



MÁSTER UNIVERSITARIO EN INGENIERÍA DE TELECOMUNICACIÓN

TRABAJO FIN DE MÁSTER

Análisis comparativo de modelos de aprendizaje
automático para la predicción de la generación eléctrica de
un parque eólico marino.

Autor: Carlos de los Santos Jiménez

Director: Antonio Muñoz San Roque

Madrid

2024

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título

Análisis comparativo de modelos de aprendizaje automático para la predicción de la generación eléctrica de un parque eólico marino.

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico **2023/24** es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido

tomada de otros documentos está debidamente referenciada.



Fdo.: Carlos de los Santos Jiménez

Fecha: ...16.../ ...06.../ ...2024...

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO



Fdo.: Antonio Muñoz San Roque

Fecha: ...16.../ ...06.../ ...2024...

AUTORIZACIÓN PARA LA DIGITALIZACIÓN, DEPÓSITO Y DIVULGACIÓN EN RED DE PROYECTOS FIN DE GRADO, FIN DE MÁSTER, TESIS O MEMORIAS DE BACHILLERATO

1º. Declaración de la autoría y acreditación de la misma.

El autor D. Carlos de los Santos Jiménez

DECLARA ser el titular de los derechos de propiedad intelectual de la obra: Análisis comparativo de modelos de aprendizaje automático para la predicción de la generación eléctrica de un parque eólico marino., que ésta es una obra original, y que ostenta la condición de autor en el sentido que otorga la Ley de Propiedad Intelectual.

2º. Objeto y fines de la cesión.

Con el fin de dar la máxima difusión a la obra citada a través del Repositorio institucional de la Universidad, el autor **CEDE** a la Universidad Pontificia Comillas, de forma gratuita y no exclusiva, por el máximo plazo legal y con ámbito universal, los derechos de digitalización, de archivo, de reproducción, de distribución y de comunicación pública, incluido el derecho de puesta a disposición electrónica, tal y como se describen en la Ley de Propiedad Intelectual. El derecho de transformación se cede a los únicos efectos de lo dispuesto en la letra a) del apartado siguiente.

3º. Condiciones de la cesión y acceso

Sin perjuicio de la titularidad de la obra, que sigue correspondiendo a su autor, la cesión de derechos contemplada en esta licencia habilita para:

- a) Transformarla con el fin de adaptarla a cualquier tecnología que permita incorporarla a internet y hacerla accesible; incorporar metadatos para realizar el registro de la obra e incorporar “marcas de agua” o cualquier otro sistema de seguridad o de protección.
- b) Reproducirla en un soporte digital para su incorporación a una base de datos electrónica, incluyendo el derecho de reproducir y almacenar la obra en servidores, a los efectos de garantizar su seguridad, conservación y preservar el formato.
- c) Comunicarla, por defecto, a través de un archivo institucional abierto, accesible de modo libre y gratuito a través de internet.
- d) Cualquier otra forma de acceso (restringido, embargado, cerrado) deberá solicitarse expresamente y obedecer a causas justificadas.
- e) Asignar por defecto a estos trabajos una licencia Creative Commons.
- f) Asignar por defecto a estos trabajos un HANDLE (URL *persistente*).

4º. Derechos del autor.

El autor, en tanto que titular de una obra tiene derecho a:

- a) Que la Universidad identifique claramente su nombre como autor de la misma
- b) Comunicar y dar publicidad a la obra en la versión que ceda y en otras posteriores a través de cualquier medio.
- c) Solicitar la retirada de la obra del repositorio por causa justificada.
- d) Recibir notificación fehaciente de cualquier reclamación que puedan formular terceras personas en relación con la obra y, en particular, de reclamaciones relativas a los derechos de propiedad intelectual sobre ella.

5º. Deberes del autor.

El autor se compromete a:

- a) Garantizar que el compromiso que adquiere mediante el presente escrito no infringe ningún derecho de terceros, ya sean de propiedad industrial, intelectual o cualquier otro.
- b) Garantizar que el contenido de las obras no atenta contra los derechos al honor, a la intimidad y a la imagen de terceros.

- c) Asumir toda reclamación o responsabilidad, incluyendo las indemnizaciones por daños, que pudieran ejercitarse contra la Universidad por terceros que vieran infringidos sus derechos e intereses a causa de la cesión.
- d) Asumir la responsabilidad en el caso de que las instituciones fueran condenadas por infracción de derechos derivada de las obras objeto de la cesión.

6º. Fines y funcionamiento del Repositorio Institucional.

La obra se pondrá a disposición de los usuarios para que hagan de ella un uso justo y respetuoso con los derechos del autor, según lo permitido por la legislación aplicable, y con fines de estudio, investigación, o cualquier otro fin lícito. Con dicha finalidad, la Universidad asume los siguientes deberes y se reserva las siguientes facultades:

- La Universidad informará a los usuarios del archivo sobre los usos permitidos, y no garantiza ni asume responsabilidad alguna por otras formas en que los usuarios hagan un uso posterior de las obras no conforme con la legislación vigente. El uso posterior, más allá de la copia privada, requerirá que se cite la fuente y se reconozca la autoría, que no se obtenga beneficio comercial, y que no se realicen obras derivadas.
- La Universidad no revisará el contenido de las obras, que en todo caso permanecerá bajo la responsabilidad exclusiva del autor y no estará obligada a ejercitar acciones legales en nombre del autor en el supuesto de infracciones a derechos de propiedad intelectual derivados del depósito y archivo de las obras. El autor renuncia a cualquier reclamación frente a la Universidad por las formas no ajustadas a la legislación vigente en que los usuarios hagan uso de las obras.
- La Universidad adoptará las medidas necesarias para la preservación de la obra en un futuro.
- La Universidad se reserva la facultad de retirar la obra, previa notificación al autor, en supuestos suficientemente justificados, o en caso de reclamaciones de terceros.

Madrid, a ...16..... deMayo..... de ...2024.....

ACEPTA

Fdo: Carlos de los Santos Jiménez

Motivos para solicitar el acceso restringido, cerrado o embargado del trabajo en el Repositorio Institucional:



COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

MÁSTER UNIVERSITARIO EN INGENIERÍA DE TELECOMUNICACIÓN

TRABAJO FIN DE MÁSTER

Análisis comparativo de modelos de aprendizaje
automático para la predicción de la generación eléctrica de
un parque eólico marino.

Autor: Carlos de los Santos Jiménez

Director: Antonio Muñoz San Roque

Madrid

2024

Agradecimientos

A mi padre, por transmitirme su forma de vivir y disfrutar, y su lucha hasta el último día.

A Antonio, por su labor de guía y consejo, y por su entendimiento de todas las situaciones vividas durante el desarrollo del trabajo

ANÁLISIS COMPARATIVO DE MODELOS DE APRENDIZAJE AUTOMÁTICO PARA LA PREDICCIÓN DE LA GENERACIÓN ELÉCTRICA DE UN PARQUE EÓLICO MARINO.

Autor: De los Santos Jiménez, Carlos

Director: Muñoz San Roque, Antonio.

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

RESUMEN DEL PROYECTO

El trabajo se centrará en la identificación, entrenamiento y comparación de modelos de *machine learning* para la predicción de potencia eólica en horizontes temporales de 1 a 9 horas de un parque eólico marino situado en el mar del Norte. Se hará uso tanto de datos obtenidos de los sensores de las turbinas como de predicciones meteorológicas.

Palabras clave: energía eólica, offshore, predicción, aprendizaje automático, NWP

1. Introducción

El desarrollo sostenible y la lucha contra el cambio climático han llevado a un cambio significativo en el uso de fuentes de energía renovable. La energía eólica marina se ha destacado como una opción viable debido a la constancia y fiabilidad del viento en alta mar. Sin embargo, la predicción precisa de la generación de energía eólica sigue siendo un desafío debido a las fluctuaciones meteorológicas. Este trabajo se enfoca en comparar diferentes modelos de aprendizaje automático para predecir la generación de energía en parques eólicos marinos, tomando como caso de estudio el parque eólico Alpha Ventus, ubicado en el mar del Norte. El objetivo es que el trabajo pueda servir de utilidad a los generadores de energía que acuden al mercado intradiario para corregir sus ofertas de generación realizadas 24 horas antes en el mercado diario.

2. Definición del proyecto

El Proyecto desarrollará todo el trabajo necesario para la identificación y entrenamiento de los distintos modelos de *Machine Learning* utilizados para la predicción de la potencia eólica. Se establecerán dos modelos de referencia, ARIMA y persistencia, y se comparará su desempeño con tres redes neuronales: MLP, LSTM y GRU para horizontes temporales de 1 a 9 horas, de forma que las predicciones sean relevantes para el mercado intradiario.

3. Descripción del trabajo realizado

La Ilustración 1 muestra un resumen de la metodología llevada a cabo para la elaboración del trabajo:

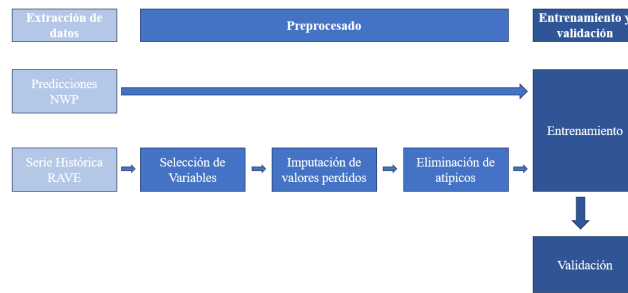


Ilustración 1: Metodología de trabajo

1. **Extracción de datos:** los modelos desarrollados combinan en su entrenamiento datos procedentes de los sensores de las propias turbinas del parque eólico (serie histórica RAVE) y predicciones meteorológicas (*Numerical Weather Predictions*) del modelo de ICON-D2 que cubre todo el territorio alemán, Benelux, Suiza, Austria y partes de los demás países vecinos con una resolución horizontal de 2,2 km (Reinert et al., 2023).
2. **Preprocesado:** tras la obtención de datos se seleccionan las variables más relevantes ofrecidas por los sensores de las turbinas para la predicción. Estas variables son aquellas con un coeficiente de correlación con la potencia eólica mayor que 0,2. Tras esto, para mantener la integridad estructural de la serie temporal se lleva a cabo la imputación de valores perdidos haciendo uso del algoritmo XGBoost (Chen & Guestrin, 2016) y la ecuación teórica de la potencia eólica:

- a.
$$P = \frac{1}{2} A \rho v^3 C_p$$

3. Ecuación 1: Ecuación teórica de la potencia eólica

Tras esto se eliminan los valores atípicos que pueden dañar la precisión de la potencia eólica haciendo uso del algoritmo *isolation forest* (Liu et al, 2009).

4. **Entrenamiento y validación:** a continuación, se entrena cada uno de los modelos mencionados. Para el entrenamiento se hace uso del 80% de los datos disponibles, reservado el 20% restante para analizar la validez predictiva de los modelos. Los modelos son los siguientes:
 - **Modelo de persistencia:** modelo simple en el que el valor futuro de la potencia eólica para un determinado horizonte de predicción coincide con el valor actual.
 - **Modelo ARIMA:** modelo autorregresivo basado en la metodología desarrollado Box y Jenkins (1972).
 - **Red MLP:** red neuronal simple de tipo *feed-forward* que permite capturar no linealidades de la serie.

- **Red LSTM:** red neuronal recurrente con memoria a largo plazo, desarrollada por Hochreiter y Schmidhuber (1997).
- **Red GRU:** red neuronal recurrente, de características similares a la red LSTM, pero de menor complejidad. Fue desarrollada por Cho et al. (2014).

4. Resultados

El entrenamiento se ha realizado con las distintas combinaciones de variables seleccionadas, tanto las procedentes de las mediciones de los sensores como las predicciones de los modelos ICON-D2. También se han variado el número de retardos incluidos como entrada de cada una de las variables explicativas. La siguiente tabla muestra el error medio absoluto para un horizonte de predicción de 3 horas de los 3 mejores modelos:

Modelo	V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H
GRU	Potencia Eólica, Viento Histórico y W64	3	235.31	363.56	466.41
MLP	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	243.97	387.47	485.30
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W64	3	258.78	388.47	489.97

Tabla 1: desempeño de los 3 mejores modelos para un horizonte de 3 horas

5. Conclusiones

- Cualquiera de los modelos: MLP, GRU, y LSTM supera la capacidad predictiva de los dos modelos de referencia seleccionados: persistencia y ARIMA.
- El modelo GRU entrenado con las variables: Potencia Eólica, Viento Histórico y W64 es del de mayor precisión para horizontes temporales cercanos.

6. Referencias

- [1] Reinert, D. R., Prill, F. P., Frank, H. F., Denhard, M. D., Baldauf, M. B., Schraff, C. S., Gebhardt, C. G., Marsigli, C. M., & Zängl, G. Z. (2023). *DWD Database Reference for the Global and Regional ICON and ICON-EPS*
- [2] Chen, Tianqi & Guestrin, Carlos. (2016). XGBoost: A Scalable Tree Boosting System. 785-794. 10.1145/2939672.2939785.
- [3] Liu, Fei Tony & Ting, Kai & Zhou, Zhi-Hua. (2009). Isolation Forest. 413 - 422. 10.1109/ICDM.2008.17.
- [4] Box, G. E. P., & Jenkins, G. M. (1972). Time series analysis forecasting and control. *Econometrica*, 40(5), 970. <https://doi.org/10.2307/1912100>
- [5] Hochreiter, S., & Schmidhuber, J. (1997b). Long Short-Term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [6] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014b). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1406.1078>

COMPARATIVE ANALYSIS OF MACHINE LEARNING MODELS FOR WIND POWER FORECASTING OF AN OFFSHORE WIND FARM.

