid, España
sesteban@ucm.es

Payam Aboutalebi
Instituto de Investigación y Desarrollo de Procesos- IIDP
Faculty of Engineering of Bilbao,
University of the Basque Country UPV/EHU
48013, Bilbao, Spain
payam.aboutalebi@ehu.es

Abstract— This article describes different experimental tests that have been carried out with prototypes of small-scale floating wind turbines from the UCM in the wave channel of the UPV. The forced dynamics of the barge-type floating wind turbine anchored to the bottom are analyzed. The dynamics are analyzed in different situations, with waves and with wind. Experiments have been carried out with aggressive waves and waves scaled to the size of the prototype. Problems are detected in the monitoring system to be able to record the signals at such a small scale, both with the prototype signals and with the wave signal. Results of the behavior obtained with the system excited by wind and waves are presented.

Resumen—En este artículo se describen diferentes pruebas experimentales que se han realizado con prototipos de aerogeneradores flotantes a escala reducida de la UCM en el canal de olas de la UPV/EHU. Se analiza la dinámica forzada del aerogenerador flotante de tipo barcaza anclado al fondo. Se analiza la dinámica en diferentes situaciones, con oleajes y con viento. Se han realizado experimentos con oleajes agresivos y oleajes escalados al tamaño del prototipo. Se detectan problemas en el sistema de monitorización para poder registrar las señales a una escala tan pequeña, tanto con las señales del prototipo, como con la señal de oleaje. Se presentan resultados del comportamiento obtenido con el sistema excitado por vientos y oleajes.

Keywords— *Floating Offshore Wind Turbine; Towing Tank; Experimental Test.*

I. INTRODUCCIÓN

Tras el desarrollo de diferentes prototipos de aerogeneradores en la UCM y el diseño de prototipos de barcas con columnas de agua oscilantes en la UPV/EHU, dentro del proyecto de investigación conjunto [1], se plantea la necesidad de confluír en pruebas experimentales con los prototipos. Se pretende realizar experimentos con prototipos a escala reducida de FOWT (Floating Offshore Wind Turbine) en el canal de olas de la UPV/EHU.

Esta confluencia presenta una gran complejidad, es necesario trabajar con sistemas aerodinámicos, hidrodinámicos, eléctricos y mecánicos. Además, es necesario excitar estos sistemas con oleajes y vientos y monitorizarlos y controlarlos.

En la UCM se han desarrollado diferentes prototipos de aerogeneradores y sus sistemas de monitorización [2-4]. Algunos de estos han sido adaptados para su montaje en barcas flotantes para poder ser utilizados en estos experimentos.

El canal de la UPV/EHU tiene una escala similar a la de los prototipos de la UCM, ver Fig. 1. Dispone de un generador de oleajes en uno de los extremos y una playa en el otro extremo para absorber parcialmente la energía de las olas y que los rebotes sean menos significativos.




Fig. 1. Canal de olas con modelo de FOWT, izquierda es la vista hacia el generador de oleaje, derecha hacia la playa.

Este sistema experimental se complementó con sistema de generación de viento formado por un ventilador industrial como se muestra en la Fig. 2.




Fig. 2. En paralelo al generador de oleaje se añadió un ventilador capaz de generar viento.

Se probaron dos tipos de barcaza, ancladas mediante cuatro líneas al fondo del canal, como muestra Fig. 3. Como sistema de anclaje se utilizaron ventosas. Respecto a los otros experimentos, de relajación del sistema sin oleaje, se modificaron las longitudes de las líneas de anclaje para conseguir un comportamiento más realista, por lo que la dinámica se modificó sustancialmente y por tanto los resultados no son comparables entre sí.




Fig. 3. Barcaza anclada al fondo mediante cuatro líneas.

Se probaron diferentes longitudes de cadenas, hasta dar con un comportamiento equivalente a las que se pueden encontrar en los sistemas reales, que permitiese cierto grado de libertad.

Sobre los dos tipos de barcaza se montaron los prototipos de aerogeneradores instrumentados, como se muestra en la Fig. 4. En la figura se puede observar que las columnas de agua están posicionadas en la proa y en la popa de la barcaza, estando abiertas en este caso. Se probaron dos configuraciones de FOWT:

1. Aerogenerador forzado y barcaza con columnas de agua abiertas o cerradas.
2. Aerogenerador con estabilizador giroscópico y barcaza con columnas de agua controlables.

Se han realizado una amplia gama de experimentos:

- Con oleaje regular a escala:
 - Oleaje medio $T=5s$ $H_s=2cm$
 - Oleaje agresivo $T=4s$ $H_s=2cm$
 - Oleaje agresivo $T=5s$ $H_s=3cm$
- Con y sin viento.




Fig. 4. Prototipos de FOWT instrumentados. La imagen izquierda es un aerogenerador forzado sobre barcaza de columnas de agua abiertas o cerradas. La imagen derecha es un aerogenerador libre, sobre barcaza con estabilizador giroscópico y columnas de agua controlables.

II. MODELADO MATEMÁTICO

Aunque existen modelos matemáticos de turbinas con mayor detalle, para poder identificar el efecto de los diferentes subsistemas se modela la dinámica del grado de libertad de cabeceo o “pitch”, ϕ , mediante una ecuación diferencial lineal de segundo orden (1). Esto permitirá extraer los parámetros principales del comportamiento del sistema.

$$I \cdot \ddot{\phi}(t) + D \cdot \dot{\phi} + K \cdot \phi = T_{olas} + T_{viento} \quad (1)$$

Donde:

- I es el momento de inercia principal respecto al grado de libertad de cabeceo. Este depende de la distribución de masas del sistema y del centro de giro del sistema, que a su vez es función del centro de flotación del sistema.
- D es el factor de amortiguamiento. Este depende principalmente de la hidrodinámica de la barcaza y del comportamiento aerodinámico del aerogenerador.
- K es el factor de restauración. Este valor depende principalmente de la hidrodinámica de la barcaza y de las características de las líneas de anclaje.
- T_{olas} y T_{viento} representan los pares perturbadores generados por las olas y por el viento.

Se puede normalizar la ecuación diferencial dividiendo momento de inercia, para no tener que identificar este valor. De esta forma se trabajaría con pares perturbaciones normalizados respecto a la inercia del sistema.

Anteriormente se realizaron experimentos de relajación, para identificar la dinámica propia del sistema. A continuación, se presentan los experimentos del sistema perturbado por oleajes y viento.

III. DATOS EXPERIMENTALES

Se realizaron bastantes experimentos con diferentes tipos de oleajes, con y sin viento. En los experimentos iniciales, durante el primer día de experimentos, se trabajó con oleajes demasiado agresivos.

Posteriormente, se escaló la altura de la ola y su periodo acorde a la escala del modelo, trabajando con olas con altura significativa de 1, 2 y 3 cm, que son similares a la altura de la barcaza. También se trabajó con diferentes periodos de ola, 0.4 y 0.5s, lo que permite extraer comportamientos con diferentes resonancias. En la Fig. 5 se puede observar que en el primer caso la barcaza puede cabalgar suavemente sobre la ola, por tener una longitud similar, mientras que en el segundo caso la longitud de la ola es mayor que la de la barcaza, generando mayor resonancia.




Fig. 5. Acople entre ola y barcaza.

A continuación, en Fig. 6, 7 y 8 se muestran los experimentos con oleajes de alturas significativas de 1, 2 y 3 cm.

Los experimentos se han realizado en condiciones de viento constante. Debido a ello, se aprecia un cabeceo promedio en los experimentos, que viene generado por el arrastre que introduce el aerogenerador respecto al viento.

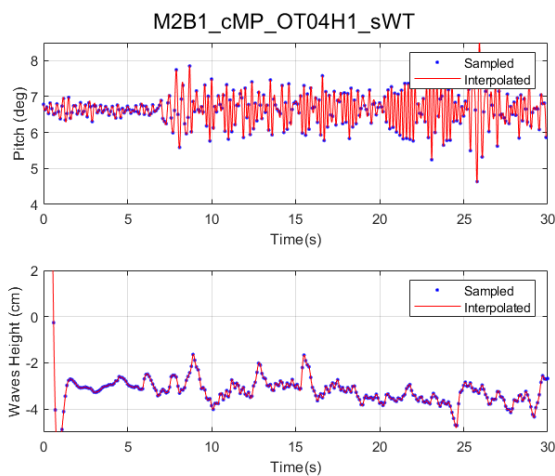


Fig. 6. Experimentos con viento y oleaje de $T=0.4s$ y $H=1cm$.




Fig. 7. Experimentos con viento y oleaje de $T=0.5s$ y $H=2cm$.




Fig. 8. Experimentos con viento y oleaje de $T=0.5s$ y $H=3cm$.

Es necesario destacar que el registro del oleaje no está sincronizado con los registros del movimiento de la barcaza, se registraban en sistemas diferentes. Los sensores de oleaje requieren de un tiempo de estabilización de unos 2 segundos, lo que impedía sincronizarlos. Por otro lado, la resolución real del sensor de oleaje no es suficiente, pues en la práctica comienza a medir aceptablemente para amplitudes de ola de 3 cm, siendo bastante impreciso para medidas inferiores, como las de 1 cm y 2 cm. En el experimento con oleaje de 1 cm se aprecian fallos de medida cíclicos en el sensor de oleaje. En algunos momentos se dispara la medida a valores muy altos, que no se apreciaban en el experimento real.

Debido a la inicialización del sensor de oleaje, es necesario descartar la parte inicial del experimento. Por otro lado, por la reflexión del oleaje es necesario descartar la parte final del experimento. Además, habrá que sincronizar las señales de oleaje con las de movimiento, pues tras unos segundos de inicialización del experimento llega el oleaje a la barcaza y este comienza a perturbarla.

De cara a la identificación, debido a la baja calidad de la medida del oleaje, nos centraremos en los oleajes de altura significativa de 3 cm. Al intentar identificar modelos a partir de estas señales seleccionadas, se obtienen los resultados poco satisfactorios, como se muestra en la Fig.9.

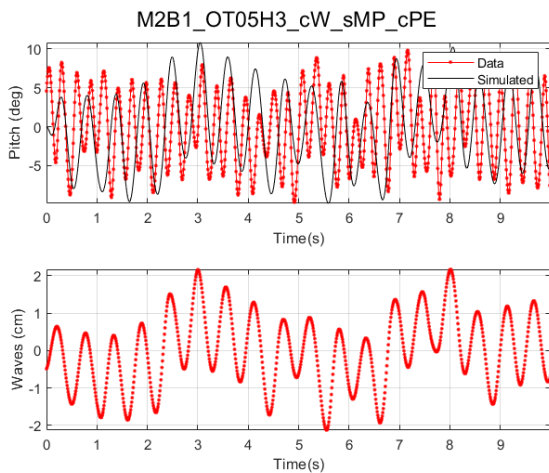


Fig. 9. Identificación del modelo perturbado con oleaje original.

En estas señales se han eliminado los sesgos de cabeceo, introducidos por el viento, y de oleaje, introducidos por el sensor de oleaje.

Se puede apreciar que la señal de cabeceo que proporciona el modelo no tiene la misma frecuencia que la señal de cabeceo registrada por la electrónica, prácticamente es el doble. Esto se debe a que la señal de excitación del sistema, el oleaje, tiene una frecuencia inferior a la del cabeceo experimental. Esto significa que alguna de las señales no está muestreada con el doble de periodo.

Para resolver estos problemas, se procede a escalar el tiempo del oleaje, para que coincida la frecuencia de excitación con la de respuesta del sistema. A continuación, en la Fig. 10 se muestran los resultados obtenidos con los valores procesados.

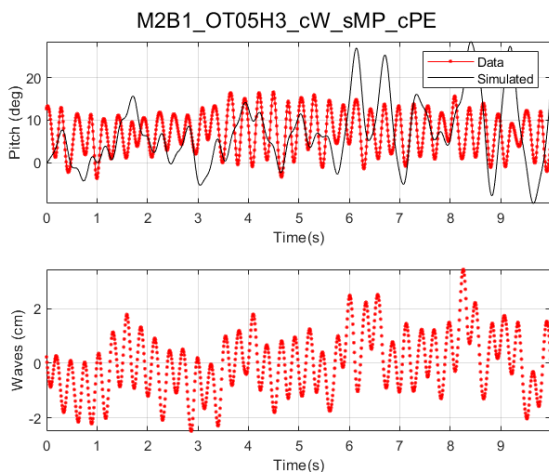


Fig 10. Identificación del modelo perturbado con oleaje procesado.

Ahora, el modelo captura adecuadamente el cabeceo promedio, generado por el viento, y la frecuencia, pues aparecen pequeños picos con la misma frecuencia que en los datos experimentales. Pero la respuesta debida al oleaje no se parece a los resultados experimentales. Esto se debe a que la señal del oleaje registrada tiene una componente en baja frecuencia que no se corresponde con los experimentos

observados, pues en estos se comprobó que el oleaje generado era un oleaje regular. Esta componente tiene una amplitud mayor y es amplificada por el modelo. Esta respuesta a grandes olas fantasmas, que realmente no existen, constituye la respuesta principal del sistema.

IV. CONCLUSIONES Y TRABAJOS FUTUROS

Se han integrado los prototipos de aerogeneradores de la UCM con las barcasas con columnas oscilantes de agua de la UPV/EHU. Se ha montado un sistema experimental sobre el canal de oleaje de la UPV/EHU, añadiendo la funcionalidad de generar viento para los aerogeneradores flotantes. Sobre este entorno se han realizado experimentos preliminares para evaluar la viabilidad de identificar modelos y evaluar comportamiento de sistemas de control.

De los experimentos se puede identificar el efecto del viento en el cabeceo promedio del FOWT y las amplitudes de oscilación de la barcaza respecto a diferentes oleajes perturbadores. Es decir, se puede extraer información relevante de estos experimentos.

Pero en lo que respecta al oleaje, este debe ser escalado en tamaño y tiempo, acorde a la escala del modelo. Por ello, se debe trabajar con oleajes de altura significativa de 1, 2 y 3 cm. El sistema actual no captura correctamente oleajes tan pequeños, introduciendo picos y componentes ficticias de más baja frecuencia. Esto hace inviable identificar modelos perturbados a partir de las señales de perturbación registradas en los experimentos.

Como instrumento para monitorizar y controla los prototipos se ha utilizado Arduino Mega [5]. Este dispositivo ha sido manejado desde Matlab, lo que introduce mucho retardo en la captura de las señales. Este problema se ha resuelto inicialmente mediante interpolación de los datos. Para futuros experimentos ya se está reprogramando en C, para conseguir periodos de muestreo de 0.01 s.

Es necesario desarrollar otro sistema que permita registrar el oleaje en tiempo real con resolución centimétrica. Una posible alternativa es mediante procesado de imagen. Utilizando las fotografías y vídeos capturados durante los experimentos se puede diseñar un procesado de imagen en tiempo real que capture el perfil de oleaje y la posición de la barcaza. La barcaza es fácil de reconocer, pudiéndose determinar las esquinas superiores. A partir de estas esquinas se puede determinar el "pitch", "surge" y "heave" de la barcaza. Como tiene un fondo uniforme, sería posible determinar también el perfil de ola relativo a la barcaza, que es justamente la señal que excita al modelo. Esto permitiría determinar la señal de excitación (perfil de oleaje) y la salida del sistema (cabeceo de la barcaza) de forma sincronizada y con una precisión milimétrica. Abriendo más la captura de la imagen, se podría hasta determinar forma de las líneas de anclaje, pudiéndose estimar su estado de tensión. Este sistema de monitorización se puede plantear como una nueva tarea en los proyectos de investigación.