Author: De los Santos Jiménez, Carlos.

Supervisor: Muñoz San Roque, Antonio

Collaborating Entity: ICAI – Universidad Pontificia Comillas.

ABSTRACT

The work will focus on the identification, training and comparison of machine learning models for wind power prediction in time horizons from 1 to 9 hours for an offshore wind farm located in the North Sea. It will be used both data obtained from turbine sensors and meteorological forecasts.

Keywords: wind power, offshore, forecasting, machine learning, NWP

1. Introduction

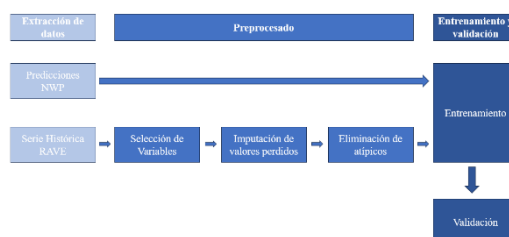
Sustainable development and the fight against climate change have led to a significant shift in the use of renewable energy sources. Offshore wind energy has been highlighted as a viable option due to the constancy and reliability of offshore wind. However, accurate prediction of wind power generation remains a challenge due to meteorological fluctuations. This work focuses on comparing different machine learning models for predicting power generation in offshore wind farms, taking the Alpha Ventus wind farm, located in the North Sea, as a case study. The objective is that the work can be useful to power generators that use the intraday market to correct their generation bids made 24 hours before in the day-ahead market.

2. Project Definition

The Project will develop all the necessary work for the identification and training of the different Machine Learning models used for wind power prediction. Two reference models, ARIMA and persistence, will be established and their performance will be compared with three neural networks: MLP, LSTM and GRU for time horizons from 1 to 9 hours, so that the predictions are relevant for the intraday market.

3. Work Description

Figure 1 shows a summary of the methodology used to prepare this work:



1. Data mining: the developed models combine in their training data from the wind farm's own turbine sensors (historical RAVE series) and weather forecasts (Numerical

Weather Predictions) from the ICON-D2 model covering the entire German territory, Benelux, Switzerland, Austria and parts of the other neighboring countries with a horizontal resolution of 2.2 km (Reinert et al., 2023).

2. Preprocessing: after data collection, the most relevant variables provided by the turbine sensors are selected for prediction. These variables are those with a correlation coefficient with wind power greater than 0.2. After this, in order to maintain the structural integrity of the time series, the imputation of missing values is carried out using the XGBoost algorithm (Chen & Guestrin, 2016) and the theoretical wind power equation:

$$P = \frac{1}{2} A \rho v^3 C_p$$

Equation 2: Theoretical equation of wind power

After this, outliers that could damage the accuracy of the wind power are eliminated using the isolation forest algorithm (Liu et al, 2009).

3. Training and validation: next, each of the models mentioned above is trained. For training, 80% of the available data is used, reserving the remaining 20% to analyze the predictive validity of the models. The models are as follows:

- Persistence model: simple model in which the future value of wind power for a given prediction horizon coincides with the current value.
- ARIMA model: autoregressive model based on the methodology developed by Box and Jenkins (1972).
- MLP network: simple feed-forward neural network that allows capturing nonlinearities in the series.
- LSTM network: recurrent neural network with long-term memory, developed by Hochreiter and Schmidhuber (1997).
- GRU network: recurrent neural network, with similar characteristics to the LSTM network, but of lower complexity. It was developed by Cho et al. (2014).

4. Results

The training has been carried out with the different combinations of variables selected, both from the sensor measurements and the predictions of the ICON-D2 models. The number of lags included as input for each of the explanatory variables has also been varied. The following table shows the mean absolute error for a 3-hour prediction horizon of the 3 best models:

Modelo	V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H
GRU	Potencia Eólica, Viento Histórico y W64	3	235.31	363.56	466.41
MLP	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	243.97	387.47	485.30
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W64	3	258.78	388.47	489.97

5. Conclusions

- - Any of the models: MLP, GRU, and LSTM outperforms the predictive capacity of the two selected reference models: persistence and ARIMA.
- - The GRU model trained with the variables: Wind Power, Historical Wind and W64 is the most accurate for close time horizons.

6. References

- [1] Reinert, D. R., Prill, F. P., Frank, H. F., Denhard, M. D., Baldauf, M. B., Schraff, C. S., Gebhardt, C. G., Marsigli, C. M., & Zängl, G. Z. (2023). *DWD Database Reference for the Global and Regional ICON and ICON-EPS*
- [2] Chen, Tianqi & Guestrin, Carlos. (2016). XGBoost: A Scalable Tree Boosting System. 785-794. 10.1145/2939672.2939785.
- [3] Liu, Fei Tony & Ting, Kai & Zhou, Zhi-Hua. (2009). Isolation Forest. 413 - 422. 10.1109/ICDM.2008.17.
- [4] Box, G. E. P., & Jenkins, G. M. (1972). Time series analysis forecasting and control. *Econometrica*, 40(5), 970. <https://doi.org/10.2307/1912100>
- [5] Hochreiter, S., & Schmidhuber, J. (1997b). Long Short-Term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [6] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014b). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. arXiv (Cornell University). <https://doi.org/10.48550/arxiv.1406.1078>

Índice de la Memoria

<i>Índice de la Memoria</i>	18
<i>Índice de Ilustraciones</i>	20
<i>Índice de Figuras</i>	21
<i>Índice de Tablas</i>	22
Capítulo 1. Introducción.....	23
1.1 Motivación.....	25
Capítulo 2. La energía eólica.....	28
2.1 Parques eólicos	28
2.2 Los Aerogeneradores	31
Capítulo 3. El Parque Eólico Alpha Ventus	33
3.1 Historia del parque.....	33
3.2 Los aerogeneradores de Alpha Ventus	34
3.3 El proyecto Rave	35
3.3.1 Mediciones y sensores del proyecto RAVE	37
Capítulo 4. Estado del Arte	40
4.1 La Generación de energía eólica	40
4.2 Técnicas de predicción	40
4.2.1 Métodos Físicos	41
4.2.2 Métodos estadísticos y de aprendizaje automático.....	43
4.3 Métodos Híbridos	53
Capítulo 5. Metodología.....	56
5.1 Extracción de datos.....	56

5.1.1 Serie Histórica RAVE	56
5.1.2 Predicciones NWP	59
5.2 Preprocesado.....	63
5.2.1 Selección de Variables.....	64
5.2.2 Imputación de Valores Perdidos.....	66
5.2.3 Identificación y Tratamiento de atípicos	70
5.3 Identificación y Ajuste de los modelos.....	75
5.3.1 Modelo Arima	75
5.4 Redes Neuronales	82
5.4.1 Redes Neuronales <i>Feed-Forward tipo Perceptrón Multicapa</i>	82
5.4.2 Redes neuronales Recurrentes	86
5.5 Validez predictiva.....	95
Capítulo 6. Resultados.....	96
6.1 Modelo de Persistencia y ARIMA.....	97
6.1.1 RMSE	97
6.1.2 MAE	97
6.2 Modelo LSTM	97
6.2.1 LSTM <i>Stateless</i>	98
6.2.2 LSTM <i>Stateful</i>	106
6.3 GRU.....	107
6.3.1 RMSE	108
6.3.2 MAE	108
6.4 MLP.....	109
6.4.1 RMSE	109
6.4.2 MAE	109
6.5 Visión general.....	110

Capítulo 7.	Conclusiones.....	114
Capítulo 8.	Referencias	116
Capítulo 9.	Anexos	127
9.1	Anexo I: Especificación Técnica de los Aerogeneradores	127
9.2	Anexo II: Lista completa de los sensores	130
9.3	Anexo III: Altura de los Niveles del Modelo ICON-D2	133
9.4	Anexo IV: Preparación de datos para redes LSTM y GRU	134
9.5	Anexo V: Alineación con los ODS	135

Índice de Ilustraciones

Ilustración 1: Metodología de trabajo.....	12
Ilustración 2: Distribución de potencia eólica instalada en Europa (Wind Europe, 2022)	29
Ilustración 3: Esquema de funcionamiento de un parque eólico marino (Iberdrola, 2017)	30
Ilustración 4: Componentes principales de un aerogenerador marino	31
Ilustración 5: Interior de la góndola de un aerogenerador (Mártil & Mártil, 2022)	32
Ilustración 6: Localización del Alpha Ventus y disposición de sus aerogeneradores	34
Ilustración 7: Disposición e identificación de los aerogeneradores	37
Ilustración 8: Identificación de los sensores y sus medidas	38
Ilustración 9: Ubicaciones de los sensores (Data - RAVE: Research at Alpha Ventus, s.f.).....	39
Ilustración 10: Ejemplo de k-NN (Jørgensen & Shaker, 2020).....	47
Ilustración 11: Ejemplo de SVM (Jørgensen & Shaker, 2020)	49
Ilustración 12: Ejemplo de la estructura típica de una red neuronal (Hanifi et al., 2020)	50
Ilustración 13: ejemplo procesamiento WDP (Zu & Song, 2018)	54
Ilustración 14: Metodología de desarrollo del proyecto	56
Ilustración 15: Interfaz de extracción de datos RAVE.....	57

Ilustración 16: Superficie cubierta por el modelo ICON-D2 (Reinert et al., 2023).	60
Ilustración 17: Interfaz Web Pamore	60
Ilustración 18: Interfaz Web Pamore (Cont.)	61
Ilustración 19: Interfaz Web Pamore (Cont.)	62
Ilustración 20: Serie temporal de potencia eólica.....	76
Ilustración 21: Resultado de la estimación del modelo ARIMA.....	80
Ilustración 22: Esquema de funcionamiento de una neurona tipo perceptron.....	83
Ilustración 23: Esquema de una red MLP (Wikipedia, 2023)	85
Ilustración 24: Redes Recurrentes vs. Redes Feed-Forward («Programming With TensorFlow», 2021)	86
Ilustración 25: Esquema de desenrollamiento de RNN (Goyal et al., 2018)	87
Ilustración 26: Celda LSTM (Varsamopoulos et al., 2018)	88
Ilustración 27: Capa LSTM desenrollada (Understanding LSTM Networks -- Colah's Blog, s. f.)	89
Ilustración 28: unidad LSTM sin desenrollar	90
Ilustración 29: Capas LSTM en cascada (Nicholas et al., 2018).....	91
Ilustración 30: Celda GRU (Mahjoub et al., 2022)	92
Ilustración 31: Curva de potencia Servion 5M.....	128
Ilustración 32: Curva de potencia Adwen AD-5116	129
Ilustración 33: Altura de los niveles del modelo ICON-D2 (Reinert et al., 2023).....	133
Ilustración 34: Preparación de datos para redes LSTM y GRU	134

Índice de Figuras

Figura 1: Matriz de Correlaciones	65
Figura 2: Diagrama Velocidad del Viento - Dirección y Potencia – Dirección	65
Figura 3: Desempeño del algoritmo XGBoost para la predicción de la velocidad del viento en la góndola.....	68
Figura 4: Valores predichos para los valores perdidos de la velocidad del viento en la góndola	69
Figura 5: Curva inicial potencia - velocidad del viento.....	71
Figura 6: Curva de potencia ideal (Luo et al., 2017).....	71

Figura 7: Tipos de atípicos	72
Figura 8: Atípicos detectados por Isolation Forest	74
Figura 9: Curva de potencia sin atípicos	74
Figura 10: Correlograma de la serie original	77
Figura 11: correlograma de la serie diferenciada	78
Figura 12: Coeficientes de la PACF de la serie diferenciada	79
Figura 13: Evolución temporal de los residuos	81

Índice de Tablas

Tabla 1: desempeño de los 3 mejores modelos para un horizonte de 3 horas	13
Tabla 2: Sesiones del mercado intradiario	26
Tabla 3: Resumen del parque Alpha Ventus	33
Tabla 4: Descripción de los sensores de los aerogeneradores	38
Tabla 5: Ventajas e inconvenientes de la red GRU	92
Tabla 6: Rango de Hiperparámetros	94
Tabla 7: RMSE modelos de persistencia y ARIMA	97
Tabla 8: MAE modelos de persistencia y ARIMA	97
Tabla 9: RMSE modelos LSTM stateless	102
Tabla 10: MAE modelos LSTM stateless	106
Tabla 11: RMSE modelos LSTM stateful	107
Tabla 12: MAE modelos LSTM stateful	107
Tabla 13: RMSE modelos GRU	108
Tabla 14: MAE modelos GRU	108
Tabla 15: RMSE modelos MLP	109
Tabla 16: MAE modelos MLP	110
Tabla 17: Mejores modelos según MAE a 1 hora	110
Tabla 18: modelos de media con un horizonte de 9 horas	111
Tabla 19: Mejores modelos de media con un horizonte de 3 horas	112
Tabla 20: Mejores modelos con un horizonte de 5 horas	113

Capítulo 1. INTRODUCCIÓN

El concepto de desarrollo sostenible y la lucha contra el cambio climático han provocado, durante el siglo XXI, un cambio de valores y de concepción en la relación del ser humano con el medio ambiente y los seres vivos que le rodean. Esto se ha traducido, por ejemplo: en maneras más sostenibles de hacer uso de los recursos naturales que el planeta nos ofrece, en cambios a la hora de consumir los productos optando por productos más respetuosos con el medio ambiente y en una promoción del reciclaje y de la gestión responsable de residuos.

Este cambio de pensamiento se ha visto impulsado también desde las principales instituciones globales. En 2015, la Asamblea General de las Naciones Unidas aprueba los denominados “Objetivos de Desarrollo Sostenible”, 17 objetivos que abogan por: “mejorar la sanidad y la educación, reducir las desigualdades y estimular el crecimiento económico, al tiempo que se lucha contra el cambio climático y se trabaja para preservar nuestros océanos y bosques” (*THE 17 GOALS / Sustainable Development*, s. f.). Estos objetivos sustituyeron a los objetivos del Milenio previamente promulgados en el año 2000. Además, los objetivos de desarrollo sostenible han impulsado la adopción de medidas adicionales como puede ser el denominado acuerdo verde europeo (2019) (*EU Green Deal*) o la taxonomía de la Unión Europea (2022).

Uno de los aspectos en los que este cambio se ha manifestado de una forma más evidente ha sido en el uso de fuentes de energía renovable frente a los combustibles fósiles. Se definen como fuentes de energía renovable aquellas fuentes en las que la energía derivada proviene de fuentes naturales que se reponen a un ritmo mayor del que se consumen (United Nations, s.f.). Entre estas fuentes destacan: la energía solar y la energía eólica.

De acuerdo con los datos de la *International Renewable Energy Agency* (IRENA), la capacidad instalada globalmente en el caso de energía solar fotovoltaica ha pasado de un valor de 0,809 GW en el año 2000 a 1.047 GW de potencia instalada en el año 2022 y en términos de generación eléctrica, ésta ha aumentado de 0,83 TWh a 831TWh entre los años 2000 y 2022. Por su parte, la energía eólica, en términos de potencia instalada ha pasado de 17 GW a 899 GW entre los años 2000 y 2022 y en términos de energía, de 31

TWh a 1589 TWh anuales. De acuerdo con estos datos la energía eólica se establece como la principal fuente de energía renovable usada en el mundo. Esta energía eólica se genera en los denominados parques eólicos que pueden ser terrestres, si los aerogeneradores se encuentran fijados sobre la masa continental o marinos, si los aerogeneradores están fijados en el fondo marítimo u oceánico. De acuerdo con la IRENA, solo el 7% de la potencia eólica instalada se corresponde con parques eólicos marinos. Foley et al. (2012) explican que los parques eólicos marinos son mucho más dependientes y sensibles a fenómenos meteorológicos y atmosféricos, lo que afecta a su desempeño. Este aspecto afecta gravemente a los costes asociados al mantenimiento del parque y a su longevidad. Por otro lado, tanto el coste del despliegue como el de mantenimiento de los parques eólicos marinos es en torno a 1,5 o 2 veces más caro que uno terrestre (Zheng et al., 2016). Por último, suponen un reto adicional frente a los terrestres a la hora de recopilar datos y volcar la energía producida a la red (Zheng et al., 2016).

Pese a esto, y debido a la escasez de lugares terrestres y al impacto de los parques en las poblaciones cercanas, se está impulsando fuertemente el desarrollo de parques eólicos marinos, ya que este tipo de parques también presentan algunas ventajas: los vientos marinos son más rápidos, consistentes y fiables (Kaplan, 2015), los aerogeneradores no necesitan poseer una gran altura como los terrestres ya que la variación de la velocidad del viento con la altura es menor (Zheng et al., 2016) y por último, debido a las dimensiones de los océanos y mares en nuestro planeta, el espacio es prácticamente ilimitado. Una de las iniciativas que impulsan la energía eólica marina ha sido promovida por la Comisión Europea, quien presentó en noviembre de 2020 la Estrategia Europea de Energía Renovable Marina en la que establecen un objetivo de expandir la potencia eólica marina instalada desde los 12 GW actuales a los 60 GW en 2030, que alcanzarían un valor de 300 GW en 2050.

Sin embargo, uno de los principales retos a los que se enfrenta la energía eólica en general, y en particular la energía eólica marina debido a las complicaciones adicionales a las que se enfrenta es la ausencia de certeza en la generación de energía debido a las fluctuaciones en la velocidad y la dirección del viento (Hanifi et al., 2020). Por esta razón, resulta vital el desarrollo de herramientas y métodos que permitan anticipar la generación de energía de manera precisa, asegurando el suministro, disminuyendo los costes del uso de contingencia y fuentes de energía alternativas y permitiendo a los operadores del sistema

planear con suficiente precisión y anterioridad la selección de tecnologías que posibiliten un uso eficiente y ecológico de la energía.

1.1 MOTIVACIÓN

Tal y como se ha puesto de manifiesto, el sector energético está experimentando una transformación sin precedentes, impulsada por la urgencia de abordar el cambio climático y la necesidad de transitar hacia sistemas energéticos más sostenibles y menos dependientes de combustibles fósiles. En este contexto, el mercado eléctrico juega un papel fundamental, actuando como el entorno donde se negocian y gestionan la generación y el consumo de electricidad. Este mercado se compone de distintas subastas, en las que cabe destacar el mercado diario y el mercado intradiario, cada uno con funciones específicas que aseguran el equilibrio y la eficiencia del sistema eléctrico.

El mercado diario, también conocido como el mercado *day-ahead*, es donde se define la planificación de la generación de electricidad para el día siguiente. En este mercado, las empresas generadoras presentan sus ofertas de venta, que incluyen la estimación de la energía que pueden producir y el precio de ésta, mientras que los consumidores indican sus necesidades de consumo. Las ofertas se ordenan por precio, y se seleccionan comenzando por las más económicas hasta cubrir la demanda prevista, estableciendo así un precio de equilibrio. Este mecanismo asegura una operación eficiente y efectiva desde el punto de vista del coste del sistema eléctrico, pero su eficacia depende en gran medida de la precisión en las predicciones de demanda y generación. Este proceso tiene lugar a las 12:00h del día anterior.

Por otro lado, el mercado intradiario permite a los participantes realizar ajustes a sus posiciones después del cierre del mercado diario a través de 6 subastas (en el caso de España y Portugal) celebradas en el propio día en cuestión, respondiendo a desviaciones imprevistas en la generación o el consumo. La Tabla 2 recoge las horas de apertura, cierre y casación a continuación, se presenta una tabla que resume el mercado intradiario en España, incluyendo tanto el mercado intradiario continuo como las sesiones intradiarias:

Tipo de Mercado	Inicio	Cierre	Cobertura Temporal
Intradiario Continuo	16:00 horas del día anterior	1 hora antes de cada hora de suministro	24 horas del día de suministro
Intradiario tradicional: <i>1ª Sesión</i>	21:00 horas del día anterior	21:45 horas del día anterior	00:00 a 24:00 del día de suministro
Intradiario tradicional: <i>2ª Sesión</i>	01:00 horas del día de suministro	01:45 horas del día de suministro	08:00 a 24:00 del día de suministro
Intradiario tradicional: <i>3ª Sesión</i>	04:00 horas del día de suministro	04:45 horas del día de suministro	11:00 a 24:00 del día de suministro
Intradiario tradicional: <i>4ª Sesión</i>	08:00 horas del día de suministro	08:45 horas del día de suministro	15:00 a 24:00 del día de suministro
Intradiario tradicional: <i>5ª Sesión</i>	12:00 horas del día de suministro	12:45 horas del día de suministro	19:00 a 24:00 del día de suministro
Intradiario tradicional: <i>6ª Sesión</i>	17:00 horas del día de suministro	17:45 horas del día de suministro	00:00 a 24:00 del día siguiente

Tabla 2: Sesiones del mercado intradiario

Este mercado es esencial para gestionar la intermitencia inherente a las fuentes de energía renovable, como la eólica y la solar, facilitando la integración de estas energías en el sistema y manteniendo la estabilidad y seguridad del suministro. En algunos mercados europeos, las sesiones intradiarias pueden cerrar hasta 30 minutos antes del despacho de la energía. Esto significa que los participantes del mercado tienen la capacidad de ajustar sus posiciones prácticamente hasta el último momento, reflejando cambios en las condiciones de generación, demanda o ambos.

Cabe destacar, que, a la fecha de realización de este trabajo, el mercado intradiario continuo tiene menor liquidez ya que el número de transacciones realizadas en este mercado es mucho más pequeño que en el mercado intradiario “tradicional” o en el

mercado diario. La elaboración de sistemas de predicción con gran precisión para horizontes temporales muy pequeños puede impulsar el uso de este mercado.

Por todo esto, la relevancia de este trabajo para las empresas generadoras de energía, especialmente aquellas involucradas en la producción eólica marina, se hace manifiesta en los siguientes aspectos:

1. **Optimización de Operaciones y Reducción de Costes:** Una predicción más precisa de la generación eólica permite a las empresas generadoras planificar sus operaciones de manera más eficiente, reduciendo la necesidad de activar fuentes de generación más costosas o de incurrir en penalizaciones por desviaciones en sus compromisos de generación.
2. **Mejora de la Participación en el Mercado:** Las empresas que pueden prever con mayor exactitud su capacidad de generación tienen una ventaja competitiva en el mercado, pudiendo optimizar sus ofertas en los mercados diario e intradiario para maximizar sus beneficios.
3. **Contribución a la Estabilidad de la Red:** Al mejorar la predicción de la generación eólica, las empresas ayudan a mantener el equilibrio entre oferta y demanda en el sistema eléctrico, un aspecto crítico para la seguridad y la estabilidad de la red.
4. **Fomento de la Transición Energética:** Al mejorar la integración de las energías renovables en el sistema eléctrico, las empresas generadoras contribuyen directamente a la transición hacia un modelo energético más sostenible.

En este sentido, el desarrollo de un modelo predictivo avanzado centrado en una predicción de la generación de energía eólica marina con un horizonte temporal de 1 a 9 horas para el mercado intradiario no solo representa un avance técnico y científico, sino que también ofrece beneficios económicos y operativos tangibles para las empresas generadoras, al tiempo que facilita una integración más armoniosa de las energías renovables en el mercado eléctrico.

Capítulo 2. LA ENERGÍA EÓLICA

En este capítulo se describirán conceptos básicos asociados a la energía eólica y su funcionamiento. Por un lado, se ofrecerá una descripción de los parques eólicos y su funcionamiento, así como de las turbinas. Por otro, se detallarán las características, ventajas e inconvenientes de los parques eólicos marinos.

2.1 PARQUES EÓLICOS

Los parques eólicos se definen como instalaciones que poseen un conjunto de turbinas eólicas agrupadas a una distancia relativamente cercana con el objetivo de la generación de energía eléctrica haciendo uso del viento.

Resulta evidente que el viento representa el factor clave para el correcto funcionamiento de un parque y del valor de su generación. El viento es principalmente consecuencia de tres fenómenos (Ahrens & Henson, 2015):

1. **Diferencias de temperatura debido a la radiación solar:** la radiación solar incide de manera diferente en las diversas superficies y zonas de la atmósfera. Como consecuencia, el aire que se encuentra por encima de estas superficies también se calienta a diferente velocidad.
2. **Diferencias de presión:** Cuando el aire caliente asciende, deja tras de sí una región de menor presión en la superficie. El aire frío, más denso, se precipita entonces para llenar la zona de baja presión, creando zonas de mayor presión. El movimiento del aire de las zonas de alta presión a las de baja presión es lo que percibimos como viento
3. **Efecto Coriolis:** La rotación de la Tierra desempeña un papel importante en la dirección y el patrón del viento. Este efecto, conocido como efecto Coriolis, hace que el viento se desvíe hacia la derecha en el hemisferio norte y hacia la izquierda en el hemisferio sur. Esta desviación es responsable de la rotación de los patrones de viento a gran escala, como los alisios, los vientos del oeste y los vientos de levante polares.

Los parques necesitan un flujo constante de viento de alta velocidad, aunque las turbinas poseen una velocidad límite de viento, que una vez alcanzada provoca la detención forzosa de la misma por motivos de seguridad. Debido a la importancia del viento, resulta crítico la elección de localización del parque que se elige con el objetivo de que se cumplan estas condiciones. De acuerdo con la localización podemos distinguir dos tipos de parque: terrestre (*onshore*) y marino (*offshore*). El primero, como su nombre indica, es construido sobre la masa continental, mientras que el segundo se construye en los mares u océanos. La Ilustración 2 muestra la distribución de la potencia eólica instalada en Europa entre los años 2013 y 2022. Es fácil apreciar que la generación eólica terrestre es la más extendida.




Ilustración 2: Distribución de potencia eólica instalada en Europa (Wind Europe, 2022)

Sin embargo, frente a estos datos y de acuerdo con Iberdrola (2017), los parques eólicos marinos tienen un gran potencial de desarrollo y resultarán cruciales en un futuro cercano. Kaplan (2015) y Zheng et al. (2016) analizan las ventajas de este tipo de parques entre las que destacan:

- Los vientos marinos son más rápidos, consistentes y fiables.
- Los aerogeneradores no necesitan poseer una gran altura como lo terrestres ya que la variación de la velocidad del viento con la altura es menor.
- El espacio disponible para su construcción es prácticamente ilimitado y no generan un pacto visual ni afectan a poblaciones cercanas.

- El transporte marítimo es más eficiente que el terrestre lo que facilita su construcción.

Frente a estas ventajas también encontramos grandes inconvenientes (Foley et al., 2012) (Zheng et al. 2016):

- Su desempeño es mucho más dependiente y sensible a fenómenos meteorológicos y atmosféricos.
- Poseen unos costes de mantenimiento más elevados que los de los parques terrestres y su vida útil es menor.