Tras estos primeros experimentos se han detectado los puntos fuertes y débiles del sistema experimental, se ha aprendido donde se debe dedicar esfuerzo para mejorar futuras experimentaciones.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación de España, con el proyecto MCI/AEI/FEDER número PID2021-123543OBC21.

REFERENCIAS

- [1] WEB Proyecto. <https://www.floatingwindturbineucm.com/>
- [2] Aimara, G. A., & San Román, S. E. (2022). Modelo a Escala de Aerogenerador para Control. In *Irakaskuntzaren berrikuntza kontrol ingeniarietan itsas energian*, ISBN 978-84-1319-379-3, págs. 53-58.
- [3] Fernández, M., Sánchez, B., Esteban, S. & Santos, M. (2024) Arquitectura Hardware Asequible para Implementar Controles de Pitch en una Turbina Offshore. In *Irakaskuntzaren berrikuntza kontrol ingeniarietan itsas energia*, ISBN 978-84-1319-379-3, págs. 77-82.
- [4] Herrera Herrero, F. G., Goñi Ancho, A., & Coello Fernández, J. (2023). Infraestructura IoT para monitorización y control de granjas de aerogeneradores. <https://docta.ucm.es/entities/publication/96ce92db-a40f-48d4-bbf8-54f9408284d9>
- [5] Arduino. (n.d.). *Arduino Mega 2560 Rev3*. Recuperado de <https://www.arduino.cc/en/Main/ArduinoBoardMega2560>

Generación automática de datos de diseño de palas de turbinas eólicas

Fernando Herrera-Marín
Facultad de Informática
Universidad Complutense de Madrid
Madrid, España
fherre04@ucm.es

Jesús Enrique Sierra-García
Department of Electromechanical
Engineering, University of
Burgos, España
jesierra@ubu.es

Matilde Santos
Institute of Knowledge Technology
Universidad Complutense de Madrid
Madrid, España
msantos@ucm.es

Resumen—La Dinámica de Fluidos Computacional (CFD) es una herramienta muy utilizada en ingeniería y ciencias para simular el comportamiento de los fluidos bajo diversas condiciones. Sin embargo, la CFD presenta limitaciones significativas, como gran necesidad de recursos computacionales y largos tiempos de cómputo, lo que restringe su aplicabilidad en proyectos a gran escala o aquellos que requieren resultados en tiempo real. Estas limitaciones resaltan el potencial de integrar herramientas basadas en técnicas de la Inteligencia Artificial, en concreto Redes Neuronales Convolucionales (CNN), que han demostrado la capacidad de aproximar soluciones a problemas complejos con una velocidad y eficiencia superiores. Este artículo presenta una herramienta que permite la creación de bases de datos para el diseño de palas de turbinas eólicas, que pueden ser usados para alimentar estas CNN, optimizando así los procesos de simulación y análisis en la dinámica de fluidos.

Index Terms—Simulación, Turbinas eólicas, Palas, Dinámica de Fluidos Computacional, Redes Neuronales Convolucionales, Generación de Datos.

I. INTRODUCCIÓN

En un presente donde el cambio climático es una realidad, la búsqueda de alternativas sostenibles a los combustibles fósiles es una necesidad. Las energías renovables juegan un papel primordial en esta misión de garantizar un futuro sostenible.

Energías como la mareomotriz, eólica y solar ya representan un porcentaje significativo de la energía neta producida por los países desarrollados. Entre 2004 y 2016, la proporción de energía renovable en el consumo bruto de energía en Europa experimentó un aumento significativo, alcanzando un incremento del 147,8 por ciento en 2017 en comparación con 2008 [1]. La importancia de estas alternativas ha crecido tanto que, en 2020, el 38% de la energía generada en la Unión Europea provino exclusivamente de fuentes renovables, con una notable contribución de la energía eólica e hidroeléctrica [2].

A diferencia de la energía solar e hidroeléctrica, la energía eólica presenta una mayor versatilidad ya que puede instalarse en una mayor variedad de condiciones geográficas y climáticas. Por otro lado, el desarrollo de la eficiencia y tecnología de las turbinas eólicas ha alcanzado una gran madurez tecnológica. Se puede conseguir un aumento de hasta un 32% en la velocidad de rotación de las turbinas mediante la optimización del número y el ángulo de las palas [3]. Este potencial de mejora es posible gracias al avance de

tecnologías como la dinámica de fluidos computacional (CFD, por sus siglas en inglés), cuya aplicación en el diseño y la optimización de perfiles aerodinámicos ha producido mejoras notables en la eficiencia energética asociada con las turbinas eólicas (WT) [4] [5] [6].

Las herramientas CFD tienen un gran potencial para la optimización de palas y otros componentes estructurales de las turbinas u otros dispositivos. Sin embargo, uno de los grandes inconvenientes que limita su aplicabilidad es que requieren un alto consumo computacional y de tiempo. Las simulaciones pueden tardar desde varios minutos hasta horas, lo que dificulta o hace inviable integrar las simulaciones CFD con técnicas de optimización.

Por otro lado, las redes neuronales son computacionalmente muy eficientes y pueden contribuir a aliviar el costo computacional de CFD, con la peculiaridad de que deben ser entrenadas para reproducir los resultados proporcionados por las herramientas CFD. En concreto las Redes Neuronales Convolucionales (CNNs) se han aplicado a la optimización de diseños aerodinámicos y la predicción de patrones de flujo turbulento.

Uno de los trabajos más destacados es [7]. Este estudio propone un modelo para predecir flujos laminares estacionarios en dominios 2D y 3D utilizando CNNs. Los resultados muestran que estas redes pueden estimar el campo de velocidad hasta dos órdenes de magnitud más rápido que un CFD acelerado por GPU y cuatro órdenes de magnitud más rápido que un solucionador basado en CPU, manteniendo un bajo margen de error. Otro avance significativo se encuentra en el trabajo de Eichinger et al. [8]. Se presenta una CNN diseñada para construir modelos sustitutos de orden reducido en simulaciones CFD. Los autores utilizaron una imagen de la geometría del canal para predecir flujos en un canal con obstáculos variables. Al comparar arquitecturas CNN clásicas con U-Net, los resultados indicaron que la U-Net alcanzó menores errores de predicción y mejor capacidad de generalización a geometrías no vistas. El estudio de Viquerat y Hachem [9] se centra en la predicción de arrastre en flujos laminares a bajos números de Reynolds. Utilizando curvas Bézier para generar formas 2D con diversas características geométricas y un método para resolver las ecuaciones de Navier-Stokes, los autores demostraron que las CNNs pueden optimizar diseños

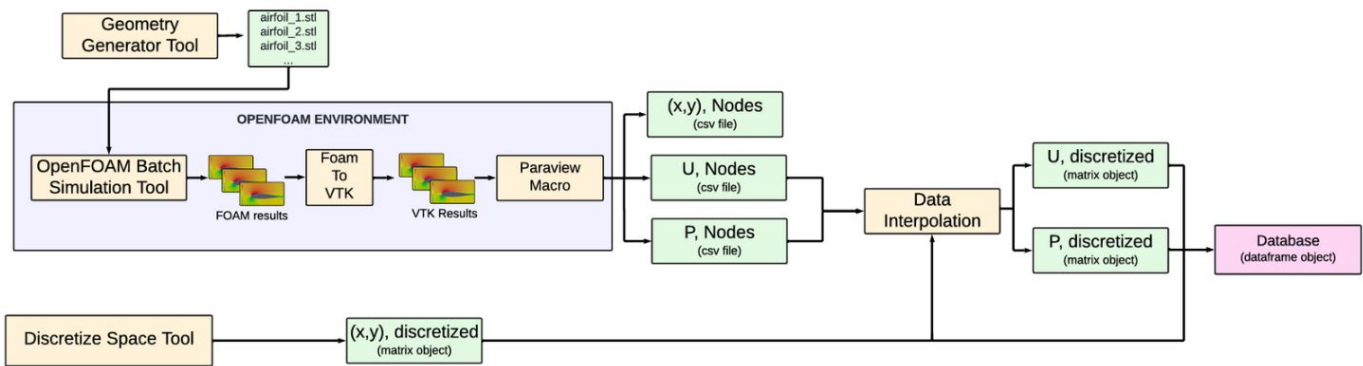


Figura 1: Metodología para la creación de datos de palas de turbinas.

aerodinámicos de manera precisa y eficiente.

Estos estudios ilustran el impacto de las CNNs en el ámbito de CFD y la ingeniería aerodinámica, consolidándolas como herramientas clave para resolver problemas complejos y avanzar en la optimización de diseños.

Para avanzar en esta línea de investigación, en este trabajo se propone una metodología para automatizar la creación de conjuntos de datos de palas de turbina eólica para el entrenamiento de redes neuronales y análisis estadístico. La metodología utiliza un enfoque paramétrico para definir la forma del perfil aerodinámico de las palas de forma automática junto con ecuaciones matemáticas y el software OpenFOAM [10] como herramienta de simulación de CFD. Con esta herramienta, se ha generado automáticamente un extenso conjunto de datos.

La estructura del resto del artículo es la siguiente. La Sección II explica la metodología propuesta para generar conjuntos de datos de palas de turbinas eólicas. Se presentan los resultados en la sección III y el artículo termina con las conclusiones y los trabajos futuros.

II. METODOLOGÍA PARA LA GENERACIÓN AUTOMÁTICA DATOS

Para construir un modelo de aprendizaje automático es esencial generar un conjunto extenso de datos de flujo que se utilizarán durante el entrenamiento. Esto implica cubrir adecuadamente el espacio de entrada posible, es decir, el rango de formas de las palas de turbina, para garantizar la validez del modelo.

Para generar esta base de datos exhaustiva, se diseña un proceso automatizado que permite simular una amplia variedad de configuraciones geométricas de palas sin necesidad de interacción adicional del usuario. El proceso consiste en generar el conjunto de datos con la geometría de los perfiles y obtener los campos de velocidad y presión resultantes de las simulaciones CFD, generadas en masa mediante el software de cálculo. Se desarrollan diferentes herramientas para este proceso de generación de datos, según se muestra en la Figura 1.

El llamado generador de geometría es el responsable de alimentar el software de cálculo con un lote de perfiles de palas y turbinas, generados aleatoriamente.

La herramienta de simulación automática de OpenFOAM es responsable de configurar los parámetros que determinan las condiciones para cada caso de simulación y ejecutar sucesivamente los comandos para que estas simulaciones se lleven a cabo. Esta herramienta permite la simulación simultánea de un número indefinido de casos, tarea que sería inviable y altamente improductiva si se hiciera manualmente. Una vez que se ejecutan las simulaciones, los datos resultantes se guardan en los archivos correspondientes.

La explotación de los resultados requiere la conversión previa al formato VTK y la ejecución de una macro en la interfaz de visualización de OpenFOAM. Las herramientas "foamToVTK" "Paraview Macro" permiten la ejecución de estas funciones de forma masiva sin necesidad de acceder directamente a la interfaz de visualización. Se obtienen las coordenadas de los nodos de cálculo, así como los valores de velocidad y presión asociados con cada punto.

Los puntos donde se calculan la velocidad y la presión dependen de la malla generada por OpenFOAM. Esta malla depende de la forma de la pala y, en general, es diferente para cada pala. Así, para obtener la velocidad y presión en los mismos puntos para todas las palas del conjunto de datos, es necesario crear una malla común para todas las palas e interpolar los valores.

Con este fin, la representación de la geometría se obtiene en forma de Función de Distancia Firmada (SDF, por sus siglas en inglés) tras la discretización previa del espacio en forma de malla. Estos datos obtenidos de la matriz tendrán una dimensión constante para todos los casos y alimentarán la red neuronal.

También es necesario interpolar los valores de velocidad y presión obtenidos en los puntos de cálculo para cada posición de la matriz SDF que define el espacio. De este modo, se obtienen campos de velocidad y presión de dimensión constante para todo el conjunto de casos, formando una base de datos coherente y homogénea para entrenar la red neuronal.

II-A. Diseño de perfiles de palas

La forma de la pala de la turbina se define utilizando un enfoque paramétrico, variando características geométricas clave, como el ángulo de ataque, el grosor, la curvatura y la

longitud de la pala. La geometría del perfil de la pala de la turbina se define a través de las siguientes ecuaciones, en las cuales los coeficientes M, P y T definen esta geometría.

La curvatura de la cuerda y_c y el gradiente de curvatura $\frac{dy_c}{dx}$ se definen mediante las ecuaciones (1) y (2).

El parámetro p se refiere a la posición del punto de máxima curvatura del perfil NACA, expresado como una fracción de la longitud de la cuerda. Toma valores en el rango de 0 a 1, donde:

- $p = 0$ significa que el punto de máxima curvatura está ubicado en el borde de ataque (la parte delantera del perfil).
- $p = 1$ significa que el punto de máxima curvatura está ubicado en el borde de salida (la parte trasera del perfil).

La variable x representa la posición a lo largo de la cuerda del perfil, también expresada como una fracción de la longitud total de la cuerda. Los valores de x varían desde $x = 0$ (en el borde de ataque) hasta $x = 1$ (en el borde de salida), es decir, $0 \leq x \leq 1$.

- Para la porción frontal del perfil (desde el borde de ataque hasta el punto de máxima curvatura), $0 \leq x \leq p$.
- Para la porción trasera del perfil (desde el punto de máxima curvatura hasta el borde de salida), $p \leq x \leq 1$.

Parte frontal ($0 \leq x \leq p$)

$$\text{Curvatura: } y_c = \frac{M}{p^2}(2Px - x^2) \quad (1)$$

$$\text{Gradiente: } \frac{dy_c}{dx} = \frac{2M}{p^2}(P - x) \quad (2)$$

Parte trasera ($p \leq x \leq 1$)

$$\text{Curvatura: } y_c = \frac{M}{1-p^2}(1 - 2P + 2Px - x^2) \quad (3)$$

$$\text{Gradiente: } \frac{dy_c}{dx} = \frac{2M}{(1-p)^2}(P - x) \quad (4)$$

La distribución de grosor y_t se da mediante la ecuación (5).

$$y_t = \frac{T}{0,2} (a_0x^{0,5} + a_1x + a_2x^2 + a_3x^3 + a_4x^4) \quad (5)$$

Donde:

$$\begin{aligned} a_0 &= 0,2969 & a_1 &= -0,126 & a_2 &= -0,3516 \\ a_3 &= 0,2843 & a_4 &= -0,1015 \end{aligned}$$

Mediante las ecuaciones mencionadas, se obtienen los puntos que componen el contorno de cada geometría de perfil. Para la generación del objeto tridimensional, se utilizará la biblioteca FreeCAD [11], que permite crear y manipular modelos 3D de forma paramétrica. El archivo resultante se guarda en formato .STL, desde el cual se llevará a cabo la simulación CFD.