Tal y como se ha mencionado previamente, la localización del parque eólico marino resulta clave. Esta suele estar alejada de la costa, de cualquier ruta naval comercial, de zonas de importancia medioambiental o de instalaciones navales y militares. La Ilustración 3 muestra el funcionamiento de un parque eólico marino. A grandes rasgos, la energía mecánica del viento mueve las palas de la turbina, esta energía es transformada en energía eléctrica en el interior de la turbina. Tras esto, la energía eléctrica a una subestación que la convierte en corriente de alta tensión para facilitar su transporte.




Ilustración 3: Esquema de funcionamiento de un parque eólico marino (Iberdrola, 2017)

Por último, cabe destacar también, que existen parques eólicos marinos de cimentación fija y flotante. Los primeros alcanzan hasta los 60 metros de profundidad y son los más comunes. Los segundos permiten la construcción de los parques en aguas más profundas, aunque son más escasos.

2.2 LOS AEROGENERADORES

Los aerogeneradores son los integrantes de los parques eólicos, y los encargados de transformar la energía del viento en electricidad, usando la fuerza aerodinámica de las aspas o palas del rotor. La Ilustración 4 ofrece una visión de las partes principales de un aerogenerador:

- **Aspas del rotor:** se mueven debido a la fuerza del viento. Su longitud es variable en función del modelo del aerogenerador.
- **Góndola:** es la parte vital para la obtención de la energía eléctrica, contiene el generador y la caja de engranajes. Su funcionamiento se describe en detalle a continuación.
- **La torre:** estructura metálica encargada de soportar las aspas y la góndola. Su longitud es variable y suele incorporar distintos sensores para realizar tareas de mantenimiento.
- **Los cimientos:** estructura encargada de soportar el aerogenerador y las fuerzas que inciden sobre él. Pueden ser flotantes o fijos.




Ilustración 4: Componentes principales de un aerogenerador marino




Ilustración 5: Interior de la góndola de un aerogenerador (Mártil & Mártil, 2022)

La Ilustración 5 muestra el interior de una góndola de un aerogenerador tipo. Su funcionamiento es el siguiente:

1. El viento genera una fuerza de rotación que hace moverse a las aspas rotando el eje (denominado buje) del que parten. El rotor convierte la energía cinética del viento en energía mecánica (ENEL, s.f.).
2. El eje puede estar conectado directamente o a través de un multiplicador al generador. Si posee un multiplicador, este se encarga de transformar la rotación lenta de las palas en una más rápida.
3. El generador convierte la energía mecánica rotación del eje en energía eléctrica.

Cabe destacar que existen mecanismos para orientar la góndola correctamente en la dirección del viento haciendo uso del motor de orientación. También existen otros ajustes como el del ángulo de las palas para mejorar el rendimiento del aerogenerador.

Capítulo 3. EL PARQUE EÓLICO ALPHA VENTUS

En este capítulo se ofrecerá la información sobre el parque eólico marino Alpha Ventus. Este parque, que es el primer parque eólico marino en Alemania, será el objeto de estudio del trabajo. La Tabla 3 resume las principales características del parque:

<i>Entrada en operación</i>	2010
Producción total (2010-2019)	2,1 TWh
Nº de aerogeneradores	12
Desarrollador	DOTI
Operadores/Dueños	DOTI
Localización	54°00'40"N 6°36'28"E

Tabla 3: Resumen del parque Alpha Ventus

3.1 HISTORIA DEL PARQUE

La concepción y construcción del parque se remonta a 2002 momento en el Gobierno alemán promulga la estrategia federal para el uso de la energía eólica marina. Esta regulación posibilita que las empresas EWE, E.ON y Vattenfall constituyan una *joint venture* para la construcción del parque. Los planes para la construcción comienzan en 2006 gracias a la ayuda de la financiación gubernamental. Entre 2008 y 2009 se llevó a cabo la construcción en el mar de los aerogeneradores y la subestación con una duración de 32 semanas. El coste total de construcción fue de \$250 M frente a los \$190 M proyectados debido a ciertos retrasos.

Por otro lado, además de la presencia de los operadores y dueños del parque, la empresa Tennet Offshore GmbH es la encargada de supervisar la transmisión de la energía a la red y de la gestión de la subestación eléctrica.

Alpha Ventus fue el primer parque eólico marino alemán, y desde su concepción se le ha reconocido como un éxito y un parque de pruebas que permita desarrollar y mejorar la energía eólica marina en Alemania. El parque se sitúa a unos 65 km de la costa, en una profundidad de 30 m y hace uso de turbinas con un rotor de 132 m de diámetro.

3.2 LOS AEROGENERADORES DE ALPHA VENTUS

El parque posee dos tipos de aerogeneradores:

- 6 aerogeneradores Adwen AD-5116, con una potencia nominal de 5 MW cada uno sobre cimientos de trípode, fabricados por la empresa Adwen.
- 6 aerogeneradores Senvion 5M, también de una potencia nominal de 5 MW, pero con cimentación tipo *jacket*, fabricados por la empresa Senvion.

En el Anexo I: Especificación Técnica de los Aerogeneradores se ofrece información adicional sobre ambos tipos.

Ambas empresas, tanto Adwen, como Senvion, pertenecen actualmente a Siemens Gamesa Renewable Energy. La disposición de los aerogeneradores y la localización del parque se ofrecen en la Ilustración 6.

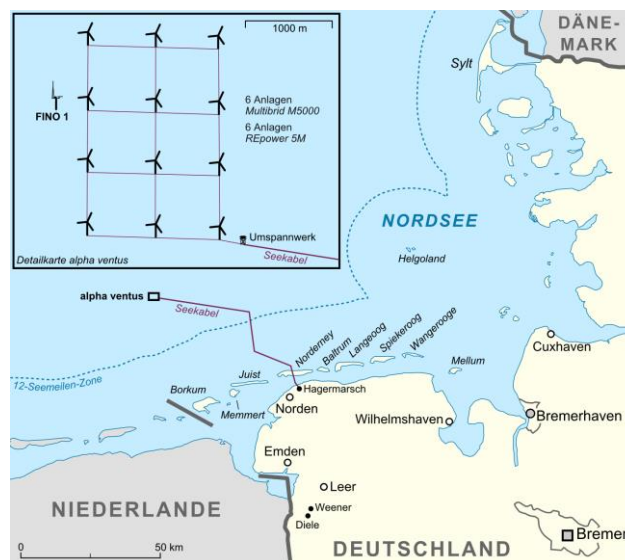


Ilustración 6: Localización del Alpha Ventus y disposición de sus aerogeneradores

Cabe destacar, la presencia de lo que en la Ilustración 6 se denomina “FINO 1”. El nombre representa una plataforma de observación meteorológica empleada en investigaciones y está situada en el interior de un parque eólico, siendo un componente integral del proyecto FINO, cuyas siglas corresponden a Forschungsplattformen in Nord-und Ostsee, que se traduce como "Plataformas de investigación en los mares del Norte y Báltico".

El proyecto FINO se originó con el propósito de evaluar los impactos de las infraestructuras marinas en el ecosistema marino. Específicamente, esta plataforma se erigió para analizar las condiciones ambientales que puedan favorecer la generación de energía eólica. La construcción de FINO1 fue encargada por el Ministerio Federal alemán de Medio Ambiente, Conservación de la Naturaleza, Construcción y Seguridad Nuclear (BMUB) en 2001 y comenzó su funcionamiento en otoño de 2003.

La plataforma obtiene una gran cantidad de información meteorológica haciendo uso de sus múltiples sensores. Esta resulta clave para entender el funcionamiento del parque debido a su proximidad a los aerogeneradores.

Los datos recogidos por la plataforma pueden ser accedidos a través de Rave.

3.3 EL PROYECTO RAVE

Tras la declaración la estrategia federal para el uso de la energía eólica en el mar, el Gobierno decidió respaldar la energía eólica marina mediante la creación de un campo de pruebas en alta mar, el parque eólico Alpha Ventus, que dio origen a RAVE. RAVE, un programa de investigación respaldado económicamente por el Gobierno alemán, y coordinado por el Instituto Fraunhofer de Sistemas de Energía Eólica (IWES), tiene como objetivo principal promover el progreso en el desarrollo del sector de la energía eólica. Desde su establecimiento en 2007, la financiación gubernamental otorgada a RAVE ha superado los 120 millones de euros (*About RAVE - RAVE: Research at Alpha Ventus*, s.f.).

El proyecto estableció cuatro metas fundamentales para impulsar la energía eólica marina en Alemania:

- Validar la eficacia en alta mar de las turbinas de 5 MW.
- Mejorar la tecnología del sistema.
- Investigar cuestiones pendientes relacionadas con el uso de la energía eólica marina.
- Expandir el potencial de investigación en el país.

Estas metas fueron alcanzadas hace tiempo: las turbinas de 5 MW constituyen ahora una parte significativa de los parques eólicos marinos, la tecnología del sistema ha experimentado avances decisivos con prototipos de hasta 12 MW, y se están desarrollando turbinas de hasta 15 MW. Más de 35 proyectos de investigación han abordado diversas cuestiones relacionadas con la energía eólica marina, consolidando un panorama de investigación amplio, diverso y reconocido internacionalmente en Alemania.

En la actualidad, el enfoque se dirige hacia nuevos objetivos, como la reducción de los costos de la energía eólica marina y la disminución del riesgo técnico. Esto plantea nuevas preguntas de investigación centradas en la optimización del rendimiento y la confiabilidad. Además, la abundante cantidad de datos recopilados por RAVE proporciona la base para abordar numerosas cuestiones científicas fundamentales.

En conjunto, se han implementado más de 1.200 canales de medición, siendo la Agencia Federal Marítima e Hidrográfica (BSH) la entidad encargada de gestionar de manera centralizada todas las mediciones de los proyectos.

Los principales colaboradores de RAVE incluyen las compañías responsables de la operación de Alpha Ventus y diversas instituciones de investigación. Los socios vinculados a las actividades del parque eólico son DOTI (consorcio operador con participación de EWE, RWE y Vattenfall), Siemens Gamesa Renewable Energy (fabricante de aerogeneradores, anteriormente Senvion y Adwen), y la Fundación Offshore Alemana, que detenta los derechos del parque.

El proyecto ofrece una base de datos con todas las mediciones realizadas por los sensores del parque, incluyendo la plataforma FINO1. Estos datos serán utilizados en el desarrollo del proyecto.

3.3.1 MEDICIONES Y SENSORES DEL PROYECTO RAVE

El parque eólico y sus aerogeneradores ofrecen numerosas mediciones de sus sensores a través de la base de datos de RAVE. Puesto que existen dos tipos de aerogeneradores, cada uno de un fabricante diferente, la distribución de los sensores difiere entre ellos. Por esta razón, resulta crucial seleccionar correctamente los aerogeneradores en función de los sensores y medidas disponibles. La Ilustración 7 muestra la disposición de los aerogeneradores.

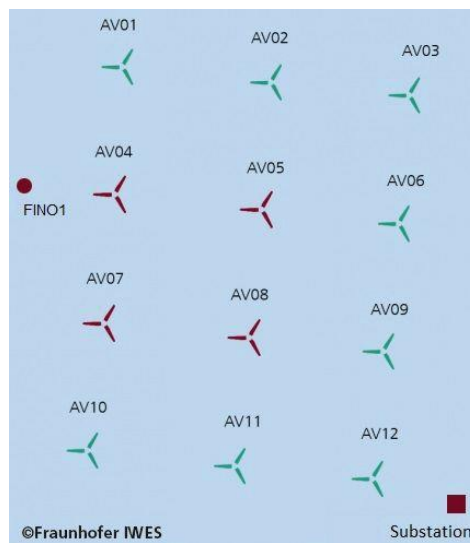


Ilustración 7: Disposición e identificación de los aerogeneradores

De entre estos aerogeneradores, AV04 y AV05 representan las opciones idóneas para el desarrollo del trabajo, ya que son los que cuentan con un mayor número de mediciones y se encuentran más cercanos a la plataforma FINO 1 (300 m y 1,3 Km respectivamente) ofreciendo medidas meteorológicas adicionales que debido a esta cercanía representan fielmente las condiciones experimentadas por los aerogeneradores.

Estos aerogeneradores tienen diferentes sensores y una disposición determinada de los mismos. Los sensores se distribuyen en 5 partes principales de los aerogeneradores:

- La torre.
- La góndola.
- Las palas o aspas.
- El eje del rotor.
- Los cimientos tipo *jacket*

Estos sensores se clasifican en seis tipos descritos en la Tabla 4:

<i>Tipo de Sensor</i>	<i>Descripción</i>	<i>Unidad</i>	<i>Letras Identificativas</i>
DMS	Galga extensiométrica	kNm	DT, D, DC, DR
FOS	Sensor de fibra óptica	λ (longitud de onda)	F
Ambiental	Temperatura, humedad, presión	°C, %, hPa	T, H, P
Inclinómetro	Inclinación	°	N
Control	Velocidad del rotor, del generador, ángulo de <i>pitch</i> , potencia activa, velocidad y dirección del viento ...	Rpm, °, kW, m/s ...	N/A: vienen descritos directamente
ICP	Acelerómetro	m/s^2	B

Tabla 4: Descripción de los sensores de los aerogeneradores

La identificación de los sensores se construye de la siguiente manera:




Ilustración 8: Identificación de los sensores y sus medidas

La ubicación del sensor se indica con una letra que representa el componente estructural del aerogenerador en la que se encuentra el sensor y dos números que identifican los puntos de unión dentro de dicho componente en los que se ubica el sensor. Las posibles letras son las siguientes:




Ilustración 9: Ubicaciones de los sensores (Data - RAVE: Research at Alpha Ventus, s.f.)

En el Anexo II: Lista completa de los sensores se ofrecen todos los sensores para ambos aerogeneradores y su posición. La información adicional sobre las características técnicas, de diseño y de fabricación de éstos se encuentra en el siguiente enlace: <https://rave-offshore.de/en/data.html>.

Tal y como se ha mencionado previamente, la plataforma FINO 1 posee sensores meteorológicos adicionales entre los que destacan los que miden la presión atmosférica, la humedad, la dirección del viento, la velocidad del viento, y, la temperatura del aire para alturas que varían entre 30 y 100 metros.

Las frecuencias de medición de los sensores varían entre 0,2 y 50 Hz. La base de datos de RAVE permite la obtención de las medidas agregadas cada diez minutos, ofreciendo el valor medio, el mínimo, el máximo y la desviación típica de la medición. Adicionalmente, incluye para cada medición dos campos denominados *flag* y *detailed_flag*. El primero solo tiene un dígito que puede ser: 0, si no ha ocurrido ningún evento relevante, 1, si ha ocurrido un evento relevante y 9, si las comprobaciones obligatorias en la medición no se han llevado a cabo. El campo *detailed_flag* está compuesto por 16 dígitos que representan las comprobaciones obligatorias de calidad de medida realizadas (aunque actualmente solo se usan los primeros 7 dígitos).

Capítulo 4. ESTADO DEL ARTE

4.1 LA GENERACIÓN DE ENERGÍA EÓLICA

Teóricamente la potencia eólica se describe con la siguiente ecuación (Lydia et al., 2014):

$$P = \frac{1}{2} \rho A v^3$$

En la que A se refiere al área de captura (m^2), v hace referencia a la velocidad del viento (m/s) y ρ representa la densidad del aire (kg/m^3) que depende de la temperatura y la presión del aire. Una opción sencilla para obtener una previsión de energía sería hacer uso de la curva de potencia del fabricante, en la que se representa la relación entre la potencia generada (eje de ordenadas) y la velocidad del viento (eje de abscisas). Sin embargo, la obtención de la predicción no es tan simple y no se basa únicamente en la predicción del viento ya que existen diversos aspectos como la degradación de las turbinas o los factores de control, por lo que la relación entre la potencia y la velocidad del viento es aleatoria y no lineal (Nazir et al., 2020),

4.2 TÉCNICAS DE PREDICCIÓN

La predicción de la generación eléctrica resulta vital para asegurar la resiliencia del sistema y el suministro para los consumidores. Tal y como se ha adelantado previamente, en el caso de la energía eólica, debido al carácter intermitente del viento, la predicción precisa de la energía puede reducir eficazmente el enorme impacto en la seguridad de funcionamiento de la red cuando se conecta a ella un suministro intermitente (Deng et al., 2020). Teniendo esto en cuenta, resulta crucial el desarrollo de herramientas que permitan anticipar de forma precisa la generación de energía eléctrica en los parques eólicos, ya sean terrestres o marinos.

Coincidiendo con la expansión de la energía eólica, se han desarrollado métodos para la predicción de ésta. Entre estos métodos, podemos diferenciar tres tipos: físicos,

estadísticos y de aprendizaje automático, y modelos híbridos. Por otro lado, es necesario distinguir diferentes horizontes temporales a la hora de realizar la predicción, ya que en cada horizonte un tipo de modelo o procedimiento será óptimo. De acuerdo con Hanifi et al. (2020) podemos establecer cuatro horizontes diferentes:

1. Muy corto plazo (0-30 minutos): utilizado para aplicar medidas regulatorias, operaciones en tiempo real y control de los aerogeneradores.
2. Corto plazo (30 min – 6 horas): para la planificación de la carga y la aplicación de medidas que la hagan más eficiente.
3. Medio plazo (6 horas – 1 día): utilizado para llevar a cabo operaciones que garanticen la seguridad del sistema eléctrico y para el trading energético.
4. Largo plazo (1 día – 1 mes): para la gestión de la operación, la planificación de los mantenimientos, los requisitos de reserva energética y el estudio de los costes óptimos de operación del sistema.

4.2.1 MÉTODOS FÍSICOS

Respecto a los modelos físicos, éstos hacen uso de bases de datos meteorológicas globales y requieren una gran cantidad de capacidad de computación para ser precisos, pues hacen de una descripción detallada de la atmósfera baja para estimar la energía eólica a través de la resolución de complicados modelos matemáticos que utilizan dicha descripción (Foley et al., 2012). En este grupo hace uso de los modelos de predicción numérica del tiempo (Numerical Weather Prediction). Estos modelos ofrecen una descripción detallada del estado de la atmósfera en un tiempo, altura y región determinada, pero son dependientes de las condiciones iniciales (Foley et al., 2012). A continuación, estas variables se usan en complejos modelos matemáticos para obtener la velocidad del viento y aplicar así la curva de potencia del fabricante para obtener la predicción de la potencia eólica. Teniendo esto en cuenta, Nielsen et al. (2007) demuestran que el uso combinado de múltiples predicciones NWP permite disminuir el error cometido debido a esta dependencia. Es importante destacar que el uso de esta técnica está destinado a regiones de un tamaño considerable, ya que emplearla para parques eólicos concretos posee un elevado coste computacional y temporal. La principal ventaja de estos modelos es que no necesitan hacer uso de datos históricos, aunque tal y como explica Nielsen et al. (2002), la mayoría de estos modelos incluye un módulo MOS o Model Output Statistics para

incorporar la información histórica y capturar los efectos no considerados por estos modelos físicos. Algunos de los ejemplos más relevantes de uso de modelos físicos son los siguientes:

- El modelo Prediktor, ideado en laboratorio danés Risø National Laboratory y del cual hace uso la propia operadora del mercado eléctrico danés. Hace uso de las predicciones meteorológicas obtenidas por el modelo atmosférico HIRLAM y de la curva de potencia de un parque determinado para obtener las predicciones de potencia (Landberg & Watson, 1994).
- La herramienta estadounidense EWind hace uso de un modelo de meso-escala que, con el fin de ajustar las predicciones a las condiciones específicas de una región, utilizan como punto de partida y referencia los pronósticos meteorológicos generados por un modelo de mayor alcance (Zack et al., 2000).
- LocalPred desarrollada en España por CENER y CIEMAT (Marti et al., 2001), se basa en un modelo de predicción de la velocidad del viento para obtener la potencia generada en terrenos de mayor complejidad. Añade pronósticos de corto plazo utilizando modelos de series temporales, y combina un detallado modelado físico del terreno mediante el modelo de meso-escala MM5 para mejorar las predicciones meteorológicas específicas para el área del parque eólico, convirtiéndolas en estimaciones de la producción de energía mediante una curva de potencia (Marti et al., 2001).

Este tipo de modelos debido a su complejidad y coste computacional, se ejecutan cada 6 o 12 horas y ofrecen predicciones con un horizonte de entre 48 y 72 horas. Sin embargo, el foco del trabajo se centrará en los modelos estadísticos y de aprendizaje cuyo horizonte de predicción es mucho menor.

4.2.2 MÉTODOS ESTADÍSTICOS Y DE APRENDIZAJE AUTOMÁTICO

El desarrollo de los métodos estadísticos y de aprendizaje automático ha permitido su uso para una gran variedad de ámbitos siendo la predicción de generación eléctrica en parques eólicos uno de ellos. Es importante destacar, que debido a la escasez de parques eólicos marinos, la mayoría de la literatura sobre el uso de estos modelos se centra en parques eólicos terrestres.

En este tipo de modelos una gran cantidad de datos es analizada y los procesos meteorológicos, a diferencia del enfoque de los modelos físicos, no están explícitamente descritos a través de ecuaciones, condiciones iniciales y condiciones de contorno. Estos modelos determinan la relación entre la generación eléctrica histórica y el tiempo variables meteorológicas típicamente obtenidas a través de NWP y la usan para predecir la generación futura (Foley et al., 2012). Estos son más sencillos de modelar ya que no involucran complejas operaciones matemáticas, como los modelos físicos, y son más baratos, sin embargo, su precisión decrece a medida que aumenta el horizonte de predicción (Foley et al., 2012).

En la literatura, estos modelos se comparan inicialmente con un el modelo de referencia denominado modelo de persistencia:

$$\hat{P}_{t+h|t} = P_t$$

Es fácil observar, que, bajo este modelo, el valor de la potencia eléctrica en un horizonte de tiempo h coincide con el valor actual. Este modelo funciona bien para horizontes temporales muy cortos en determinados parques eólicos regionales.

Por otro lado, de acuerdo con Negnevitsky et al. (2009) este tipo de modelos pueden ser clasificados en dos grandes grupos: métodos estadísticos basados en el análisis de series temporales y métodos de aprendizaje automático. Además, en este tipo de modelos el flujo de trabajo está claramente definido (Hanifi et al., 2022):

1. Selección de variables explicativas: tal y como explica Lin y Liu (2020), resulta vital elegir las variables adecuadas. En su estudio, recogen las cuatro variables más usadas en la literatura de investigación existente: velocidad del viento a la altura de la turbina, dirección del viento, temperatura atmosférica y humedad relativa. Frente a esto, Lin

y Liu (2020), proponen hacer uso del ángulo medio de inclinación de las palas, la orientación del molino, la temperatura ambiente, y la velocidad del viento a diferentes alturas, obteniendo que tanto la velocidad del viento a diferentes alturas como el ángulo medio de inclinación de las palas resulta vital para la precisión de la predicción en el caso de un molino eólico marino. Las principales características de estos modelos son la necesidad de una gran cantidad de datos y la capacidad deductiva de los modelos para obtener la relación entre las variables explicativas y la variable de interés a predecir. Sin embargo, en la literatura se siguen observado la velocidad, la dirección del viento y la temperatura como las variables principalmente usadas (Hanifi et al., 2020). Esta etapa es especialmente importante en el caso de los modelos de aprendizaje automático.

2. Preprocesado de datos: en esta etapa, se realiza lo que comúnmente se conoce como la limpieza de los datos, es decir, se revisa que no haya datos omitidos o que carezcan de sentido, se tratan los datos atípicos que puedan afectar negativamente a la predicción y se normalizan los datos.
 - 2.1. Atípicos obvios: en el caso de la predicción eólica, es común encontrarse lecturas negativas de potencia eólica, esto valores que son claramente atípicos, hacen referencia a los momentos en los que las palas de la turbina no se encontraban girando, pero el sistema de control de esta necesitaba energía (Shen et al., 2019) y resulta vital su eliminación. Hanifi et al. (2022) proponen tres alternativas para su tratamiento: 1) la eliminación sin sustitución de dichos valores, 2) el reemplazamiento por la media de potencia de los últimos cuatro meses y 3) el reemplazamiento por el valor positivo de potencia más cercano en el tiempo. Hanifi et al. (2023) también proponen su reemplazamiento por 0 para asegurar la integridad de la serie temporal.
 - 2.2. Anomalías y otros atípicos: estos son aquellos valores que, aunque representan mediciones correctas, se encuentran muy alejados de los valores típicos y que afectan de manera notable a la precisión de los modelos. En el caso de la predicción eólica, estos ocurren debido diversas causas: fallos en la transmisión, procesamiento y gestión de los datos, fenómenos electromagnéticos, daños en las palas o existencia de hielo o polvo ... (Hanifi et al., 2022). Se han propuesto diferentes métodos en la literatura y su uso depende de las características de los

- datos. Destaca el uso del conocido Isolation Forest como uno de los mejores algoritmos en el caso de la predicción eólica (Lin & Liu, 2020).
- 2.3. Recuperación y tratamiento de valores perdidos: se completan aquellos valores que se hayan podido perder en el proceso de obtención de los datos.
 - 2.4. Remuestreo: en el caso de la predicción eólica es común llevar a cabo un remuestreo pues las medidas de la velocidad del viento de los anemómetros no se corresponden exactamente con el flujo de viento que alcanza a las palas de las turbinas reduciendo la correlación entre la velocidad del viento y la potencia eólica (Kisvari et al., 2021). Debido a que dichos datos son típicamente obtenidos por un SCADA que suele permitir frecuencias de muestreo de hasta 1 Hz, se puede obtener una media de diferentes conjuntos de datos para solventar dicho obstáculo y transformarlos en conjuntos de datos que se corresponden con medidas cada 10 minutos atendiendo así a la literatura, y el estándar IEC 61400-12-1 para las turbinas se recomienda obtener datos cada 10 min (Hanifi et al., 2020).
 - 2.5. Normalización: se lleva a cabo para evitar un peso exceso de peso de determinadas variables debido a su orden de magnitud (Lin & Liu, 2020).
3. Entrenamiento (training): en esta fase como su propio nombre indica se utiliza una porción significativa de los datos para entrenar el modelo. Se corresponde con la fase en la que el modelo “aprende” la relación entre la o las variables de entrada y la variable de salida.
 4. Prueba (test): se comprueba la validez predictiva del modelo con el conjunto de datos reservado y no usado durante el entrenamiento a través de distintos estadísticos y medidas de error. Algunas de estas medidas de validez predictivas son: MAPE, MAE, RMSE, NMRSE La expresión de las más relevantes se desarrollará posteriormente en el trabajo.

Métodos estadísticos basados en el análisis de series temporales

Estos métodos se cimentan en la idea de que las mejores predicciones se alcanzan haciendo uso del valor histórico de la variable de interés y son típicamente usados para horizontes temporales muy cortos: de minutos u horas ya que son modelos capaces de identificar los aspectos aleatorios ocultos de la variable de interés (Hanifi et al., 2023). La mayoría de los métodos se basan en el uso de la regresión lineal para predecir el valor

de la velocidad del viento o la potencia eólica directamente y en los modelos propuestos por Box y Jenkins (1972):

$$X_t = \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t - \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$

Donde φ_i representa el parámetro autorregresivo, θ_j el parámetro de la media móvil, ε_t representa ruido blanco, p y q representan el orden autorregresivo y de la media móvil respectivamente y X_t el valor, en este caso de potencia eólica en el instante t .