II-B. Análisis de la dinámica de fluidos

Se ha utilizado el software OpenFOAM para el análisis de dinámica de fluidos según la geometría de la pala.

En la carpeta "constant" se encuentran los archivos relacionados con aspectos fundamentales que permanecen constantes a lo largo del tiempo durante la simulación.

- `transportProperties` contiene las propiedades físicas del fluido, como la viscosidad cinemática y la densidad.
- `momentumTransport` define el modelo de turbulencia utilizado en la simulación y sus parámetros.
- `trisurface` es el directorio que contiene el archivo STL que define la geometría del estudio, donde se guardarán los archivos generados por el generador de geometría.

La carpeta "system" contiene los archivos de configuración que controlan la ejecución de la simulación. Entre todos los archivos, los siguientes son sujetos a modificaciones:

- `blockMeshDict` define el entorno en el que se lleva a cabo la simulación. Establece la dimensión del espacio y el comportamiento de sus paredes.
- `surfaceFeaturesDict` determina el método utilizado para la intersección objeto/entorno. Este proceso es necesario antes de ejecutar el mallado.
- `snappyHexMeshDict` configura el generador de mallas `snappyHexMesh`, incluyendo la definición de la geometría, los niveles de refinamiento y los parámetros para ajustar la calidad de la malla.

Los valores predeterminados para algunos de los parámetros de malla definidos en 'snappyHexMeshDict' son los siguientes.

Para la configuración automática de los parámetros para cada caso de simulación se ha desarrollado una herramienta de software que interactúa con OpenFOAM. Para cada caso de estudio se ejecutarán los siguientes pasos en el orden indicado para completar la simulación:

- `blockMesh` Este comando construye el entorno a partir de una malla hexaédrica definida por la información en el archivo "blockMeshDict".
- `surfaceFeatures` Extrae las características de la geometría definidas en el archivo .STL y obtiene su intersección con el entorno. Este proceso es esencial para el posterior refinamiento de la malla.
- `snappyHexMesh -overwrite` Permite el refinamiento de la malla alrededor de geometrías complejas. El parámetro "overwrite" asegura que los resultados generados sobrescriban los archivos de malla existentes.
- `potentialFoam` Este comando es recomendado antes de simular casos complejos, ya que estabiliza el campo de velocidad inicial antes de comenzar la simulación.
- `simpleFoam` Llama al solver `simpleFoam`. Es un solver de estado estacionario para flujos incompresibles que utiliza el algoritmo SIMPLE (Método Semi-Implícito para Ecuaciones de Presión Vinculadas) para acoplar presión y velocidad.

Función	Parámetro	Valor	Descripción
CastellatedMesh	maxLocalCells	100000	Límite de celdas por procesador.
	maxGlobalCells	2000000	Límite global de celdas.
	minRefinementCells	10	Número mínimo de celdas a refinar.
	maxLoadUnbalance	0.10	Controla el desequilibrio de carga permitido.
	nCellsBetweenLevels	3	Número de celdas intermedias.
Refinamiento superficie	features	level 6	Nivel de refinamiento en bordes.
	refinementSurfaces	level (5 6)	Refinamiento min y máx de superficie.
	resolveFeatureAngle	30	Ángulo mínimo
Refinamiento de región	refinementRegions	levels ((1E15 4))	Nivel de refinamiento en región.

TABLA I: Características previas de SnappyHexMeshDict

Una vez que se ha ejecutado la simulación de todos los casos de estudio, los resultados obtenidos se guardan automáticamente en su archivo correspondiente. Desde el directorio de simulación, se puede acceder al visualizador de OpenFOAM, “ParaView”, ejecutando el comando “paraFoam” desde la ventana de comandos.

Dentro de ParaView, se puede visualizar el entorno generado, así como su intersección con la geometría de estudio y el refinamiento de la malla en las áreas de mayor interés (Figura 2).




Figura 2: Refinamiento de malla en ParaView

Para obtener una imagen más clara de los resultados, se debe aplicar un corte para seccionar la geometría y permitir una representación bidimensional de los campos de velocidad y presión obtenidos (Figura 3 y Figura 4). Este proceso es necesario para asegurar la extracción de datos en formato bidimensional.




Figura 3: Campo de velocidad en ParaView

De nuevo, este proceso es bastante lento y tedioso para llevarlo a cabo manualmente. ParaView permite diseñar macros




Figura 4: Campo de presión en ParaView

para que un proceso de extracción de datos pueda ser definido y extrapolado a diferentes casos de estudio.

Sin embargo, antes de construir esta macro, es necesario convertir los resultados al formato “VTK”. Este formato facilita la compatibilidad de los resultados con la herramienta de visualización y es necesario para asegurar el correcto funcionamiento de la macro. La herramienta “FOAM TO VTK” ejecuta el comando “foamToVTK” para cada caso de estudio, generando el archivo VTK correspondiente que contiene los resultados en el formato especificado.

Una vez que los resultados han sido convertidos al formato VTK, se puede implementar la función de la macro a través de ParaView, permitiendo la extracción de los resultados deseados en formato .csv.

Los resultados obtenidos tendrán una estructura según la Figura 5. Se obtienen los resultados de velocidad (U), energía cinética turbulenta (k), viscosidad (nut), energía de disipación (omega) y presión (p) en los nodos de la malla del plano de corte seleccionado (en este caso, Z=0.25).

Block Number	Point ID	Points	U	k	nut	omega	p	
0	1	0	-4, -3, 0,25	20.0004, -0.00101187, 1.59857e-05	0.227533	0.0581774	7.55071	0.344492
1	1	1	-4, -4, 0,25	20.0005, -0.000458878, 1.8318e-05	0.228127	0.0603883	8.06927	0.334233
2	1	2	-5, -3, 0,25	20, -5.57443e-05, -2.32804e-07	0.23948	0.128936	1.88099	0.349096
3	1	3	-5, -4, 0,25	20.0001, -0.00011159, -1.8825e-07	0.236096	0.101603	4.6129	0.340985
4	1	4	-3.59445, -3.59445, 0,25	20.0008, -0.000645667, 3.32102e-05	0.229668	0.0613024	5.46434	0.329147
5	1	5	-3.58909, -3.32873, 0,25	20.0008, -0.000826276, 3.34006e-05	0.2295	0.0609439	5.19639	0.331754
6	1	6	-3, -3, 0,25	20.0013, -0.00166814, 2.56048e-05	0.227	0.0565721	5.26854	0.325509
7	1	7	-2.60508, -3.45318, 0,25	20.0027, -0.00137996, 2.96834e-05	0.224424	0.056998	5.5004	0.294649

Figura 5: Estructura de los resultados de datos

III. RESULTADOS

Para que el contenido de la geometría sea procesado correctamente por la red neuronal, es necesario representar la geometría en forma de matriz. Primero, se requiere una discretización del espacio en una malla bidimensional, y luego se obtendrá la SDF para cada una de las celdas.

La Función de Distancia Firmada permite una representación detallada de un volumen asignando a cada punto en el espacio una distancia firmada a la superficie de un objeto geométrico. La distancia firmada indica la distancia desde el punto hasta la superficie del objeto, siendo positiva si el punto está fuera del objeto, negativa si está dentro del objeto, y cero si está justo sobre la superficie del objeto. Esto permite una representación compacta y eficiente de la geometría, manteniendo información detallada sobre la misma. Matemáticamente, una SDF se define como:

$$SDF(p) = d(p, S) \quad (6)$$

Donde p es un punto en el espacio tridimensional. S representa la superficie del objeto. $d(p, S)$ es la distancia euclidiana más corta entre p y cualquier punto en S .

Se establece un refinamiento de malla de 2000 x 800, lo que da como resultado una matriz SDF de 1,600,000 posiciones. La Figura 6 muestra un ejemplo de un perfil de turbina en el espacio y su representación mediante SDF. A las regiones ubicadas dentro de la geometría se les asigna un valor de -1.




Figura 6: Función de Distancia Firmada de un perfil aerodinámico

Los resultados de velocidad y presión extraídos se han obtenido en los nodos que conforman la malla de la pieza. A diferencia de la matriz de distancia firmada, los campos de presión y velocidad tienen dimensionalidades diferentes para cada estudio de caso, y sus valores se refieren a puntos distintos a lo largo del espacio.

Como último paso en el proceso de adquisición de datos de referencia, se implementa una herramienta de interpolación para obtener una base de datos más consistente y uniforme. A partir de los resultados obtenidos, se estiman los valores de

velocidad y presión en las posiciones previamente definidas por el espacio discretizado en la matriz SDF.

III-A. Resultados del tiempo computacional

A continuación se presentan los tiempos de ejecución obtenidos para un caso de simulación aislado. Este tiempo de ejecución incluye todo el proceso de generación de datos descrito en la Figura 1 para un solo caso de simulación. Además, para comprender mejor el impacto de las condiciones de mado en el rendimiento del proceso, se realizaron varios casos de simulación. Estos casos modificaron los parámetros de mado listados en la Tabla II, y se observó su influencia en los tiempos de ejecución obtenidos. Los resultados se presentan en la Tabla II.

Con base en los resultados obtenidos, se puede realizar el siguiente análisis sobre la influencia de los diferentes parámetros en el rendimiento del proceso:

- **Tamaño de la Celda:** Celdas más pequeñas resultan en tiempos de ejecución significativamente mayores debido al incremento en el número de celdas.
- **Límite de Celdas por Procesador:** Variar este límite afecta el balanceo de carga y puede aumentar o reducir el tiempo de ejecución según la eficiencia del procesamiento paralelo.
- **Límite Global de Celdas:** Imponer un límite evita un refinamiento excesivo, resultando en tiempos de ejecución más manejables.
- **Celdas Mínimas por Iteración:** Valores más altos ralentizan la convergencia, lo que incrementa el tiempo de ejecución.
- **Control del Desbalance de Carga:** Un control más estricto generalmente mejora la eficiencia del procesamiento paralelo, reduciendo el tiempo de ejecución.
- **Celdas de Búfer:** Más celdas de búfer resultan en transiciones más suaves pero con tiempos de ejecución ligeramente más largos.
- **Nivel de Refinamiento de Características de Borde:** Niveles más altos causan un aumento significativo en el tiempo de ejecución debido a la complejidad añadida al mado.
- **Niveles de Refinamiento de Superficies:** Niveles más altos de refinamiento de superficies mejoran la precisión pero a costa de tiempos de ejecución más largos.
- **Ángulo de Resolución de Detalle Geométrico:** Ángulos más bajos requieren mallas más detalladas, incrementando así el tiempo de ejecución.
- **Refinamiento Específico por Región:** Un mayor refinamiento en regiones específicas optimiza el uso de recursos computacionales, afectando los tiempos de ejecución de manera variable.

IV. CONCLUSIONES Y TRABAJOS FUTUROS

En este estudio, se sugiere un enfoque automatizado para generar conjuntos de datos de palas de turbinas eólicas con fines de análisis estadístico y entrenamiento de redes neuronales en el futuro. La técnica utiliza OpenFOAM como

Simulación	maxLocal Cells	maxGlobal Cells	minRefinement Cells	nCellsBetween Levels	Características	superficies de refinamiento	Tiempo de Ejecución(s)
Simulación 1	100000	2000000	10	3	nivel 6	nivel (5 6)	56.21
Simulación 2	150000	2500000	15	4	nivel 7	nivel (4 6)	58.50
Simulación 3	120000	2200000	12	3	nivel 6	nivel (5 6)	57.30
Simulación 4	110000	2100000	11	3	nivel 6	nivel (5 5)	56.00
Simulación 5	130000	2300000	13	4	nivel 6	nivel (5 6)	59.00
Simulación 6	140000	2400000	14	3	nivel 6	nivel (5 7)	55.80
Simulación 7	125000	2250000	13	3	nivel 6	nivel (4 6)	56.70
Simulación 8	115000	2150000	12	3	nivel 6	nivel (5 6)	56.40
Simulación 9	105000	2050000	11	3	nivel 6	nivel (5 5)	55.90
Simulación 10	135000	2350000	14	4	nivel 6	nivel (5 7)	59.10

TABLA II: Variación del Tiempo de Ejecución en función de Diferentes Parámetros de Mallado

herramienta de simulación CFD, herramientas geométricas para automatizar el diseño de palas 3D, y ecuaciones para especificar la forma del perfil aerodinámico de las palas. Un conjunto de datos extenso ha sido generado automáticamente con este programa.

Como conclusión, el análisis de los diversos parámetros de mallado considerados en la Tabla II muestra un claro intercambio entre la precisión de la simulación y el tiempo de ejecución. Ajustar estos parámetros puede ayudar a optimizar el rendimiento de las simulaciones para cumplir con necesidades específicas, ya sea priorizando la precisión o la eficiencia computacional.

Como trabajos futuros, se destaca la explotación del conjunto de datos generado con esta metodología para entrenar redes neuronales, y la integración de estas redes neuronales entrenadas con técnicas de optimización para optimizar el diseño de las palas.

ACKNOWLEDGMENTS

Este trabajo ha sido parcialmente apoyado por el proyecto PID2021-123543OB-C21 del MICIU/AEI/ y FEDER.

REFERENCIAS

- [1] Stoenoiu, C., Balan, M., Șerban, F., & Cristea, C. (2021). Evolution of renewable energy consumption in the European countries. *IOP Conference Series: Earth and Environmental Science*, 664. [Online]. Available: <https://doi.org/10.1088/1755-1315/664/1/012018>. [Accessed: Dec. 1, 2024].
- [2] Hoarca, I., Bizon, N., & Enescu, F. (2021). Using the potential of renewable energy sources in Romania to reduce environmental pollution. *2021 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, 1-6. [Online]. Available: <https://doi.org/10.1109/ECAI52376.2021.9515074>. [Accessed: Dec. 1, 2024].
- [3] Varol, A., Ilkiliç, C., & Varol, Y. (2001). Increasing the efficiency of wind turbines. *Journal of Wind Engineering and Industrial Aerodynamics*, 89, 809-815. [Online]. Available: [https://doi.org/10.1016/S0167-6105\(01\)00069-1](https://doi.org/10.1016/S0167-6105(01)00069-1). [Accessed: Dec. 1, 2024].
- [4] Sayed, M., Kandil, H., & Shaltot, A. (2012). Aerodynamic analysis of different wind-turbine-blade profiles using finite-volume method. *Energy Conversion and Management*, 64, 541-550. [Online]. Available: <https://doi.org/10.1016/J.ENCONMAN.2012.05.030>. [Accessed: Dec. 1, 2024].
- [5] Wang, X., Shen, W., Zhu, W., Sørensen, J., & Jin, C. (2009). Shape Optimization of Wind Turbine Blades. *Wind Energy*, 12, 781-803. [Online]. Available: <https://doi.org/10.1002/WE.335>. [Accessed: Dec. 1, 2024].
- [6] Pandey, R. (2021). Development and Optimization of Wind Turbine Blade Design for Enhanced Efficiency. *Mathematical Statistician and Engineering Applications*. [Online]. Available: <https://doi.org/10.17762/msea.v70i1.2505>. [Accessed: Dec. 1, 2024].

- [7] Guo, X., Li, W., & Iorio, F. (2016). Convolutional Neural Networks for Steady Flow Approximation. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. [Online]. Available: <https://doi.org/10.1145/2939672.2939738>. [Accessed: Dec. 1, 2024].
- [8] Eichinger, M., Heinlein, A., & Klawonn, A. (2022). Surrogate convolutional neural network models for steady computational fluid dynamics simulations. *ETNA - Electronic Transactions on Numerical Analysis*. [Online]. Available: https://doi.org/10.1553/etna_vol56s235. [Accessed: Dec. 1, 2024].
- [9] Viquerat, J., & Hachem, E. (2020). A supervised neural network for drag prediction of arbitrary 2D shapes in laminar flows at low Reynolds number. *Computers & Fluids*. [Online]. Available: <https://doi.org/10.1016/j.compfluid.2020.104645>. [Accessed: Dec. 1, 2024].
- [10] OpenFOAM Foundation, *OpenFOAM: The Open Source CFD Toolbox*, versión 11, 2024. Disponible en: <https://www.openfoam.com>
- [11] FreeCAD Community. (n.d.). The Python API. FreeCAD. [Online]. Available: <https://freecad-python-api.readthedocs.io/en/latest/>. [Accessed: Dec. 1, 2024].

Machine learning para la identificación de anomalías en Turbinas eólicas

B. Weiss, S. Esteban, and M. Santos
Universidad Complutense de Madrid
28040 Madrid, España

Email: bweiss@ucm.es, segundo@dacya.ucm.es, msantos@ucm.es

Resumen—Este artículo presenta un análisis de los datos del parque de turbinas eólicas Alpha Ventus, con el objetivo de detectar anomalías en el rendimiento de los aerogeneradores. Se han utilizado datos reales del proyecto RAVE (Research at Alpha Ventus), para analizar los efectos de la velocidad del viento, la posición de la góndola y otros factores ambientales en la eficiencia de las turbinas. En este artículo, entre las diversas técnicas de aprendizaje automático, se han seleccionado los k-vecinos más cercanos (K-NN) para identificar patrones y detectar anomalías indicativas de posibles problemas. Los resultados muestran que algunas turbinas del parque eólico, ubicadas en el centro, están sujetas a efectos de estela significativos e irregularidades operativas. Al ajustar los parámetros del modelo K-NN se mejora la fiabilidad de la operación y el mantenimiento de las turbinas.

Palabras clave—Turbinas eólicas, anomalías, Machine learning, K-NN.

I. INTRODUCCIÓN

Las turbinas eólicas marinas (OWT) capturan vientos más fuertes que las terrestres, lo que lleva a una mayor y más estable producción de energía. Los avances tecnológicos están reduciendo los costos, haciendo que la energía eólica marina sea más competitiva [1].

El principal problema de estas turbinas eólicas es su mantenimiento ya que están sometidas a fuertes cargas. En este artículo se aplica una técnica de aprendizaje automático para la detección de fallos y así poder reducir las interrupciones operativas [2].

Se ha realizado un análisis exhaustivo de los datos de un parque eólico real. Los datos provienen del proyecto RAVE (Investigación en Alpha Ventus). Los datos utilizados en este estudio son parte del proyecto RAVE y están disponibles públicamente a través de su portal oficial [3]. Estos datos reales se recopilan de varias fuentes, se generan en grandes cantidades y muestran cambios rápidos según el tiempo o la ubicación. Las señales son bastante ruidosas, lo que puede ser producido por errores de medición, interferencias o errores de procesamiento durante el manejo de los datos. Este ruido también proviene del comportamiento estocástico inherente a las condiciones atmosféricas [4], como la

velocidad y dirección del viento, la temperatura y la presión.

En este artículo se presenta un análisis de datos reales de una granja de turbinas eólicas para la detección de anomalías. Las anomalías son desviaciones detectadas en los datos que reflejan irregularidades o comportamientos inusuales en el funcionamiento de las turbinas. Estas pueden manifestarse como indicadores de fallos mecánicos, desgastes no previstos, variaciones ambientales extremas, errores en los sensores o eventos operativos fuera de lo común. En esencia, las anomalías capturan la evidencia de problemas en el equipo o situaciones atípicas que se registran a través de los sistemas de monitoreo. [5].

Se utilizan datos del proyecto RAVE, como la velocidad del viento, la potencia generada y las posiciones de los aerogeneradores en el parque eólico. Se aplica un preprocesamiento, tanto filtrado como normalización. Luego se aplica el algoritmo de k-vecinos más cercanos (K-NN), con un enfoque particular en las turbinas ubicadas en el centro del parque eólico, que son más susceptibles a los efectos de estela y a irregularidades operativas. El análisis resalta el impacto de estos efectos de sombra. Efectos de sombra son las turbulencias causadas por la proximidad de otras turbinas, reduciendo la velocidad del viento aguas abajo y afectando el rendimiento de las turbinas afectadas.

El resto del artículo se organiza como sigue. La sección 2 explica las características y el diseño del parque eólico. La sección 3 analiza los datos proporcionados por el parque y las variables analizadas. La sección 4 explica el modelo de potencia esperado, el entrenamiento del modelo k-vecinos más cercanos y los resultados. Finalmente se presentan las conclusiones y el trabajo futuro.

II. MATERIALES

Los parques eólicos, que comparten infraestructura, pueden reducir los costos por turbina, aunque esto también hace que el mantenimiento sea más complejo [6].




Figura 1. Configuración del Parque Eólico Marino Alpha Ventus [3].

El Proyecto RAVE tiene como objetivo mejorar el monitoreo de datos en tiempo real y la detección de anomalías utilizando sensores avanzados para la recopilación precisa de datos. El parque eólico está compuesto por doce turbinas eólicas de 5 MW, enumeradas y ancladas del 1 al 12, ancladas a 30 metros de profundidad en el mar [7]. Las turbinas eólicas son de dos tipos, Adwen M5000- 116 y Senvion 5M. Las principales características se muestran en el Tabla I.

El parque *Alpha Ventus* se encuentra en el Mar del Norte. Es el primer parque eólico marino de Alemania [8], [9]. En la figura 1 se muestra su configuración.

II-A. Variables y datos

El proyecto RAVE incluye más de 30 terabytes de datos desde 2010. Los datos se registran en intervalos de 10 minutos o menos. Se recopilan mediciones de velocidad del viento, dirección del guiñada de la góndola, lo que indica cómo se alinea la turbina con la dirección del viento. Dirección del Viento: la dirección desde la que incide el viento. Velocidad del Viento. Potencia eléctrica generada por la turbina, en kilovatios (kW).

Las turbinas eólicas más antiguas del proyecto RAVE, WT1-6, del 2009, muestran peor rendimiento debido al envejecimiento natural y los avances tecnológicos. Las turbinas más nuevas, instaladas alrededor del 2011, se benefician de materiales mejorados, diseños y sistemas de control [10].

Del parque se han seleccionado las turbinas 4, 5 y 6 debido a su dispersión en la potencia generada a diferentes velocidades del viento, lo que resalta posibles inconsistencias operativas o ineficiencias. Además pueden verse afectadas por los efectos de estela de las turbinas aguas arriba, lo que puede reducir la velocidad del viento y aumentar la turbulencia, contribuyendo a las anomalías

viento, temperatura y humedad en múltiples puntos del parque eólico y sus alrededores. Además, se tienen datos del rendimiento de las turbinas eólicas, como la potencia generada, las velocidades de rotación y los registros de mantenimiento [9]. Las variables utilizadas en este estudio son:

Velocidad del rotor en revoluciones por minuto (RPM). Posición de la góndola: es el ángulo de observadas.

En la figura 2 se muestran las series temporales de datos de las turbinas 1 y 5, que tienen diferentes posiciones dentro del parque eólico. Como se muestra en la figura 1, la turbina 1, posicionada en la fila delantera, expuesta directamente al viento con efectos de estela mínimos. Por el contrario, la turbina 5 experimenta turbulencia de estela de las turbinas aguas arriba, como la turbina 2, lo que lleva a mayor estrés mecánico y variabilidad en la potencia generada. La turbina 6 presenta pocos valores atípicos. Estas turbinas proporcionan un conjunto diverso de anomalías de diferentes partes de sus curvas operativas.

La figura 3 muestra la relación entre la velocidad del viento (m/s) y la potencia generada (kW) de las turbinas 4, 5 y 6, es decir, su curva de potencia. Alcanzan el máximo alrededor de los 10 m/s, velocidad nominal, que es de aproximadamente 5000 kW. La WT6 exhibe varios valores atípicos, especialmente a velocidades del viento superiores a 10 m/s. La WT5 muestra un rendimiento relativamente estable. La WT4 tiene una distribución dispersa de valores atípicos, especialmente a velocidades del viento superiores a 10 m/s, lo que apunta a posibles problemas de rendimiento.

Se han obtenido las matrices de correlación que muestran que la potencia esperada, la velocidad del rotor, la velocidad del viento y la potencia generada tienen una correlación positiva. La posición de la góndola dio una correlación positiva con la dirección del viento; para este caso, la turbina 4 tiene la correlación más alta, alrededor del 20 %, mientras que las turbinas 5 y 6 tienen alrededor del 16 %. Esto sugiere que la posición de la turbina 4, casi en el centro, a 800 m de la turbina 5 y a 400 m de la estación FINO1, tuvo más errores de guiñada, y esos errores redujeron la potencia generada.

III. MÉTODOS: DETECCIÓN DE ANOMALÍAS CON K-NN

Se aplica un enfoque de aprendizaje supervisado utilizando el algoritmo de k-vecinos más cercanos (K-NN) para clasificación y detección de anomalías.

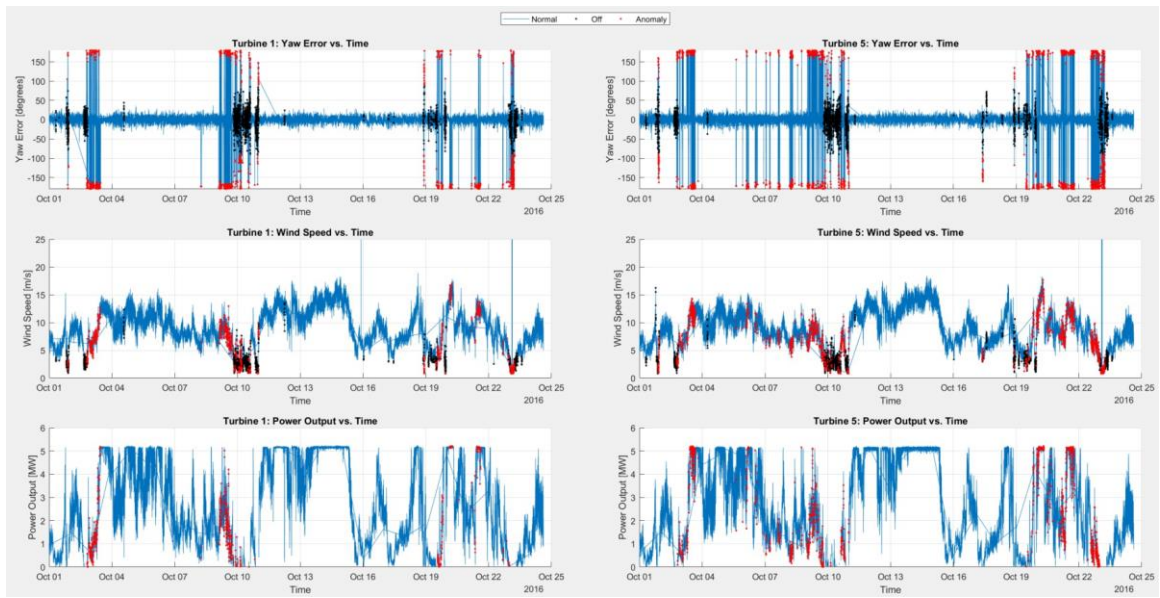


Figura 2. Datos de series temporales con diferencia de 10 minutos de las turbinas 1 y 5 en octubre de 2016




Figura 3. Potencia generada en las turbinas 4, 5 y 6 en octubre de 2016

Tabla I
CARACTERÍSTICAS DE LAS TURBINAS EÓLICAS ADWEN M5000-116 Y SENVION 5M [11].

Característica	Adwen M5000-116	Senvion 5M
Fabricante	Adwen (AREVA Wind)	Senvion (REpower Systems)
Posiciones en el parque	OWTs 7-12	OWTs 1-6
Potencia nominal	5 MW	5 MW
Diámetro del rotor	116 m	126 m
Longitud de la pala	57.2 m	61.5 m
Área barrida	10,568 m ²	12,469 m ²
Velocidad de arranque del viento	3.5 m/s	3.5 m/s
Velocidad nominal del viento	12 m/s	12.5 m/s
Velocidad del viento de parada	25 m/s	30 m/s
Rango operativo	-20 a 50°C	-20 a 45°C
Altura del buje	Variable (hasta 90 m en el mar)	90 m

El algoritmo K-NN funciona agrupando puntos de datos similares en un espacio de características e identifica anomalías comparando nuevos puntos de datos con los conocidos, midiendo sus distancias [13].

En este estudio, se compara el rendimiento real de la turbina con la potencia esperada en función de la velocidad del viento. Si coinciden se etiquetan como "normales", mientras que las desviaciones significativas se marcan como "anomalías". El modelo K-NN se entrena con estos datos etiquetados. Un nuevo dato se clasifica en función de la clase mayoritaria de sus k vecinos más cercanos.

III-A. Modelado de la curva de potencia y detección de anomalías

En primer lugar, los datos se han preprocesado mediante un escalado a los rangos esperados de las variables. También se han normalizado con el método min-max, o escalado de características, que transforma los datos a un rango específico, típicamente [0, 1]. Este método escala linealmente los datos en función de los valores mínimo y máximo en el conjunto de datos, asegurando que todas las características estén en la misma escala.

La fórmula para la normalización min-max es

$$x_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (1)$$

donde x es el valor original, x_{min} y x_{max} son los valores mínimo y máximo de la característica, y x_{norm} es el valor normalizado.

Esto asegura que cada característica del conjunto de datos contribuya de manera equitativa al análisis. Esta técnica transforma los datos para que tengan una media de 0 y una desviación estándar de 1, lo que es esencial para algoritmos que dependen de cálculos de distancia, como el método de k -vecinos más cercanos (K-NN) [2].

Para aplicar la técnica de K-NN se ha fijado el número de vecinos a cinco, por lo que cada predicción considera los cinco datos más cercanos. Se

emplea la distancia euclídea para medir la distancia entre los puntos en el espacio multidimensional de características. Las entradas del modelo K-NN para cada turbina incluyen los conjuntos de datos de Velocidad del Viento (v), Potencia de Salida (P), Velocidad del Rotor, Posición de la Góndola, Dirección del Viento y un Cálculo de Potencia Esperada.

El cálculo matemático de la potencia esperada a diferentes velocidades del viento proporciona una característica adicional que mejora la capacidad predictiva o de clasificación del modelo K-NN en función de las condiciones del viento. La ecuación para la potencia esperada P_{esperada} de una turbina eólica es la siguiente:

$$P_{\text{esperada}}(v) = \frac{1}{2} \cdot \rho \cdot A \cdot C_p \cdot v^3 \quad (2)$$

donde:

- ρ es la densidad del aire (típicamente 1.225 kg/m³ a nivel del mar).
- A es el área barrida por las palas de la turbina.
- C_p es el coeficiente de potencia (factor de eficiencia).
- v es la velocidad del viento.