Sin embargo, tal y como expone Chai et al. (2015) no es la técnica más adecuada debido al contexto de altas fluctuaciones que se observan en los parques eólicos y a la no estacionariedad de la mayoría de estas series temporales.

Pese a esto, Torres et al. (2005) demuestra que el uso de modelos ARMA para predecir la velocidad media horaria del viento permite reducir un 20% el error frente al modelo de persistencia. Erdem y Shi (2011) proponen cuatro enfoques basados en los modelos ARMA para predecir la velocidad y dirección del viento y así predecir la potencia usando la curva de potencia. En el primer método, se descompone la velocidad del viento en componentes lateral y longitudinal, cada una representada por un modelo ARMA. Luego, se combinan los resultados de estos modelos para obtener las predicciones de dirección y velocidad del viento. En el segundo enfoque, se utilizan dos modelos ARMA separados: uno para predecir la velocidad del viento y otro vinculado para predecir la dirección del viento. El tercer enfoque emplea modelos de auto regresión vectorial (VAR), es decir, la versión multivariante de los modelos ARMA, para predecir todos los atributos del viento simultáneamente. Por último, el cuarto método utiliza una versión restringida del enfoque VAR para lograr la misma predicción. Con su estudio, estos autores alcanzan dos conclusiones: 1) el modelo que distingue las componentes del viento predice mejor la dirección del viento que el modelo ARMA tradicional, pero lo contrario ocurre con la velocidad de este, y, 2) el enfoque VAR posee una mejor precisión en el caso de la dirección del viento y un desempeño similar en la predicción de la velocidad. Lydia et al. (2016) realiza una comparación entre el modelo ARIMA tradicional y el equivalente no lineal para la predicción de la velocidad del viento con un horizonte de 10 minutos. Los resultados mostraron un mejor desempeño en la predicción del equivalente no lineal. Pese

a estos resultados, Neshat et al. (2021) concluye que el desempeño de este tipo de modelos es demasiado dependiente de las propiedades de no linealidad y no estacionariedad de la variable de interés, ya sea la velocidad del viento o la potencia eólica. La principal ventaja de estos modelos se encuentra en su simpleza y facilidad de implementación.

Métodos de aprendizaje automático

En este caso, la variedad de modelos y técnicas es mucho mayor que en el caso anterior. Este tipo de modelos hace uso de diferentes variables explicativas derivadas de modelos meteorológicos para obtener el valor de la predicción (Foley et al., 2012). De acuerdo con la revisión llevada a cabo por Jørgensen y Shaker (2020), existen tres métodos principales caracterizados por su uso extendido en la literatura para la predicción de potencia eólica:

- 1) **k-vecinos más cercanos:** este algoritmo se basa en el concepto de que valores similares en una serie temporal tienden a estar más cercanos entre sí. La k hace referencia al número de vecinos que se tienen en cuenta para comparar el valor actual de la serie y obtener la predicción. El procedimiento es simple:
 - a) Hallar los k instantes temporales más cercanos, en función de una métrica de distancia dada, al instante más reciente. Es decir, instantes en el que la distancia entre los valores de las variables explicativas en ese momento y el momento actual es mínima.
 - b) Calcular la media ponderada o aritmética de los vecinos o instantes seleccionados para obtener la predicción del valor siguiente.




Ilustración 10: Ejemplo de k-NN (Jørgensen & Shaker, 2020)

Yeşilbudak et al. (2017) hace uso de este algoritmo para la predicción de la potencia eólica combinando diferentes métricas de distancia, número de vecinos y variables explicativas a considerar, haciendo uso de dos, tres y cuatro variables en cada caso. En este estudio concluyen que el error mínimo de predicción se alcanza combinando las variables: velocidad del viento, dirección del viento, presión atmosférica y temperatura del aire a 60 metros de altura, con un número bajo de vecinos ($k=4$) y haciendo uso de la distancia de Manhattan alcanzando un MAPE del 1,158% y un MAE 15,839 kW para predicciones con un horizonte temporal de 10 minutos. Además, este método supera al de persistencia en todos los casos. Renani et al. (2016) estudia el caso de un parque eólico en Irán y demuestra que este algoritmo, pese a tener un tiempo de entrenamiento y prueba muy bajo, es incapaz de incorporar la naturaleza cambiante de las temperaturas y que por lo tanto su error se incrementa a medida que las estaciones cambian. Demolli et al. (2019) propone el uso de este algoritmo únicamente incluyendo el valor medio de la velocidad del viento diaria para predicciones a largo plazo, alcanzando un MAE de 42,47 kW. Su estudio también revela que este algoritmo no funciona de forma precisa si las velocidades del viento son altas.

- 2) **Máquina de vectores de soporte (SVM):** tiene como objetivo encontrar hiperplanos en un espacio N-dimensional, en el que N se corresponde con el número de características o variables. El algoritmo maximiza la distancia entre el hiperplano y los datos para la clasificación de estos (Lantz, 2013). Fue inicialmente concebido para la clasificación hasta que Drucker et al. (1996) publicaron su artículo en el que explicaban su uso para la regresión.




Ilustración 11: Ejemplo de SVM (Jørgensen & Shaker, 2020)

Zeng y Qiao (2011) comparan el desempeño de este algoritmo frente a redes neuronales con funciones de base radial y demuestran que, para horizontes temporales de muy corto plazo, una hora y dos horas, la máquina de vectores de soporte posee un menor MAE y MAPE que la red neuronal. Además, en este artículo se explica también que la precisión del algoritmo se degrada conforme el horizonte temporal aumenta. Jian et al (2017) demuestra que, en el caso de velocidades de viento elevadas, al igual que el k-nn, la precisión de la predicción se degrada. Frente a la precisión alcanzada en estos estudios previos, Heinermann y Krämer (2016) encuentran una serie de desventajas en el uso de este algoritmo, entre las que destacan: el gran número de parámetros a definir que afectan profundamente a la calidad de la predicción y el elevado coste computacional representado por el gran tiempo de entrenamiento necesario frente a otros modelos.

- 3) **Redes Neuronales:** inspiradas en el sistema nervioso del ser humano, se basan en una red de neuronas en las que unas a otras se transfieren la información tras procesarla. Poseen variedad de estructuras, con diferentes capas de entrada, capas ocultas y capas de salida en las que existen un número determinado de nodos (Lantz, 2013). Tanto Jørgensen y Shaker (2020) como Nazir et al. (2020), coinciden en que el uso de redes neuronales se ha incrementado enormemente en los últimos años y que actualmente representa el método más utilizado para la predicción de generación eólica debido a su capacidad para identificar relaciones no lineales y para evitar la complejidad de la estructura mecánica de las turbinas.




Ilustración 12: Ejemplo de la estructura típica de una red neuronal (Hanifi et al., 2020)

Una de las redes más sencillas utilizadas en la literatura es el perceptrón multicapa (MLP), un tipo de red totalmente conectada conocida como feed-forward, en el que la información se transmite en un único sentido y no hay bucles (Popescu et al., 2009). Singh et al. (2007) desarrollan un MLP haciendo uso la velocidad y la dirección del viento y la densidad del aire para la predicción de la potencia eólica en un horizonte de 10 minutos, obteniendo una diferencia porcentual entre los valores medidos y predichos de entre 0,302 y 1,082%. Mabel y Fernandez (2008) analizan la precisión de esta técnica estudiando de un conjunto de parque eólicos indios aplicando una estructura de tres neuronas de entrada, una capa oculta de cuatro neuronas y una capa de salida con una neurona con un horizonte de predicción de un mes. Desarrollan este modelo incluyendo las variables: velocidad del viento, humedad relativa y la hora de generación para obtener una predicción de generación eléctrica. Este modelo alcanza un MSE de 0,0065 y un MAE de 0,0586. De Giorgi et al. (2011) alcanzan un error absoluto normalizado de entre 0.1098–0.1550 en la potencia eólica haciendo uso de la velocidad del viento, la presión, la temperatura y la humedad relativa para horizontes temporales de 1, 3, 6, 12 y 24 horas. Zhao et al. (2012) proponen una estructura 6-13-1, en la que las variables de entrada son: la velocidad del viento, el seno y el coseno de la dirección del viento, la temperatura, la humedad y la presión, que atraviesan una capa oculta de trece neuronas y ofrecen la predicción para la potencia eólica del día siguiente en un parque eólico chino alcanzando un valor medio de 16,47% para la predicción mensual. Por último, Bilal et al. (2018) proponen una red MLP con tres capas de 5,7 y 8 neuronas para la predicción de potencia eólica de

distintos parques en Senegal. Como variables de entrada utilizan principalmente la velocidad del viento, aunque incluyen diversas pruebas con otras variables como la dirección de este, la temperatura o la humedad.

Otra de las redes que destaca es la red LSTM (long short-term memory). Es un tipo de red neuronal recurrente (un tipo de red que a diferencia de la feed-forward, permite que la información fluya hacia atrás y hacia adelante a través de la red), que puede aprender las dependencias a corto y largo plazo de las series temporales gracias a su celda de memoria o capas ocultas donde se encuentran las neuronas (Schmidhuber & Hochreiter, 1997). Esta red cuenta con tres compuertas: la de entrada (input), la de salida (output) y la de olvido (forget) que permiten añadir o eliminar información al estado de la celda. Esta característica permite precisamente que la red modele mejor las dependencias a largo plazo que una red recurrente y además es más robusta frente al problema del desvanecimiento del gradiente por el que este disminuirá gradualmente hasta alcanzar valores muy bajos, lo que impedirá el cambio de valor de los pesos e imposibilitará el entrenamiento adecuado de la red (Salehinejad et al., 2017)

Zhang et al. (2019) hacen uso de esta red para realizar predicciones de potencia eólica para un parque eólico chino con 123 turbinas usando como variable de entrada la velocidad del viento obtenida a través de NWP. Las predicciones se realizaron con un salto temporal de 15 min, que coincide con el periodo de muestreo de los datos, para un horizonte temporal de 2 días, es decir, 192 predicciones. Los resultados ofrecen una mejora del RMSE de hasta el 4,96% frente a otros métodos clásicos como una red ELMAN o una de creencia profunda. Yin y Zhao (2019) comparan el desempeño de 5 algoritmos diferentes: una red neuronal de regresión general (GRNN), random forest, SVM, potenciación del gradiente o gradient boosting y una red LSTM, para la predicción de la potencia eólica, con un horizonte temporal de muy corto plazo, de una turbina marina simulada con librería de simulación FLORIS (FLORIS, s. f.), especializada en parques eólicos marinos. Los autores utilizan la velocidad y la dirección del viento como variables principales, realizando simulaciones para velocidades de 8,16 y 28 m/s para una dirección del viento de 270° y de 16 m/s para direcciones de 180°, 225° y 315°. La red LSTM resultó ser la más precisa frente al resto de algoritmos en todos los casos, alcanzando un MAPE y un RMSE mínimo de 0,032% y 0,0018 respectivamente en el caso en el que la dirección del viento fue de

225°. Hanifi et al. (2022) utiliza esta red para predecir la potencia eólica de una turbina eólica marina escocesa. Utiliza datos correspondientes a 5 meses provenientes de un SCADA con una frecuencia de muestreo de 1 Hz, considerando únicamente los valores de potencia eólica como variable de salida y velocidad del viento como variable de entrada. Compara el desempeño de la red para predicciones con un horizonte temporal de 10 min frente a un modelo ARIMA, y el modelo de persistencia haciendo uso también de distintos algoritmos de detección de atípicos, y obtiene una mejora en la predicción en términos de RMSE al usar la red LSTM del 3,93% y 5,1% respectivamente. También cabe destacar el uso de redes Bi-LSTM, en que permiten realizar el entrenamiento de la red en ambos sentidos aumentando el desempeño de la red en el aprendizaje (Schuster & Paliwal, 1997). Ko et al. (2021) hacen uso de esta red para la predicción de la potencia eólica con un horizonte temporal de 1 hora haciendo uso de los datos de ERCOT (Generation, s. f.) entre los años 2016 y 2018. Esta contiene la potencia eólica producida por todos los parques de Texas. Los autores utilizan esta red con 11 capas que alcanza un MSE de 0,0011 y un MAPE del 10%, frente a un modelo ARIMA, SVM y de persistencia que alcanza un MSE 0,009,0,0015 0,02 y un MAPE de 34,8%, 29,3% y 11,7% respectivamente.