Los parámetros seleccionados para el modelo, mostrados en el Tabla II, se puede extraer de la ficha técnica.

Para validar el rendimiento del modelo K-NN se divide el conjunto de datos en dos subconjuntos: un conjunto de entrenamiento y otro de prueba. El conjunto de entrenamiento, con el 80 % de los datos, se utiliza para entrenar el modelo K-NN, permitiéndole aprender los patrones subyacentes. El 20 % restante sirve como un conjunto de datos para evaluar el rendimiento predictivo del modelo. Al predecir las etiquetas del conjunto de prueba y compararlas con las etiquetas reales, se evalúa la precisión del modelo. Este enfoque proporciona una estimación robusta de la capacidad de generalización del modelo a datos no vistos [1].

Tabla II
PARÁMETROS PARA LA CURVA DE POTENCIA ESPERADA DE LA TURBINA EÓLICA [12]

Parámetro	Símbolo	Valor	Descripción
Velocidad de arranque	v_{arranque}	3.5 m/s	Velocidad del viento de arranque.
Velocidad nominal	v_{nominal}	13 m/s	Velocidad del viento a la que la turbina alcanza su potencia máxima de salida.
Velocidad de corte	v_{corte}	30 m/s	Velocidad máxima del viento a la que la turbina opera antes de apagarse para evitar daños.
Punto medio	v_0	8.25 m/s	Promedio de las velocidades de arranque y nominal: $v_0 = \frac{v_{\text{arranque}} + v_{\text{nominal}}}{2}$.
Potencia nominal	P_{nominal}	5000 kW	Potencia máxima que la turbina puede generar.
Factor de eficiencia	C_p	0.593	Máximo teórico del coeficiente de potencia según la Ley de Betz.




Figura 4. Detección de anomalías para las turbinas 4, 5 y 6

IV. RESULTADOS

Los resultados de aplicar el modelo de k-vecinos más cercanos (K-NN) se muestran en la figura 4. Los límites de decisión y las clasificaciones de los puntos de datos están representados, destacando las áreas identificadas como operaciones normales y anomalías.

Cada uno representa los límites de decisión para la detección de anomalías en turbinas eólicas (WT) basados en dos características normalizadas: Velocidad del Viento (Característica 1) y Potencia (Característica 2). En cada gráfico, los puntos verdes indican datos de operación normales, mientras que los puntos rojos representan anomalías. El límite de decisión diferencia entre condiciones normales y anormales, con las regiones azules representando operaciones normales y las regiones rojas indicando anomalías.

En general, los gráficos muestran que el algoritmo de detección de anomalías identifica eficazmente los valores atípicos basados en la relación entre la velocidad del viento y la potencia. El gráfico de la izquierda muestra una mayor dispersión de anomalías, mientras que los gráficos

del centro y la derecha muestran progresivamente menos anomalías, lo que sugiere mejoras en la precisión y rigurosidad del algoritmo de detección.

V. CONCLUSIONES Y TRABAJO FUTURO

Este estudio presenta un análisis del rendimiento de las turbinas eólicas y la detección de anomalías utilizando datos reales de la planta eólica marina Alpha Ventus. Las principales conclusiones de la investigación son las siguientes.

El uso de k-vecinos más cercanos (K-NN) ha demostrado ser eficiente para identificar anomalías en los datos operativos de las turbinas eólicas, especialmente para aquellas ubicadas en el centro de la planta.

Las turbinas 4, 5 y 6 mostraron una considerable variabilidad en la potencia de salida debido a los efectos de estela de las turbinas circundantes. Esto subraya la importancia de un diseño y posicionamiento óptimos de las turbinas para mitigar las pérdidas de rendimiento y mejorar la eficiencia general en los parques eólicos.

El ajuste del número de vecinos y el umbral de desviación en los modelos condujo a métodos

ayudan a equilibrar la sensibilidad a fluctuaciones menores y centrarse en desviaciones, reduciendo los falsos positivos y mejorando la aplicabilidad práctica del modelo.

La incorporación de los cálculos de potencia esperada en el conjunto de datos mejoró significativamente la capacidad del modelo para detectar anomalías.

Como conclusión final, este estudio destaca el papel crucial de estas técnicas inteligentes basadas en datos para optimizar el rendimiento y prolongar la vida útil de las turbinas eólicas marinas.

El trabajo futuro se centrará en integrar estrategias de mantenimiento predictivo y explorar los impactos de tecnologías emergentes como IoT y análisis de big data en la eficiencia de los parques eólicos. Además, se llevará a cabo un análisis sin la inclusión del cálculo de potencia esperada en el modelo.

VI. AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto PID2021-123543OB-C21 del MI-CIU/AEI/ y FEDER.

REFERENCIAS

- [1] Sacie, M., Santos, M., López, R., and Pandit, R. (2022). Use of state-of-art machine learning technologies for forecasting offshore wind speed, wave and misalignment to improve wind turbine performance. *Journal of Marine Science and Engineering*, 10(7),938. 10.3390/jmse10070938
- [2] Zhou, B., Zhang, Z., Li, G., Yang, D., and Santos, M. (2023). Review of key technologies for offshore floating wind power generation. *Energies*, 16(2), 710. 10.3390/en16020710
- [3] Fraunhofer IWES, RAVE Research Initiative Flyer, <https://www.rave-offshore.de>, May 2023. DOI: 10.2314/ra-ve.2023.001.
- [4] Pandit, R., Infield, D., and Santos, M. (2022). Accounting for environmental conditions in data-driven wind turbine power models. *IEEE Transactions on Sustainable Energy*, 14(1), 168-177. 10.1109/TSTE.2022.3146820
- [5] Maldonado, C. B. G., Penas, M. S., and Lopez, M. V. L. (2016). Negative selection and Knuth Morris Pratt algorithm for anomaly detection. *IEEE Latin America Transactions*, 14(3), 1473-1479. 10.1109/TLA.2016.7459644
- [6] Chen, Z.; Li, H.; Liu, X.; Zhang, Y.; Lei, Z.; Shen, B. (2017). Wind Farm Performance and Design: An Overview. *Energies*, 10(11), 1904. doi:10.3390/en10111904.
- [7] Müller, K., Reiber, M., & Cheng, P. W. (2016). Comparison of Measured and Simulated Structural Loads of an Offshore Wind Turbine at Alpha Ventus. *International Journal of Offshore and Polar Engineering*, 26(3), 209–218. doi:10.17736/ijope.2016.fvr01.
- [8] Fraunhofer IWES. (2017). RAVE: Research at alpha ventus. Retrieved from <https://www.iwes.fraunhofer.de/en/research-projects/current-projects/rave.html>. doi: 10.5281/zenodo.3764854.
- [9] RAVE: Research at alpha ventus. (2017). Overview of the Project and Data. Retrieved from <https://www.rave-offshore.de/en/start.html>. doi: 10.5281/zenodo.3764860.
- [10] Cuéllar, S., Santos, M., Alonso, F., Fabregas, E., and Farias, G. (2024). Explainable anomaly detection in spacecraft telemetry. *Engineering Applications of Artificial Intelligence*, 133, 108083. 10.1016/j.engappai.2023.108083
- [11] 4C Offshore. AD 5-116 Offshore Wind Turbine, 2024. Retrieved from <https://www.4c offshore.com>.
- [12] REpower 5M Offshore - 5,08 MW - Wind turbine. Retrieved from <https://en.wind-turbine-models.com/turbines/78-repower-5m-offshore>
- [13] Marcos, D., Gómez-Silva, M.J., Santos, M., & López-González, C.I. (2024). Detección de anomalías en turbinas eólicas: un análisis comparativo. *Jornadas de Automática*, 45.

Estrategias de Control Avanzadas para Sistemas Híbridos de Aerogeneradores Flotantes y Columnas de Agua Oscilante: Un Enfoque PID

Payam Aboutalebi, *Associate Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0003-2716-1894

Email: payam.aboutalebi@ehu.eus

Fares Mzoughi, *Associate Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0003-2935-3830

Email: fares.mzoughi@ehu.eus

Irfan Ahmad

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0001-6075-2464

Email: irfanahmad.irfan@ehu.eus

Tahereh Bagheri Rouch

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0009-0002-1064-1795

Email: tahereh.bagheri@ehu.eus

Aitor J. Garrido, *Senior Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0002-3016-4976

Email: aitor.garrido@ehu.eus

Izaskun Garrido, *Senior Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0002-9801-4130

Email: izaskun.garrido@ehu.eus

Abstract—This article presents a hybrid floating wind turbine (FWT) system integrated with Oscillating Water Columns (OWCs) and a Proportional-Integral-Derivative (PID) control strategy designed to enhance platform stability and performance. By regulating the air pressure within the OWC chambers through a PID-controlled throttle valve, the system effectively mitigates pitch oscillations and improves overall platform stability. The results show that the PID controller significantly reduces platform pitch, leading to increased energy efficiency and more reliable power output. Numerical simulations demonstrate the benefits of advanced control mechanisms in optimizing hybrid renewable energy systems. The findings suggest that the hybrid FWT-OWC system, coupled with the PID control strategy, offers a promising solution for the efficient integration of wave and wind energy in practical offshore applications.

Keywords—Semisubmersible floating wind turbines, oscillating water columns, oscillatory motion mitigation, offshore energy

Resumen—Este artículo presenta un sistema híbrido de aerogenerador flotante (FWT) integrado con Cámaras de Agua Oscilante (OWC) y una estrategia de control

Proporcional-Integral-Derivativo (PID) destinada a mejorar la estabilidad y el rendimiento de la plataforma. Al regular la presión del aire dentro de las cámaras OWC mediante una válvula de estrangulación controlada por PID, el sistema mitiga eficazmente las oscilaciones de balanceo y mejora la estabilidad general de la plataforma. Los resultados demuestran que el controlador PID reduce significativamente el balanceo de la plataforma, lo que conduce a una mayor eficiencia energética y una salida de energía más confiable. Las simulaciones numéricas destacan las ventajas del uso de mecanismos de control avanzados para optimizar sistemas híbridos de energía renovable. Los hallazgos sugieren que el sistema híbrido FWT-OWC, con la estrategia de control PID, ofrece una solución prometedora para la integración eficiente de energía eólica y de las olas en aplicaciones prácticas en alta mar.

Palabras claves—Turbines eólicas flotantes semisumergibles, columnas de agua oscilantes, mitigación de movimientos oscilatorios, energía offshore

I. INTRODUCCIÓN

En los últimos años, la transición global hacia las energías renovables se ha vuelto esencial para abordar el cambio climático y alcanzar un futuro sostenible. La energía eólica marina ha surgido como un actor clave en esta transición, ofreciendo un potencial significativo para la generación de energía limpia a gran escala. La Unión Europea (UE), aprovechando sus cinco cuencas marítimas, lidera estos esfuerzos con el objetivo de alcanzar una capacidad de 111 GW de energía eólica marina para 2030 y 317 GW para 2050. Además, la UE ha establecido metas ambiciosas para la energía oceánica, buscando una capacidad instalada de 1 GW para 2030 y 40 GW para 2050, alineándose con sus objetivos energéticos y climáticos [1]–[3]. Para 2023, la UE había alcanzado 20 GW de capacidad eólica marina, un componente crítico de su portafolio total de 225 GW de energía eólica [4].

Las turbinas eólicas flotantes (FWT, por sus siglas en inglés) representan un avance prometedor en la energía marina, permitiendo la generación de energía en aguas profundas donde las turbinas tradicionales de base fija son imprácticas. Al integrarse con columnas de agua oscilantes (OWC, por sus siglas en inglés), estos sistemas híbridos aprovechan tanto la energía eólica como la de las olas, mejorando significativamente la producción energética y estabilizando la red eléctrica. Sin embargo, estas plataformas de doble energía enfrentan desafíos considerables, particularmente en el mantenimiento de la estabilidad bajo condiciones marinas adversas. El acoplamiento de las fuerzas aerodinámicas de la turbina eólica con las fuerzas hidrodinámicas que actúan sobre la subestructura introduce interacciones dinámicas complejas, a menudo a frecuencias variables, que pueden amplificar las vibraciones y desestabilizar la plataforma [5], [6]. Las oscilaciones excesivas, como los movimientos de cabeceo, balanceo y guiñada, reducen la eficiencia energética y aumentan el riesgo de fatiga estructural, lo que conlleva mayores costos de mantenimiento y una vida útil más corta del sistema [7], [8].

Para abordar estos desafíos, se han desarrollado diversas estrategias de mitigación de vibraciones. Los métodos pasivos, como los amortiguadores de masa sintonizados (TMD, por sus siglas en inglés), sistemas de lastre y amortiguadores viscosos, controlan el movimiento de la plataforma sin requerir insumos externos [9]–[11]. Aunque son efectivos para reducir las oscilaciones resonantes, los enfoques pasivos carecen de la adaptabilidad necesaria para condiciones marinas dinámicas [12], [13]. Los sistemas semiactivos, incluidos los dispositivos de fluidos magnetorreológicos, ofrecen un equilibrio entre la fiabilidad pasiva y la adaptabilidad activa al ajustar las propiedades de amortiguación para mejorar la estabilidad en condiciones cambiantes [14], [15]. Las estrategias de control activo, como los ajustes del ángulo de paso de las palas, los amortiguadores de masa activa (AMD, por sus siglas en inglés) y los controles avanzados de fuerza de líneas de amarre, proporcionan adaptabilidad en tiempo real, permitiendo una reducción precisa de las oscilaciones y una

estabilidad mejorada de la plataforma [16]–[18].

Los sistemas híbridos que combinan FWT con OWCs ofrecen ventajas únicas, ya que las OWCs no solo capturan energía de las olas, sino que también contribuyen a estabilizar el movimiento de la plataforma. Estudios recientes demuestran el potencial de las OWCs con estrategias avanzadas de control, como las técnicas de regulación de válvulas y el control conmutado supervisado, para reducir significativamente las oscilaciones y optimizar la producción de energía [19]–[21]. Por ejemplo, los sistemas integrados tipo barcaza FWT-OWC han utilizado con éxito modelos orientados al control para mejorar la estabilidad del movimiento y reducir las fluctuaciones de potencia bajo diferentes estados del mar [22], [23]. Sin embargo, persisten lagunas en el desarrollo de modelos aero-hidro-elasto-servo integrales y enfoques de control que se adapten dinámicamente a las condiciones fluctuantes.

Este estudio propone un novedoso enfoque de control conmutado supervisado activo para plataformas híbridas semisumergibles FWT-OWC. Al emular la dinámica de las válvulas OWC e integrar mecanismos de retroalimentación en tiempo real, este método ajusta dinámicamente los modos de control para estabilizar la plataforma bajo condiciones cambiantes de viento y olas. El enfoque garantiza una estabilidad óptima, reduce las oscilaciones y mejora la eficiencia de la producción energética. Herramientas como GenIE, HydroD, WADAM y SIMA se han empleado para simular y analizar el rendimiento de la plataforma en diversos escenarios, demostrando la efectividad del método propuesto [24]–[27].

El artículo está organizado de la siguiente manera: la Sección II aborda el diseño y las modificaciones del sistema, la Sección III detalla las ecuaciones de movimiento y el modelado del sistema, y la Sección IV evalúa el rendimiento del sistema. El estudio concluye en la Sección V, resumiendo los hallazgos clave e identificando direcciones para investigaciones futuras.

II. DISEÑO DEL SISTEMA Y MODIFICACIONES

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.

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.




Fig. 1. INO WINDMOOR, turbina eólica flotante semisumergible con OWCs integradas.

Este estudio amplía trabajos previos [5] 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 características clave de la plataforma se resumen en las Tablas I y II. El modelado emplea la teoría de flujo potencial, con la adición del modelo de Morison para los efectos de arrastre viscoso, lo que garantiza predicciones precisas de la respuesta del sistema híbrido.

TABLA I
CARACTERÍSTICAS DE LA SUBESTRUCTURA REMODELADA INO WINDMOOR

Propiedad	Valor
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 (MW)	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)	3x63.24
Masa del cubo (kg)	60000
Masa de la góndola (kg)	600000

III. ECUACIONES DE MOVIMIENTO

El sistema híbrido de la turbina eólica flotante (FWT) y la plataforma con cámaras OWC está gobernado por ecuaciones

de movimiento no lineales en el dominio temporal, que se expresan como sigue:

$$M_{ij}(x, u, t)\ddot{x}_j = f_i(x, \dot{x}, u, t) \quad (1)$$

En esta ecuación, M_{ij} representa los elementos de masa de la estructura, mientras que x indica el estado del sistema. Las entradas de control están representadas por u , y f_i en el lado derecho de la ecuación describe las fuerzas externas, incluyendo las cargas aerodinámicas sobre las palas y la góndola, las fuerzas hidrodinámicas sobre la plataforma, además de las fuerzas elásticas y servohidráulicas, así como el sistema de extracción de energía (PTO).

La versión en el dominio de la frecuencia de esta ecuación se expresa como:

$$I_{FWT}(\omega)\dot{q} + B_{FWT}(\omega)\dot{q} + K_{FWT}q = \vec{f}_{FWT}(\omega) \quad (2)$$

Aquí, I_{FWT} , B_{FWT} , y K_{FWT} representan la matriz de inercia, los términos de amortiguación y la matriz de rigidez, respectivamente. La fuerza resultante $\vec{f}_{FWT}(\omega)$ está compuesta por las cargas hidrodinámicas y aerodinámicas. El vector q en la ecuación 2 describe el movimiento de la plataforma de la siguiente manera:

$$q = \begin{bmatrix} \text{Avance (m)} \\ \text{Balanceo lateral (m)} \\ \text{Elevación (m)} \\ \text{Inclinación (grados)} \\ \text{Balanceo (grados)} \\ \text{Giro (grados)} \\ \text{adelante y atrás de la torre (m)} \\ \text{lateral de la torre (m)} \end{bmatrix} \quad (3)$$

Para calcular los elementos de inercia de la FWT, se considera la siguiente expresión:

$$I_{FWT}(\omega) = A_{Hydro}(\omega) + M_{Platform} + M_{Tower} \quad (4)$$

donde $M_{Platform}$ y M_{Tower} son las masas de la plataforma y de la torre, respectivamente, incluidas las estructuras superiores y la góndola. A_{Hydro} representa la masa añadida de la plataforma, la cual se puede obtener utilizando el programa WADAM para radiación de paneles [26].

La matriz de rigidez K_{FWT} se determina por la suma de las siguientes matrices:

$$K_{FWT} = K_{Hydro} + K_{Mooring} + K_{Tower} + K_{PTO} \quad (5)$$

donde K_{Hydro} es la matriz de restauración hidrostática de la plataforma, $K_{Mooring}$ describe la rigidez de los cables de amarre, K_{Tower} es la rigidez de la torre y K_{PTO} corresponde a la rigidez del sistema de aprovechamiento de energía (PTO).

Los coeficientes de amortiguación se calculan como:

$$B_{FWT}(\omega) = B_{Hydro}(\omega) + B_{Tower} + B_{PTO} \quad (6)$$

donde B_{Hydro} son los elementos de amortiguación asociados con la plataforma, B_{Tower} es la matriz de amortiguación para la torre flexible, y B_{PTO} representa el amortiguamiento generado por el sistema PTO.

Para la evaluación de la masa agregada, los coeficientes de amortiguación, la matriz de rigidez restauradora y las fuerzas hidrodinámicas, se ha desarrollado y analizado un modelo de elementos finitos de la plataforma utilizando la herramienta WADAM.

IV. ANÁLISIS DE ESCENARIOS Y EVALUACIÓN DEL RENDIMIENTO

El sistema híbrido de FWT con cámaras OWC integradas utiliza una estrategia de control PID para mitigar las oscilaciones de la plataforma, enfocándose particularmente en controlar el balanceo y los desplazamientos fore-aft de la parte superior de la torre. Para lograr este control, se regula la presión del aire dentro de la cámara de captura OWC utilizando un control de válvula de estrangulamiento. Este mecanismo ayuda a reducir las oscilaciones de la plataforma, especialmente las asociadas al balanceo, mejorando así la estabilidad dinámica del sistema.

En particular, el controlador PID ajusta la válvula de estrangulamiento en función de la retroalimentación del ángulo de balanceo de la plataforma para reducir las oscilaciones y mejorar la estabilidad de la plataforma. El controlador aplica ajustes en tiempo real a la válvula para contrarrestar cualquier desviación en el balanceo y estabilizar el sistema.

El modelado numérico del sistema se lleva a cabo bajo diferentes estados del mar y condiciones de viento turbulento utilizando las herramientas SIMO-RIFLEX-AeroDyn, desarrolladas por MARINTEK y CeSOS/NTNU. Estas herramientas permiten simular el comportamiento dinámico del sistema y evaluar su rendimiento bajo condiciones operativas complejas.

El concepto de control para mitigar las oscilaciones de la plataforma mediante el controlador PID, que ajusta la válvula OWC para estabilizar el balanceo, se ilustra en la Figura 2.




Fig. 2. Concepto de control para la estabilización del balanceo de la plataforma mediante el ajuste de la válvula de estrangulamiento OWC.

El análisis proporcionado en la Figura 3 investiga el comportamiento dinámico y el rendimiento de un sistema híbrido que integra OWCs bajo diferentes configuraciones, comparando específicamente un sistema controlado por PID con un sistema no controlado. Los resultados, ilustrados en las Figuras 3(a) a 3(h), subrayan la efectividad de los mecanismos

de control para mejorar la estabilidad, eficiencia y fiabilidad del sistema.

La Figura 3(a) presenta la elevación de las olas, que actúa como la excitación externa que influye en el sistema con una velocidad de viento constante de 7.9 m/s. El patrón oscilatorio regular de las olas muestra condiciones de entrada consistentes, proporcionando una base para evaluar el rendimiento del sistema híbrido. Las variaciones de presión del aire dentro de la cámara OWC se muestran en la Figura 3(e). Inicialmente, la presión del aire presenta fluctuaciones significativas, que se estabilizan con el tiempo. El sistema con control PID logra un perfil de presión más suave, lo cual es crucial para mantener una operación estable de la turbina y mejorar la eficiencia de conversión de energía.

La señal de control, representada en la Figura 3(b), resalta la respuesta adaptativa del controlador PID. El aumento gradual de la tensión refleja la capacidad del controlador para ajustarse dinámicamente a las condiciones cambiantes, asegurando un comportamiento del sistema estable y optimizado. La Figura 3(c) muestra la posición de la válvula, donde el sistema controlado por PID logra una operación más suave y estable en comparación con el sistema no controlado, el cual experimenta fluctuaciones significativas. Esta estabilidad en la dinámica de la válvula se traduce directamente en una mejor regulación del flujo de aire y una reducción de las pérdidas de energía.

La estabilización de la densidad del aire dentro de la cámara OWC, mostrada en la Figura 3(d), ilustra aún más las ventajas de la configuración controlada. El control PID reduce las oscilaciones de la densidad, llevando a un flujo de aire más consistente, lo cual es esencial para mantener una operación eficiente de la turbina. La Figura 3(f) muestra la fuerza ejercida sobre el sistema, donde la configuración controlada produce niveles de fuerza más altos y estables. Esta mejora indica una mejor extracción de energía del entorno de las olas.

La dinámica de la inclinación de la plataforma, presentada en la Figura 3(g), revela el desplazamiento angular de la estructura flotante. El sistema no controlado experimenta oscilaciones significativas, las cuales son efectivamente amortiguadas en la configuración controlada por PID. Esta mejora en la estabilidad reduce las tensiones estructurales y mejora la fiabilidad operativa. Por último, la potencia generada se presenta en la Figura 3(h). El sistema controlado por PID logra una salida de potencia más alta y consistente, con fluctuaciones reducidas, como se destaca en el recuadro que muestra el rendimiento en estado estacionario.

El análisis completo de las Figuras (a) a (h) demuestra el papel crítico de los mecanismos de control avanzados, como el PID, para optimizar el rendimiento de los sistemas híbridos OWC. El sistema controlado exhibe una estabilidad superior, eficiencia energética y fiabilidad operativa, lo que lo convierte en una solución prometedora para la integración de la energía de las olas en aplicaciones prácticas. Estos hallazgos refuerzan la importancia de las estrategias de control innovadoras en el avance de las tecnologías de energía renovable.

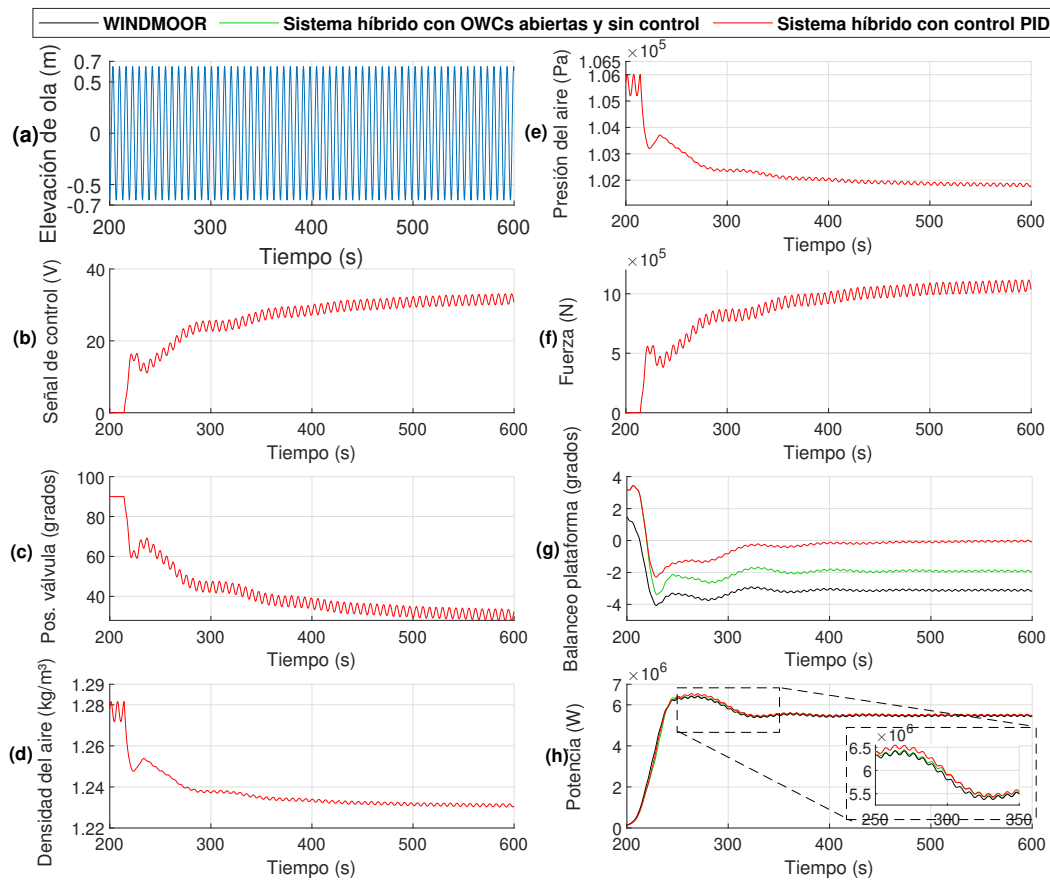


Fig. 3. Concepto de control para la estabilización del balanceo de la plataforma mediante el ajuste de la válvula de estrangulamiento OWC.

V. CONCLUSIONES

La integración de una estrategia de control PID en el sistema híbrido FWT-OWC mejora sustancialmente la estabilidad de la plataforma y el rendimiento operativo. Los resultados destacan la efectividad del controlador PID en la reducción de las oscilaciones de balanceo, mejorando el comportamiento dinámico del sistema. Esta configuración controlada conduce a una mayor eficiencia energética, reducción de fluctuaciones y una salida de potencia más confiable, lo que subraya el potencial de los mecanismos de control avanzados para optimizar los sistemas híbridos de energía renovable. Estos hallazgos sugieren que el sistema híbrido FWT-OWC, respaldado por estrategias de control inteligente, representa una solución prometedora para la integración eficiente de energía eólica y de las olas en aplicaciones reales.

El trabajo futuro incluirá el análisis de diversas condiciones de viento, incluyendo viento turbulento y oleaje, para evaluar de manera integral la eficiencia del controlador.

AGRADECIMIENTOS

Este proyecto recibió apoyo parcial a través de la financiación de los proyectos PID2021-23543OB-C21 y PID2021-123543OB-C22 (MCIN/AEI/10.13039/501100011033/FEDER, Unión Europea). Además, se

recibió asistencia financiera de los grupos de investigación del Gobierno Vasco, específicamente IT1555-22, y la iniciativa Margarita Salas MARSAA22/09 (UPV-EHU/MIU/Next Generation, Unión Europea).

REFERENCIAS

- [1] A. Martínez, L. Murphy, and G. Iglesias, "Evolution of offshore wind resources in northern Europe under climate change," *Energy*, vol. 269, p. 126655, 2023.
- [2] C. Bene, J. Moerenhout, J. Gorenstein Dedecca, L. Van Nuffel, C. Andrey, F. Gonzalez Venegas, M. Semenyuk, E. Anderson, J. Bjørndalen, M. Duvoort *et al.*, "Study on the allocation of costs and benefits for offshore infrastructure in eu sea basins," *EU: European Union*, 2023.
- [3] E. An, "Strategy to harness the potential of offshore renewable energy for a climate neutral future," *European Commission: Brussels, Belgium*, 2020.
- [4] WindEurope, "Latest wind energy data for Europe: Autumn 2024," <https://windeurope.org>, 2024, accessed: 2024-09-17.
- [5] P. Aboutalebi, 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.
- [6] M. N. Haji, J. M. Kluger, T. P. Sapsis, and A. H. Slocum, "A symbiotic approach to the design of offshore wind turbines with other energy harvesting systems," *Ocean Engineering*, vol. 169, pp. 673–681, 2018.
- [7] H. M. Johlas, L. A. Martínez-Tossas, M. J. Churchfield, M. A. Lackner, and D. P. Schmidt, "Floating platform effects on power generation in spar and semisubmersible wind turbines," *Wind Energy*, vol. 24, no. 8, pp. 901–916, 2021.