Por último, cabe destacar la red GRU (gated recurrent unit), una red más compacta y simple que la red LSTM, ya que cuenta únicamente con dos compuertas, de reinicio, que controla la cantidad de información histórica que afecta al estado actual y de actualización que controla la proporción entre la información histórica y la información nueva que entra a la red y afecta al estado actual (Cho et al., 2014). Este mecanismo permite obtener las dependencias tanto a corto como a largo plazo de la serie temporal. Fu et al. (2018) hacen uso de esta red para la predicción a corto plazo de la potencia eólica para una turbina situada en el norte de china. Su trabajo combina la información histórica (velocidad y dirección del viento, así como la temperatura del aire y la presión) y la información obtenida a través de NWP (únicamente velocidad del viento). En el caso de la información obtenida a través de NWP para las predicciones de velocidad del viento, los autores proponen una red GRU para la corrección de errores a la que entrenan con las predicciones NWP históricas y la potencia eólica generada. La red se entrena con las predicciones del viento a 30 y 100 m de distintas localizaciones cercanas, posee dos capas ocultas y una capa de salida. Tras esta corrección propone una nueva red GRU entrenada con la salida de la red

que corrige los errores de las predicciones NWP y el resto de las variables históricas, con tres capas ocultas y una capa de salida. El desempeño de esta última red lo compara con una red LSTM (con parámetros similares), con una SVM y un modelo ARIMA. Como resultado, los autores observan que el efecto de la corrección de las predicciones NWP es considerable y que ambas redes tienen un desempeño claramente superior que el resto de los modelos. Sin embargo, entre ellas no hay grandes diferencias en términos de precisión, aunque el coste computacional de la red GRU es menor. Por otro lado, Kisvari et al. (2021) comparan el desempeño de esta red frente a una red LSTM para una turbina eólica marina escocesa. Tras un proceso de selección de variables, deciden entrenar las redes con: velocidad del viento a la altura de la turbina, temperatura del generador y de la caja de cambios de la turbina, el ángulo de inclinación, la velocidad del rotor y la orientación de las palas. La red GRU obtuvo una mayor precisión en la predicción y un menor tiempo de entrenamiento.

Es importante destacar, que en el caso de las redes neuronales la elección de sus hiperparámetros, aquellos parámetros que no aprenden durante el entrenamiento, resulta crucial para la obtención de una predicción de calidad. La identificación y la elección de estos, así como la definición matemática de los tres ejemplos de redes seleccionados se describirá en un mayor detalle en los capítulos posteriores.

4.3 MÉTODOS HÍBRIDOS

Este tipo de métodos hacen un uso combinado de dos o más métodos mencionados anteriormente. En el caso de los métodos físicos, como ya se ha puntualizado, la mayoría de ellos poseen un módulo de datos históricos que utilizan para refinar las predicciones. Sin embargo, en la literatura destacan aquellos modelos que combinan algoritmos de aprendizaje automático con cualquier otro método, en especial aquellos modelos combinados con técnicas de procesamiento digital de señales. Tal y como explica Hanifi et al. (2023), existe un patrón en el uso de estos métodos que consiste en la descomposición de la serie original no estacionaria en subseries estacionarias, cada una de ellas utilizadas para la predicción, A continuación, estas predicciones se suman para obtener una predicción de mayor precisión. Zu y Song (2018) hacen uso de la denominada técnica wavelet packet decomposition (WPD), técnica basada en la descomposición

ondicular, que descompone la serie original en subseries de las que va extrayendo la información relativa a baja frecuencia. La técnica usada permite descomponer las series en subseries de alta y baja frecuencia permitiendo elegir la banda de frecuencia deseada sobre la que realizar un análisis determinado.




Ilustración 13: ejemplo procesamiento WDP (Zu & Song, 2018)

Los autores utilizan y construyen diferentes redes GRU para cada banda de frecuencia de interés con el objeto de predecir la potencia eólica generada por un parque belga con un horizonte temporal de una hora. La descomposición WPD utilizada es de tres niveles. Los resultados demuestran que el desempeño de esta técnica es mayor que el uso de una red GRU tradicional. Su et al. (2019) utilizan esta misma técnica, para obtener las componentes de alta y baja frecuencia de la serie temporal de la velocidad del viento. Los autores obtienen cuatro subseries de baja frecuencia y cuatro de alta frecuencia. Las de baja frecuencia son directamente utilizadas para entrenar una red LSTM, las de alta frecuencia son sometidas a una descomposición adicional debido a sus grandes fluctuaciones, la denominada ensemble empirical noise decomposition (EEDM), diseñada para extraer componentes significativos de datos no lineales con ruido. EEMD funciona generando múltiples realizaciones ruidosas de la señal original y, a continuación, promediando las FMI (funciones modales intrínsecas) resultantes para obtener una descomposición más estable y robusta.

En EEMD, cada realización ruidosa se crea añadiendo ruido blanco aleatorio a la señal original. Al repetir este proceso varias veces, el algoritmo puede separar las componentes oscilatorias subyacentes del ruido añadido, produciendo un conjunto de FMI que representan mejor la dinámica intrínseca de la señal (Wu & Huang, 2009).

Tras esta descomposición, Su et al. (2019) incorporan ya esta información para el entrenamiento de la red, incluyendo además la velocidad del rotor como variable con la

que se entrena la red que posee dos capas ocultas. Los resultados demuestran que la precisión de la predicción es mayor haciendo uso de las descomposiciones descritas frente al entrenamiento de la red con la variable velocidad del viento sin descomponer. Por último, cabe destacar el trabajo realizado por Hanifi et al. (2023) en el que los autores hacen uso de la técnica WPD para la predicción de la potencia eólica en una turbina marina escocesa con un horizonte de predicción de 10 minutos. Los autores que hacen uso de esta técnica dividen la serie temporal de potencia eólica y velocidad del viento en componentes de baja y alta frecuencia, obteniendo una y cinco componentes respectivamente. La componente de baja frecuencia se utiliza para el entrenamiento de una red LSTM, por otro lado, cada una de las componentes de alta frecuencia son utilizadas para el entrenamiento de redes convolucionales. Los resultados de la predicción son comparados con otros ocho algoritmos: random forest, una red LSTM, una red feed-forward, una red convolucional entre otros. El diseño propuesto obtiene los menores valores de MSE, RMSE y MAE.

Capítulo 5. METODOLOGÍA

La Ilustración 14 ofrece un resumen de la metodología empleada para desarrollar los modelos y algoritmos y alcanzar los resultados deseados.

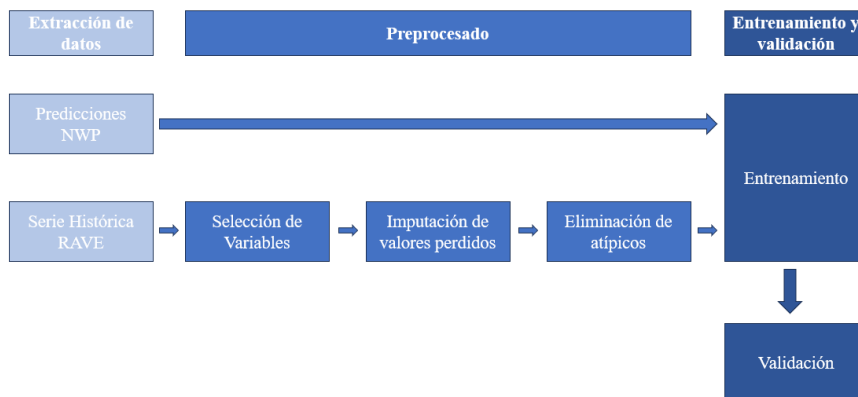


Ilustración 14: Metodología de desarrollo del proyecto

5.1 EXTRACCIÓN DE DATOS

Tal y como se observa en la ilustración anterior, se han utilizado dos fuentes para la obtención de los datos usados para el entrenamiento y la validación de los modelos.

5.1.1 SERIE HISTÓRICA RAVE

Los datos históricos de los distintos aerogeneradores del parque Alpha Ventus, y sus sensores se encuentran en el siguiente portal: <https://login.bsh.de/fachverfahren/>. Esta página web pertenece a la Agencia Federal Marítima e Hidrográfica (BSH). Una vez registrados, y aceptado el compromiso del uso de los datos para fines educativos, se accede a la página ofrecida en la siguiente ilustración:

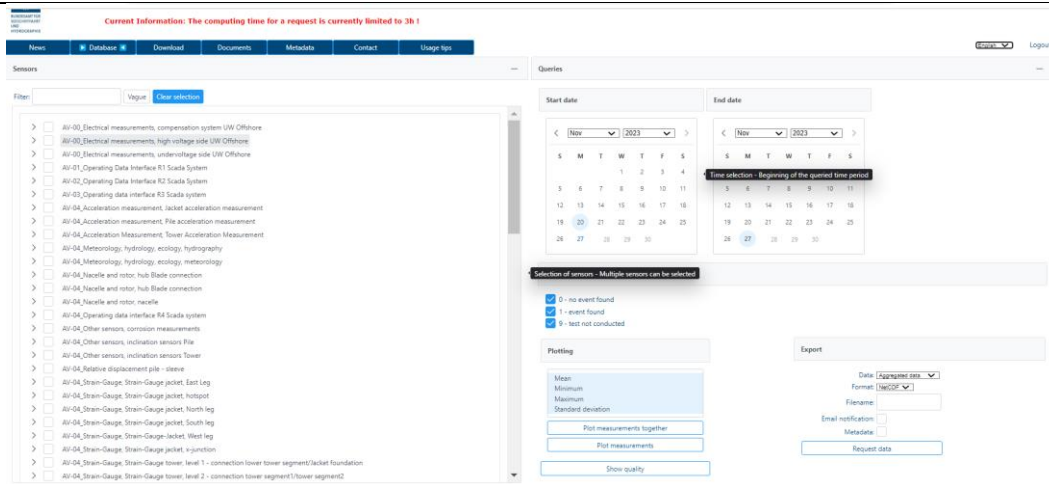


Ilustración 15: Interfaz de extracción de datos RAVE

En la ilustración, está representada la interfaz web para la descarga de los datos de los distintos aerogeneradores y sensores del parque. A la izquierda de la imagen, se encuentra una lista desplegable que permite seleccionar los aerogeneradores y sensores deseados. A la derecha se ofrecen dos calendarios interactivos para determinar la fecha de inicio y fin de las medidas deseadas. Justo debajo, se encuentran tres casillas que permiten establecer un filtro de calidad sobre las medidas realizadas: si solo se marca la casilla del 0, únicamente se incluirán medidas en las que no se ha detectado ningún evento anormal en los sensores, si adicionalmente se marca la casilla 1, se incluyen medias en las que se han detectado estos eventos. Por último, si se marca la casilla 9, se incluirán también medidas en las que las pruebas de calidad no han sido llevadas a cabo.

Finalmente, debajo de estas opciones, se observan dos columnas, por un lado, la que se encuentra más a la izquierda está destinada a la representación gráfica de las variables deseadas en la interfaz web. Por otro lado, la que se encuentra más a la derecha, permite la exportación de los datos ofreciendo las siguientes opciones:

1. Datos agregados o sin agregar: esta opción permite obtener datos de mediciones realizadas cada 10 minutos (agregados) o mediciones realizadas según el periodo mínimo de muestreo de cada sensor (sin agregar). En el caso del trabajo realizado, la opción agregada ha sido la seleccionada.
2. Formato: permite la selección del formato de exportación de los datos, ofreciendo NetCDF, un formato típico para el tratamiento de variables y series climáticas o

CSV. En el caso del trabajo realizado, en esta opción se ha seleccionado NetCDF por la facilidad para la importación y la limpieza de los datos.

3. Nombre del archivo: permite establecer el nombre del archivo en el que se incluirán los datos.
4. Opciones adicionales: permiten seleccionar si recibir una notificación por email una vez los datos estén disponibles para su descarga y si incluir metadatos en el archivo.

Una vez configuradas las opciones y solicitados los datos, pasará un periodo determinado de tiempo, en función del tamaño de los datos seleccionados, hasta que el archivo esté disponible en la pestaña *download*. Adicionalmente, el portal consta de otras pestañas:

- Pestaña *News*: pestaña en la que se incluyen las últimas noticias y actualizaciones relacionadas con la adquisición y subida al portal de los datos.
- Pestaña *Documents*: pestaña en la que se encuentran diferentes guías para el usuario: los periodos de medidas disponibles para cada sensor, una guía de descarga de los datos y una guía de ubicación y explicación de los distintos sensores.
- Pestaña *Metadata*: ofrece una interfaz muy similar a la de la Ilustración 15, pero únicamente para solicitar metadatos de los sensores.
- Pestaña *Contact*: pestaña destinada a ofrecer la información de contacto del proveedor de los datos en caso de que se produzca algún error en el portal o el usuario posea alguna duda sobre su uso.
- Pestaña *Usage Tips*: pestaña que ofrece consejos adicionales para la descarga de los datos.

Es importante destacar, que, puesto que se ha seleccionado la versión agregada de los datos, el archivo constará de las medidas de los sensores seleccionados en intervalos de diez minutos, incluyendo la media, el mínimo, el máximo y la desviación típica para cada medida durante dicho intervalo, así como, una columna de *flags* que determinan la calidad de la medida, haciendo uso de la clasificación descrita previamente. En el caso del trabajo realizado, se trabaja únicamente con las medias de las medidas.

5.1.2 PREDICCIONES NWP

Como ya se ha anticipado, los modelos desarrollados no se nutrirán únicamente de la serie histórica de las medidas realizadas por los sensores del parque eólico marino, si no que, de cara a un uso destinado a la predicción, los modelos se entrenarán también con la serie histórica de predicciones meteorológicas obtenidas haciendo uso de los procedimientos NWP.

Estas predicciones se obtendrán de la base de datos ofrecida por el servicio meteorológico alemán (DWD o deutscher wetterdienst wetter) llamada Pamore. Esta base de datos permite acceder a las predicciones de distintas variables meteorológicas de los últimos 15 meses calculadas haciendo uso de distintos modelos matemáticos. Estos modelos dividen la tierra en distintos sectores de una superficie determinada, haciendo uso de lo que denominan rejilla, y modelan para cada división el estado de la atmósfera a través de ecuaciones físicas. Entre los distintos modelos que ofrece Pamore, se ha seleccionado el modelo ICON-D2.