- [8] A. Fontanella, G. Colpani, M. De Pascali, S. Muggiasca, and M. Belloli, "Assessing the impact of waves and platform dynamics on floating wind turbine energy production," *Wind Energy Science Discussions*, vol. 2023, pp. 1–33, 2023.
- [9] Y. Gao, E. Zhai, S. Li, Z. Zhang, Z. Xu, G. Zhang, V. Racic, J. Chen, L. Wang, and Z. Zhang, "Integrated design and real-world application of a tuned mass damper (tmd) with displacement constraints for large offshore monopile wind turbines," *Ocean Engineering*, vol. 292, p. 116568, 2024.
- [10] 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.
- [11] M. Emami, R. Dezvareh, and S. A. Mousavi, "Contribution of fluid viscous dampers on fatigue life of lattice-type offshore wind turbines," *Ocean Engineering*, vol. 245, p. 110506, 2022.
- [12] J. López-Queija, E. Robles, J. Jugo, and S. Alonso-Quesada, "Review of control technologies for floating offshore wind turbines," *Renewable and Sustainable Energy Reviews*, vol. 167, p. 112787, 2022.
- [13] D. Han, W. Wang, X. Li, and X. Su, "Optimization design of multiple tuned mass dampers for semi-submersible floating wind turbine," *Ocean Engineering*, vol. 264, p. 112536, 2022.
- [14] B.-L. Zhang, Q.-L. Han, and X.-M. Zhang, "Recent advances in vibration control of offshore platforms," *Nonlinear Dynamics*, vol. 89, pp. 755–771, 2017.
- [15] C. Coudurier, O. Lepreux, and N. Petit, "Passive and semi-active control of an offshore floating wind turbine using a tuned liquid column damper," *IFAC-PapersOnLine*, vol. 48, no. 16, pp. 241–247, 2015.
- [16] L. Jin-Yang, Z. Songye, J. Zhang, M. Ruisheng, and Z. Haoran, "Vibration control of offshore wind turbines with a novel energy-adaptive self-powered active mass damper," *Engineering Structures*, vol. 302, p. 117450, 2024.
- [17] S. Sarkar, B. Fitzgerald, and B. Basu, "Individual blade pitch control of floating offshore wind turbines for load mitigation and power regulation," *IEEE Transactions on Control Systems Technology*, vol. 29, no. 1, pp. 305–315, 2020.
- [18] Z. Wu and Y. Li, "Platform stabilization of floating offshore wind turbines by artificial muscle based active mooring line force control," *IEEE/ASME Transactions on Mechatronics*, vol. 25, no. 6, pp. 2765–2776, 2020.
- [19] P. Aboutalebi, F. M'zoughi, I. Martija, I. Garrido, and A. J. Garrido, "Switching control strategy for oscillating water columns based on response amplitude operators for floating offshore wind turbines stabilization," *Applied Sciences*, vol. 11, no. 11, p. 5249, 2021.
- [20] D. Zhang, Z. Chen, X. Liu, J. Sun, H. Yu, W. Zeng, Y. Ying, Y. Sun, L. Cui, S. Yang *et al.*, "A coupled numerical framework for hybrid floating offshore wind turbine and oscillating water column wave energy converters," *Energy Conversion and Management*, vol. 267, p. 115933, 2022.
- [21] P. Aboutalebi, F. M'zoughi, I. Garrido, and A. J. Garrido, "A control technique for hybrid floating offshore wind turbines using oscillating water columns for generated power fluctuation reduction," *Journal of Computational Design and Engineering*, vol. 10, no. 1, pp. 250–265, 2023.
- [22] F. M'zoughi, P. Aboutalebi, I. Garrido, A. J. Garrido, and M. De La Sen, "Complementary airflow control of oscillating water columns for floating offshore wind turbine stabilization," *Mathematics*, vol. 9, no. 12, p. 1364, 2021.
- [23] P. Aboutalebi, A. J. Garrido, J. Schallenberg-Rodriguez, and G. Izaskun, "Validation of vibration reduction in barge-type floating offshore wind turbines with oscillating water columns through experimental and numerical analyses," *Frontiers in Built Environment*, vol. 10, 2024.
- [24] DNV GL, "Sesam user manual - genie," <https://www.dnv.com>, 2016, accessed: 2024-12-22.
- [25] DNV GL, "Sesam user manual - hydrod," <https://www.dnv.com>, 2013, accessed: 2024-12-22.
- [26] DNV GL, "Sesam user manual - wadam," <https://www.dnv.com>, 2017, accessed: 2024-12-22.
- [27] DNV GL, "Sesam sima v3.4-00," <https://www.dnv.com>, 2017, accessed: 2024-12-22.

AI-Based Modeling of Integrated Floating Offshore Wind Turbine and Oscillating Water Column Systems Hybrid Systems

Irfan Ahmad

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0001-6075-2464

Email: irfanahmad.irfan@ehu.eus

Fares Mzoughi, *Associate Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0003-2935-3830

Email: fares.mzoughi@ehu.eus

Payam Aboutalebi, *Associate Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0003-2716-1894

Email: payam.aboutalebi@ehu.eus

Tahereh Bagheri Rouch

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0009-0002-1064-1795

Email: tahereh.bagheri@ehu.eus

Aitor J. Garrido, *Senior Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0002-3016-4976

Email: aitor.garrido@ehu.eus

Izaskun Garrido, *Senior Member, IEEE*

Automatic Control Group – ACG

Department of Automatic Control and Systems Engineering

Engineering School of Bilbao – EIB/BIE

University of the Basque Country – UPV/EHU

Rafael Moreno 3, 48013 Bilbao, Spain

ORCID: 0000-0002-9801-4130

Email: izaskun.garrido@ehu.eus

Abstract—Modeling complex dynamic systems is a critical and often challenging step in developing advanced feedback control strategies, particularly for non-linear and uncertain environments. This paper presents a machine learning-based, control-oriented modeling framework designed to assist researchers in accurately representing such systems with future control implementation in mind. The study focuses on the interaction between Floating Offshore Wind Turbines (FOWTs) and Oscillating Water Columns (OWCs), two key components in marine renewable energy systems. Leveraging the predictive power of Artificial Neural Networks (ANNs) and Convolutional Neural Networks (CNNs), the framework captures the intricate pitch dynamics of the platform, using empirical data from the FAST simulation environment. By integrating machine learning techniques, the proposed framework offers a robust foundation for developing high-fidelity models, facilitating the design of effective feedback control strategies for complex, non-linear systems in marine environments.

Index Terms—Floating Offshore Wind Turbine, oscillating water column, MultiSurf, WAMIT, FAST, offshore structures, aero-hydro-servo-elastic dynamics.

I. INTRODUCTION

Renewable energy has emerged as a critical component in addressing the challenges of climate change and ensuring energy security, with offshore wind power leading the charge. Among renewable technologies, offshore wind power stands out as a rapidly growing and highly promising sector, especially in Europe [1]. Europe has made significant strides in offshore wind energy projects, driving its transition toward a low-carbon economy. The growth of offshore wind farms has been propelled by technological advancements, supportive policies, and significant investments, resulting in increased energy production and reduced greenhouse gas emissions [2].

Over the past ten years, numerous research teams have focused on harnessing energy by combining wave energy converters (WECs) with FOWTs [3]. Combining FOWTs with OWCs, a type of wave energy converter, offers a viable approach to generating hybrid renewable energy.




Fig. 1. FOWT hybrid barge platform integrated with four OWCs.

Incorporating OWCs into FOWT designs enhances platform stability, allowing for more effective capture and utilization of renewable energy sources. This synergy improves both the quantity and quality of energy output and offers an innovative approach to overcoming challenges in sustainable energy generation. By integrating FOWTs with OWCs, researchers seek to maximize energy production by leveraging synergies between wind and wave resources [4]. This integrated approach promises to advance the renewable energy field and support the transition to sustainable, efficient hybrid energy systems. The hybrid design is illustrated in Fig. 1.

Designing a hybrid offshore structure is challenging due to the aero-hydro-servo-elastic dynamics involved, which must be carefully considered [5]. Bottom-supported offshore wind turbines are suited to shallow waters, while floating wind turbines are more appropriate for deep-sea locations. Floating wind turbine designs are classified into three categories based on their stabilization mechanisms: buoyancy-stabilized (barge platform), mooring-stabilized (tension leg platform), and ballast-stabilized (spar buoy) [6].

Significant advancements have been made in modeling and control techniques for FOWTs integrated with OWCs [7]. Researchers have been actively investigating innovative ideas to optimize the performance and reliability of these complex systems through machine learning approaches, with their ability to extract patterns and make predictions from large datasets [8]. By exploiting the power of artificial intelligence, machine learning techniques enable the development of accurate and efficient models for FOWTs integrated with OWCs [9].

Several types of Wave Energy Converters (WECs) have been deployed across Europe, with notable examples being the NEREIDA Wave Power Plant in Mutriku, Spain [10] and Limpet in Scotland [11].

Zhang et al. [12] conducted a study where they developed a time-domain coupled numerical framework to simulate the integration of FOWT with OWCs within a semisubmersible floating platform. The objective of their research was to

validate the performance and feasibility of this integrated system. Another article [13] presented experimental work aimed at validating a novel floating semisubmersible structure that combines three oscillating water columns with a 5 MW wind turbine, enabling simultaneous harvesting of wind and wave energy. Furthermore, recent research by P. Aboutalebi et al. [14] successfully validated a hybrid platform capable of harnessing energy from both wind and waves. Their study demonstrated the feasibility of integrating two and four OWCs into barge platforms [15]. Fig. 1. illustrates the integration of four OWCs into a platform, highlighting the potential for active structural control. In comparison to spar and tension leg platforms [16], the size and design of barge platforms facilitate easier integration of WECs. The article is organized as follows: Section II covers the theoretical background. Section III describes the neural network architectures. Section IV outlines the methodology, including data collection and model development. Section V discusses model performance, and Section VI concludes the study with key insights and future directions.

II. THEORETICAL BACKGROUND

From an engineering perspective, offshore projects present distinct challenges that require careful consideration and innovative design approaches. Developing effective designs for offshore structures necessitates a comprehensive understanding of their analysis and fundamental principles. The incorporation of innovative platform geometries is believed to hold the potential for reducing the environmental stresses experienced by these structures. Therefore, a deep understanding of analysis techniques and core design principles is crucial in tackling the complexities of offshore projects.

Analyzing and understanding the control performance of an aero-hydro-servo-elastic floating structure is a challenging and complex task. We integrated four OWCs moonpools into the J. Jonkman barge platform, placing one at each corner and a 40 x 40 x 10 m moonpool in the middle. Several numerical engineering programs, including MATLAB, WAMIT, FAST, and Multisurf, were employed to construct the hybrid platform. The main idea of using barge-type platform because barge-type platforms are more cost-effective and easier to maintain due to their simpler design.

A. MultiSurf

MultiSurf is a 3D modeling tool used for intricate surface representation and direct import of geometry files into WAMIT. It scales up platform geometry by a factor of 1.8 using B-spline curves.

B. WAMIT

WAMIT is a hydrodynamic analysis program developed jointly by WAMIT Inc. and MIT, assessing unsteady hydrodynamic loads through a radiation and diffraction panel approach.

The geometry of the platform was generated using MultiSurf, resulting in the creation of two distinct platforms,

each possessing unique characteristics. Fig. 2, showcases the first platform, which exhibits a typical barge platform configuration. On the other hand, Fig. 3, illustrates the second platform, designed as a barge platform with four OWCs positioned at the corners.




Fig. 2. The standard barge platform geometry




Fig. 3. The four OWC-based barge platforms' geometry

C. FAST

FAST, from NREL, is open-source software for simulating wind turbine systems, enabling coupled dynamic analyses for turbines, with modules like AeroDyn, ServoDyn, ElastoDyn, HydroDyn, and MAP.

D. MATLAB/Simulink

Following the simulations conducted using FAST, the collected data is utilized to train models through deep neural networks. Additionally, control algorithms are implemented in Simulink to stabilize the hybrid system.

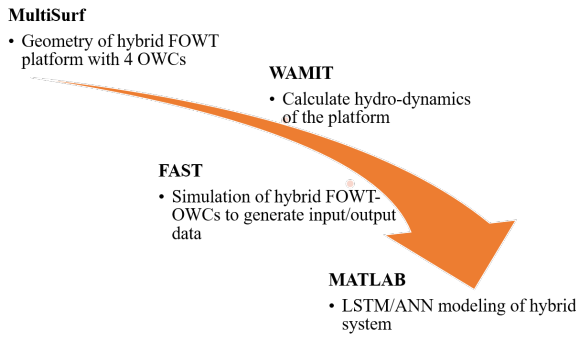


Fig. 4. Navigating multiple steps and numerical tools

The nonlinear dynamics of a 5-MW FOWT integrated with four OWCs to barge a platform in the time-domain can be described as (1):

$$M_{ij}(x, u, t)\ddot{x}_j = f_i(x, \dot{x}, u, t) \quad (1)$$

where M_{ij} , is the mass inertia, t is the time, u is the control inputs, and \ddot{x} is the second time derivative of the j^{th} Degree of Freedom (DOF).

The generalized external force acting on the system is represented by the term on the right-hand side of Equation (1). This term encompasses various components, including the aerodynamic load on the blades and nacelle, hydrodynamic forces on the platform, and elastic and servo forces.

In the frequency domain, the generalized system for the linear equations of motion can be expressed as follows in Equation (2):

$$I_{FOWT}(\omega)\ddot{x} + D_{FOWT}(\omega)\dot{x} + S_{FOWT}x = \vec{f}_{FOWT}(\omega) + \vec{f}_{PTO}(\omega) \quad (2)$$

Here, I_{FOWT} , D_{FOWT} , and S_{FOWT} can be represented as inertia, damping, and stiffness matrices, respectively. $\vec{f}_{PTO}(\omega)$ and $\vec{f}_{FOWT}(\omega)$ represent the wave-induced drag and hydrodynamic forces imposed by the Power Take-Off (PTO).

The inertia, damping, and stiffness matrices of the FOWT are best expressed in the following Equations (3-5):

$$I_{FOWT}(\omega) = A_{Hydro}(\omega) + M_{Platform} + M_{Tower} \quad (3)$$

$$D_{FOWT}(\omega) = D_{Hydro}(\omega) + D_{Tower} + D_{viscous} + D_{chamber} \quad (4)$$

$$S_{FOWT} = S_{Hydro} + S_{Mooring} + S_{Tower} \quad (5)$$

III. NEURAL NETWORK ARCHITECTURES

This section describes two widely used neural network architectures: ANN and CNN. Both architectures are employed for various machine learning tasks, including classification, regression, and time-series prediction.

A. Artificial Neural Networks (ANN)

ANNs are feedforward networks composed of multiple layers of neurons. Each neuron computes a weighted sum of the inputs, applies a non-linear activation function, and passes the result to the next layer. A typical ANN consists of an input layer, one or more hidden layers, and an output layer.

The output of a neuron in a hidden layer is given by:

$$h_t = \text{ReLU}(x_t W + b) \quad (6)$$

where:

- x_t is the input at time step t ,
- W is the weight matrix for the connections between layers,
- b is the bias term,
- $\text{ReLU}(x) = \max(0, x)$ is the Rectified Linear Unit activation function.

The output layer computes the final prediction, which can be a continuous value (in the case of regression) or a probability

distribution over classes (in the case of classification). For classification tasks, a softmax function is applied:

$$y_t = \text{softmax}(h_t W_o + b_o) \quad (7)$$

where W_o and b_o are the weights and biases of the output layer.

B. Convolutional Neural Networks (CNNs)

CNNs are specialized neural networks designed for data with grid-like topology, such as images or time-series data. CNNs use convolutional layers to apply filters to the input, extracting spatial or temporal features, followed by pooling layers to downsample the feature maps. Finally, fully connected layers are used for the prediction.

In the convolutional layer, a set of filters F is applied to the input x_t , generating feature maps:

$$h_t = \text{ReLU}(x_t * F + b) \quad (8)$$

where:

- x_t is the input at time step t ,
- F represents the convolutional filter,
- $*$ denotes the convolution operation,
- b is the bias term.

After convolution, a pooling layer reduces the dimensionality of the feature map, typically through max-pooling:

$$p_t = \text{MaxPool}(h_t) \quad (9)$$

where $\text{MaxPool}(h_t)$ selects the maximum value in a window over the feature map.

Finally, the output of the pooling layers is flattened and passed through a fully connected layer for prediction, similar to the output layer in ANN:

$$y_t = \text{softmax}(W_f p_t + b_f) \quad (10)$$

where W_f and b_f are the weights and biases of the fully connected layer.

IV. METHODOLOGY

Several steps have been involved beginning with the loading and preparation of data from FAST (Fatigue, Aerodynamics, Structures, and Turbulence). FAST integrates aerodynamics, hydrodynamics, control and electrical system dynamics, and structural dynamics models to enable coupled nonlinear aero-hydro-servo-elastic simulation in the time domain. FAST allows the analysis of various wind turbine configurations, onshore or offshore, with different rotor designs, hub types, tower and platform structures. The simulations performed in FAST are then imported into MATLAB for the development of the neural estimators. The complete data has been divided into input features and target variables, with 80% allocated for training and the remaining 20% for testing to assess model performance. Advanced Tools and steps for Integrated Platforms that are required have been shown in Fig. 4.

A. Data Collection and Preprocessing

Data was obtained from simulations using the FAST environment. The data contains various input features, such as wind speed, wave height, and platform motion, and the corresponding platform pitch dynamics are considered as output features.

The dataset was split into training (70%) and testing (30%) sets using a holdout method. The training set was normalized using z-score standardization to improve model performance, and the test data was scaled using the same mean and standard deviation to prevent data leakage.

B. ANN Model Architecture

The ANN was designed with a simple feedforward structure:

- Input layer with the size of the feature space.
- One hidden layer with 10 neurons and the Rectified Linear Unit (ReLU) activation function.
- An output layer for regression to predict the platform pitch.

The model was trained using the Adam optimizer with a learning rate of 0.01 for 50 epochs. Mean squared error (MSE) was used as the loss function.

C. CNN Model Architecture

The CNN model was designed to handle the complex nature of the system dynamics:

- The data was reshaped into a 4D structure for the CNN's input layer.
- Two convolutional layers with 16 and 32 filters, each followed by batch normalization and ReLU activation.
- A fully connected layer with 50 neurons, followed by a ReLU layer.
- The output layer for predicting the pitch dynamics.

The CNN was trained for 50 epochs using the Adam optimizer with a lower learning rate (0.001) and a smaller batch size (10).

D. Model Evaluation

Both the ANN and CNN models were evaluated based on three metrics:

- **Root Mean Squared Error (RMSE):** measures the average magnitude of the prediction errors.
- **Mean Absolute Error (MAE):** quantifies the average difference between predicted and actual values.
- **R-squared (R^2):** indicates how well the model explains the variance in the data.

The models were compared using these metrics on the test set and visualizations of predicted vs. actual output, residuals, and error histograms were generated.

V. DETAILED DISCUSSION ON ANN AND CNN PERFORMANCE

In this section, we analyze the performance of the ANN and CNN models in the prediction task. Both models demonstrated strong predictive capabilities, though the ANN slightly outperformed the CNN across key performance metrics, namely RMSE, MAE, and R-squared.

The ANN model achieved a lower RMSE of 1.3849 compared to CNN's RMSE of 1.4014, indicating that the ANN had slightly better accuracy in terms of prediction error. Similarly, the MAE for the ANN was 1.0821, slightly lower than CNN's MAE of 1.0915. These values suggest that the ANN was marginally more effective in minimizing the absolute differences between predicted and actual values.

Furthermore, the value of R squared, which measures the proportion of variance explained by the model, was higher for ANN ($R^2 = 0.65081$) than for the CNN ($R^2 = 0.64243$). This indicates that the ANN was able to explain slightly more of the variation in the dataset, further confirming its superior performance.

Despite these differences, the overall performance of the two models was quite similar, which highlights the effectiveness of both architectures in this context. The CNN, with its convolutional layers, is generally better suited for tasks involving spatial or temporal data, where local patterns are important. However, in this particular problem, the simpler feedforward structure of the ANN appeared to be more effective.

A. Performance Metrics Comparison

The following table summarizes the performance metrics for the ANN and CNN models.

TABLE I
PERFORMANCE COMPARISON OF ANN AND CNN MODELS

Metric	ANN	CNN
RMSE	1.3849	1.4014
MAE	1.0821	1.0915
R-squared	0.65081	0.64243

B. Interpretation of Results

The marginal difference in performance between the ANN and CNN can be attributed to the specific characteristics of the dataset generated from FAST. The data used in this study may not have contained sufficient spatial or temporal patterns that could be exploited by the CNN's convolutional layers. As a result, CNN's additional complexity did not yield significant improvements over the simpler ANN architecture. In fact, fully connected layers in the ANN may have been more effective in capturing the global relationships present in the data.

The relatively close performance of both models highlights the importance of selecting an appropriate architecture based on the characteristics of the dataset. Although CNNs typically excel in tasks such as image classification or time series

prediction, where local feature extraction is critical, they may not always be the best choice when the data lack such local patterns. In this case, the ability of the ANN to model complex relationships through its fully connected layers made it a more suitable choice for this problem.

Both the ANN and CNN models demonstrated strong performance in predicting the dynamics of the system. However, the ANN slightly outperformed the CNN in terms of RMSE, MAE, and R-squared. The differences in performance, though small, suggest that for this specific problem, the ANN's simpler structure was more effective. Nonetheless, the CNN remains a powerful tool for tasks where local patterns or spatial relationships are more prominent, and its performance in this study underscores its versatility.

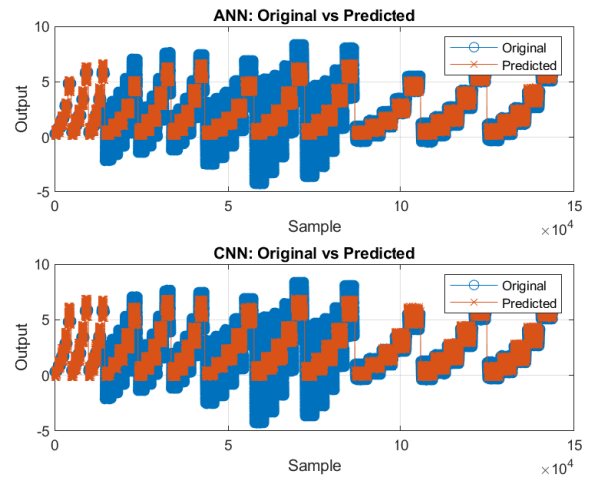


Fig. 5. Original vs. Predicted Pitch Dynamics.

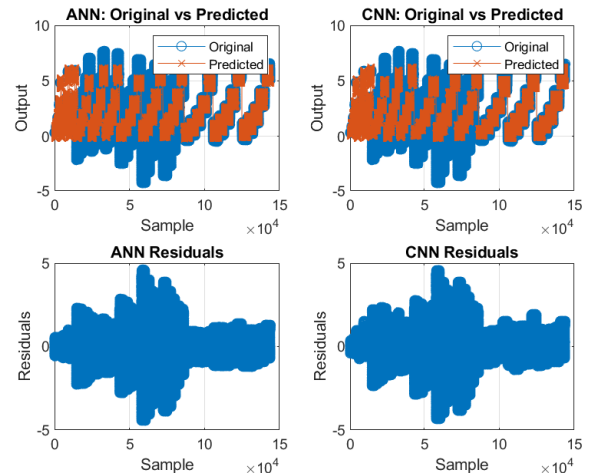


Fig. 6. Residual Plots.

In order to validate the predictive accuracy of the ANN and CNN models, Fig. 5 presents a comparison between the original platform pitch dynamics obtained from




Fig. 7. Error Histograms for ANN and CNN.

the FAST simulation environment and the predicted pitch dynamics generated by both models. The close alignment of the predicted and actual curves highlights the model's effectiveness in capturing the system's behavior under varying conditions.

To further evaluate the accuracy of the ANN predictions, Fig. 6 illustrates the residual plots, which display the difference between the actual and predicted values. These residuals provide insight into any systematic bias or errors in the model's predictions. The relatively small and randomly distributed residuals suggest that the ANN model is capable of reliably predicting the pitch dynamics of the floating structure.

Fig. 7 shows the error histograms for both the ANN and CNN models. This comparison highlights the distribution of prediction errors for each model, with the majority of errors falling close to zero, indicating a high level of prediction accuracy for both models. However, the slight differences in the error distribution between the two models suggest that each method has distinct strengths in capturing certain aspects of the system's dynamics.

VI. CONCLUSION

This study demonstrates the effectiveness of using ANN and CNN for predicting the pitch dynamics of integrated FOWT and OWC systems. The ANN model slightly outperforms the CNN in this particular case, but both models provide robust predictions that can be used to develop advanced control strategies. Future work may explore more complex neural network architectures, such as deeper CNNs or recurrent neural networks (RNNs), to further improve performance.

ACKNOWLEDGEMENTS

The authors would like to thank the Basque Government for partially funding their research work through Grant IT1555-22 and they thank MICIU/AEI/ 10.13039/501100011033 and ERDF/EU for partially funding their research work through

Grants PID2021-123543OB-C21, PID2021-123543OB-C22 and through grant PIF20/299.

REFERENCES

- [1] V. Duscha, A. Fougeyrollas, C. Nathani, M. Pfaff, M. Ragwitz, G. Resch, W. Schade, B. Breitschopf, and R. Walz, "Renewable energy deployment in europe up to 2030 and the aim of a triple dividend," *Energy Policy*, vol. 95, pp. 314–323, 2016.
- [2] A. Olabi, K. Obaideen, M. A. Abdelkareem, M. N. AlMallahi, N. Shehata, A. H. Alami, A. Mdallal, A. A. M. Hassan, and E. T. Sayed, "Wind energy contribution to the sustainable development goals: case study on london array," *Sustainability*, vol. 15, no. 5, p. 4641, 2023.
- [3] F. M'zoughi, P. Aboutaleb, I. Garrido, A. J. Garrido, and M. De La Sen, "Complementary airflow control of oscillating water columns for floating offshore wind turbine stabilization," *Mathematics*, vol. 9, no. 12, p. 1364, 2021.
- [4] I. Ahmad, F. M'zoughi, P. Aboutaleb, I. Garrido, and A. J. Garrido, "Fuzzy logic control of an artificial neural network-based floating offshore wind turbine model integrated with four oscillating water columns," *Ocean Engineering*, vol. 269, p. 113578, 2023.
- [5] J. Chen, Z. Hu, G. Liu, and D. Wan, "Coupled aero-hydro-servo-elastic methods for floating wind turbines," *Renewable energy*, vol. 130, pp. 139–153, 2019.
- [6] M. Karimi, M. Hall, B. Buckham, and C. Crawford, "A multi-objective design optimization approach for floating offshore wind turbine support structures," *Journal of Ocean Engineering and Marine Energy*, vol. 3, pp. 69–87, 2017.
- [7] F. M'zoughi, I. Garrido, A. J. Garrido, and M. De la Sen, "Fuzzy gain scheduled-sliding mode rotational speed control of an oscillating water column," *IEEE Access*, vol. 8, pp. 45 853–45 873, 2020.
- [8] I. Ahmad, F. M'zoughi, P. Aboutaleb, I. Garrido, and A. J. Garrido, "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*, vol. 13, no. 1, p. 1499, 2023.
- [9] I. Ahmad, F. Mzoughi, P. Aboutaleb, I. Garrido, and A. Garrido, "A machine-learning approach for the development of a fowt model integrated with four owcs," in *2022 26th International Conference on Circuits, Systems, Communications and Computers (CSCC)*. IEEE, 2022, pp. 72–76.
- [10] F. M'zoughi, S. Bouallegue, A. J. Garrido, I. Garrido, and M. Ayadi, "Stalling-free control strategies for oscillating-water-column-based wave power generation plants," *IEEE Transactions on Energy Conversion*, vol. 33, no. 1, pp. 209–222, 2017.
- [11] R. P. Gomes, J. Henriques, L. Gato, and A. d. O. Falcao, "Design of a floating oscillating water column for wave energy conversion," in *Proceedings of the 9th European Wave and Tidal Energy Conference, Southampton, UK*, 2011.
- [12] D. Zhang, Z. Chen, X. Liu, J. Sun, H. Yu, W. Zeng, Y. Ying, Y. Sun, L. Cui, S. Yang *et al.*, "A coupled numerical framework for hybrid floating offshore wind turbine and oscillating water column wave energy converters," *Energy Conversion and Management*, vol. 267, p. 115933, 2022.
- [13] J. Sarmiento, A. Iturrioz, V. Ayllón, R. Guanche, and I. Losada, "Experimental modelling of a multi-use floating platform for wave and wind energy harvesting," *Ocean Engineering*, vol. 173, pp. 761–773, 2019.
- [14] P. Aboutaleb, F. M'zoughi, I. Garrido, and A. J. Garrido, "A control technique for hybrid floating offshore wind turbines using oscillating water columns for generated power fluctuation reduction," *Journal of Computational Design and Engineering*, vol. 10, no. 1, pp. 250–265, 2023.
- [15] F. M'zoughi, P. Aboutaleb, I. Garrido, A. J. Garrido, and M. De La Sen, "Complementary airflow control of oscillating water columns for floating offshore wind turbine stabilization," *Mathematics*, vol. 9, no. 12, p. 1364, 2021.
- [16] A. Alkhalidi, H. Kaylani, and N. Alawawdeh, "Technology assessment of offshore wind turbines: Floating platforms—validated by case study," *Results in Engineering*, vol. 17, p. 100831, 2023.

Zabalduz

Jardunaldi, kongresu, sinposio, hitzaldi
eta omenaldien argitalpenak

INFORMAZIOA ETA ESKARIAK • INFORMACIÓN Y PEDIDOS

ACG UPV/EHU
ispgahei@ehu.eus
Tfn.: 94 601 4456 • www.ehu.eus/acg



Universidad
del País Vasco

Euskal Herriko
Unibertsitatea