El modelo resulta idóneo ya que es regional, cubriendo todo el territorio alemán, Benelux, Suiza, Austria y partes de los demás países vecinos con una resolución horizontal de 2,2 km (la más precisa de los modelos ofrecidos) (Reinert et al., 2023). En la vertical, el modelo define 65 niveles atmosféricos cuya altura viene especificada en el Anexo III:

Altura de los Niveles del Modelo ICON-D2 Parte I9.3. La Ilustración 16 muestra la superficie que cubre el modelo:

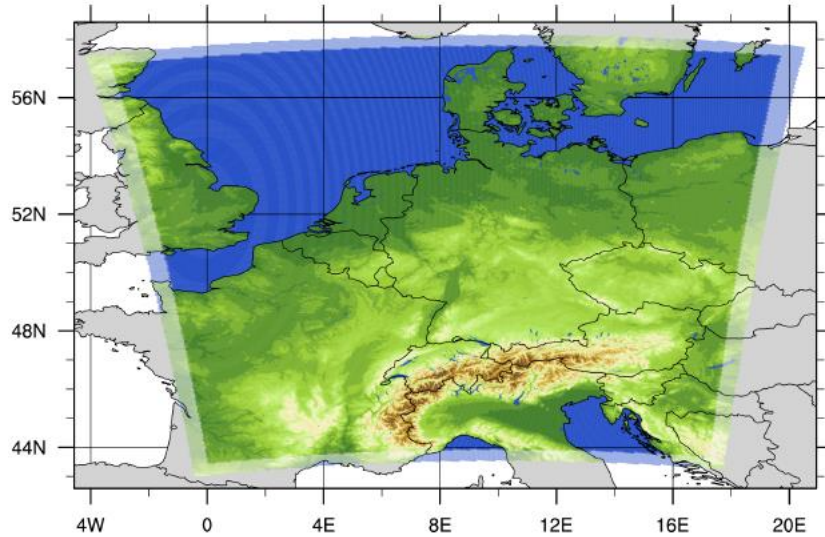
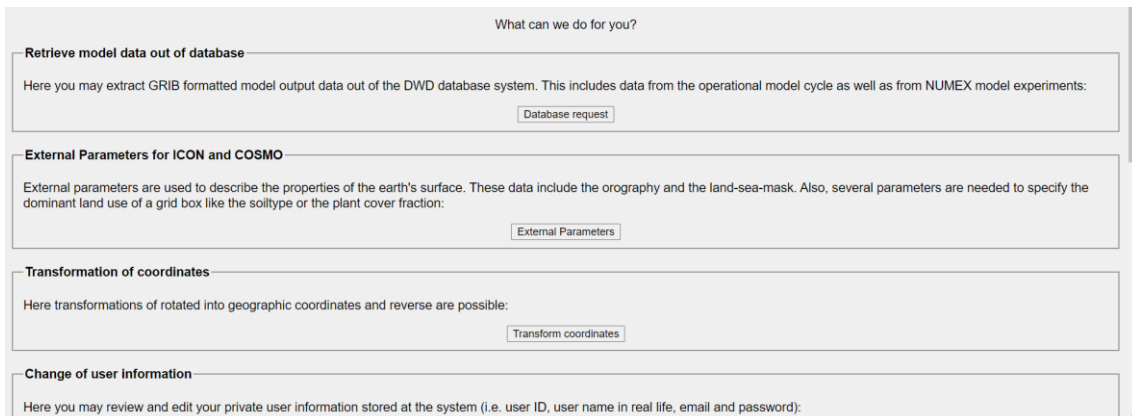


Ilustración 16: Superficie cubierta por el modelo ICON-D2 (Reinert et al., 2023).

Los datos se obtienen en el siguiente enlace: <https://oflkd028.dwd.de/cgi-bin/spp1167/webservice.cgi>, donde de nuevo tras crear una cuenta (de pago en este caso), se accede a la interfaz web para la obtención de los datos:



What can we do for you?

Retrieve model data out of database

Here you may extract GRIB formatted model output data out of the DWD database system. This includes data from the operational model cycle as well as from NUMEX model experiments:

Database request

External Parameters for ICON and COSMO

External parameters are used to describe the properties of the earth's surface. These data include the orography and the land-sea-mask. Also, several parameters are needed to specify the dominant land use of a grid box like the soiltype or the plant cover fraction:

External Parameters

Transformation of coordinates

Here transformations of rotated into geographic coordinates and reverse are possible:

Transform coordinates

Change of user information

Here you may review and edit your private user information stored at the system (i.e. user ID, user name in real life, email and password):

Ilustración 17: Interfaz Web Pamore

Tras acceder se selecciona la opción *Database Request* que da paso a la siguiente página:

Database request

Please choose the kind of model data to retrieve:

Model data from operational model cycle

Model data from NUMEX model experiments

Model data from the SPP 1167 testsuite

or

Ilustración 18: Interfaz Web Pamore (Cont.)

Una vez aquí existen dos opciones, ir seleccionando poco a poco las características de las predicciones y datos que se van a extraer de la base de datos o acceder directamente a la consola en la que escribir la *query* deseada. En este caso llevaremos a cabo la segunda opción pulsado en *Free input of database request*, alcanzando así la siguiente página:

Database request - enter resp. verify the pamore order

Please straight enter resp. verify your database request and if necessary revise it:

no DWD control words inside GRIB (stf_to_r... 

Submit request

or

Export your database request to file:

Export request

Go back one page

Go back to main form

Log out

Zur deutschen Version

Ilustración 19: Interfaz Web Pamore (Cont.)

En la ilustración de arriba encontramos una caja de texto en la que escribir la *query* deseada. En este caso, un ejemplo de *query* sería el siguiente:

```
pamore -G -F -d 2023100500 -de 2023100600 -dinc 3 -vv 1 -ee U%HI,V%HI -lv  
62,63,64,65 -ires r19b07 -lt a -kenda -model ilamf
```

Los *flags* de la consulta son las siguientes:

- Pamore: necesario, sólo significa el inicio de la consulta.
- -G: permite imprimir información sobre los archivos recuperados como el tamaño....
- -F: necesario para llamar a la base de datos interna.
- -d: fecha de inicio. Debe tener el siguiente formato: AAAAMMDDHH.
- -de: fecha final. Fecha final con el mismo formato: AAAAMMDDHH.
- -dinc: incremento de la fecha de análisis. ICON-D2 se ejecuta cada 3 horas. Esta opción permite obtener la previsión más reciente y precisa para cada hora de un día determinado.
- -vv: horizonte temporal de las predicciones desde la ejecución del modelo.

- -ee: especifica las variables meteorológicas que queremos extraer. En este caso, U y V son el viento meridional y zonal que nos permiten calcular el módulo de velocidad del viento. El código del resto de variables se encuentra en Reinert et al. (2023).
- -lv: ICON-D2 divide la atmósfera en 65 niveles. Esta opción permite obtener las variables para determinados niveles.
- Los *flags* siguientes son necesarios y especifican la rejilla del modelo y cómo se ejecuta.

El resto de las opciones se pueden consultar en: <https://webservice.dwd.de/pamore.html>.

Una vez generada la *query* y enviada la solicitud a la base de datos, se esperará un tiempo determinado hasta que esta haya procesado la solicitud y desarchivado los datos. Cuando este proceso se haya completado, el usuario recibirá una notificación por email que incluye un link a un servidor FTP del que descargarse los datos. En este servidor el usuario encontrará un archivo comprimido por cada ejecución del modelo. Al descomprimirlo, el usuario encontrará un archivo de extensión GRIB2, un tipo de archivo diseñado para el tratamiento de datos meteorológicos (*ECMWF Confluence Wiki*, 2023). Es importante destacar que el intervalo de tiempo entre la fecha de inicio y fin no puede ser demasiado elevado ya que la base de datos posee las siguientes restricciones por *query*:

- Número máximo de GRIBs: 300,000
- Número máximo de archivos: 2000
- Cantidad máxima de datos: 256 GB

5.2 PREPROCESADO

El preprocesado de los datos ha sido uno de los principales retos en el desarrollo del trabajo. Este proceso consta de tres etapas principales:

1. Selección de variables significativas para la predicción de la potencia eólica.
2. Imputación de los valores perdidos debido a errores de medición de los sensores u otras causas
3. Identificación y tratamiento de atípicos, para facilitar la predicción.

Además, previo a estas etapas, los datos procedentes de los sensores de las turbinas eólicas y la plataforma meteorológica han sido remuestreados para pasar de datos cada 10 minutos a datos horarios y así coincidir con el periodo de muestreo de los datos procedentes de la predicción numérica del tiempo.

5.2.1 SELECCIÓN DE VARIABLES

Inicialmente se han seleccionado 25 sensores de los que se han descargado los datos de sus mediciones. Estos sensores pertenecen tanto a la góndola de la turbina 4 como a la plataforma meteorológica:

- Sensores de la góndola:
 - Generación de potencia activa (kW)
 - Velocidad del viento (m/s)
 - Velocidad del generador (rpm)
 - Ángulo de paso (°)
 - Posición del rotor (°)
 - Temperatura (°C)
 - Presión (hPa)
 - Humedad relativa en la góndola (%)
- Sensores de la plataforma FINO:
 - Velocidad del viento 100, 90, 80, 70, 50, 40 m (m/s)
 - Dirección del viento 90 m (°)
 - Temperatura 100, 70, 50, 40, 30 m (°C)
 - Presión 20 m (hPa)
 - Humedad relativa 90, 50, 30 m (%)

A continuación, se ha calculado el coeficiente de correlación lineal entre estas variables explicativas y la potencia eólica:

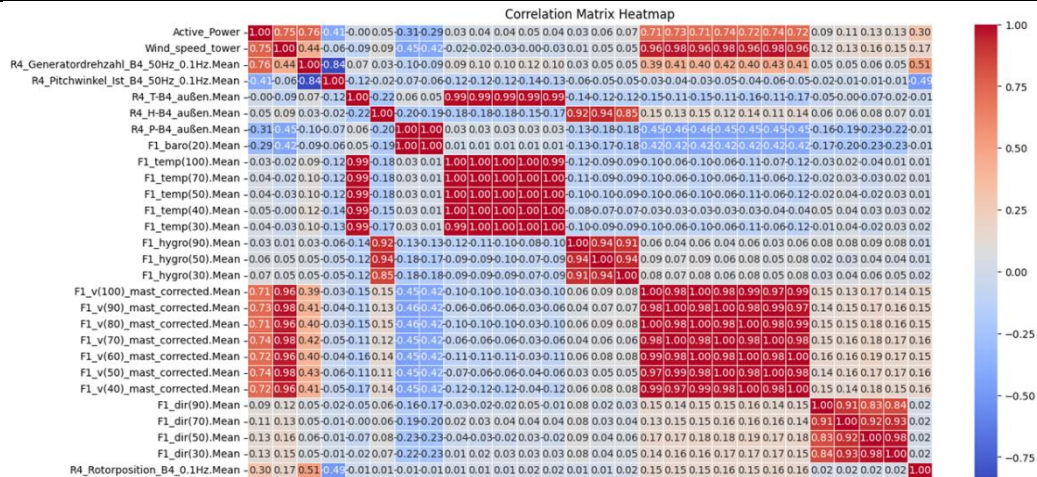


Figura 1: Matriz de Correlaciones

A continuación, se decidió eliminar aquellas variables cuyo valor absoluto del coeficiente de correlación entre dicha variable y la potencia eólica fuese menor que 0,2.

Uno de los aspectos más relevantes a tener en cuenta, es que esta decisión hace eliminar la dirección del viento. Esta variable se erige como una de las más relevantes de la literatura, sin embargo, en este caso, no es relevante, porque la turbina es capaz de orientar su góndola hacia cualquiera de las direcciones del viento, tal y como muestran las figuras siguientes:

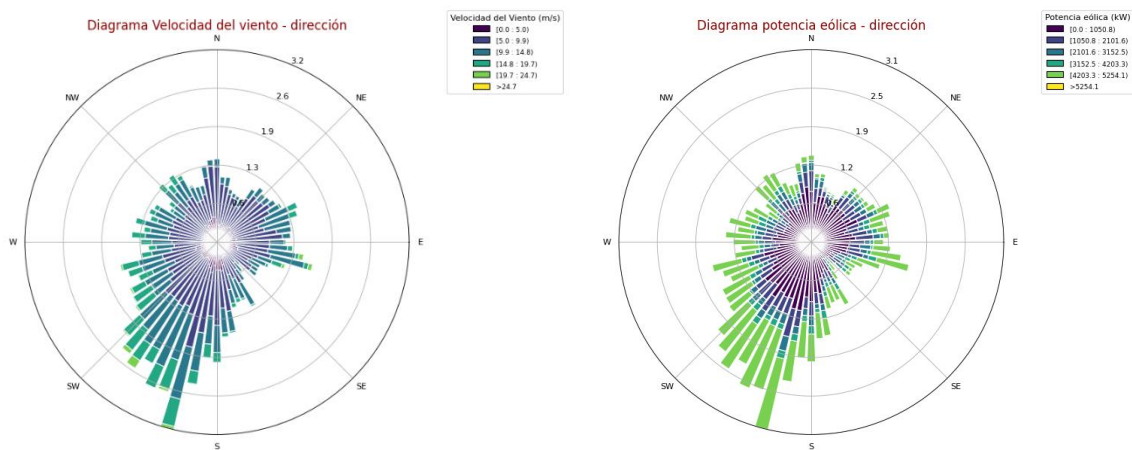


Figura 2: Diagrama Velocidad del Viento - Dirección y Potencia – Dirección

La figura muestra gráficos simétricos, y la capacidad de la turbina de orientarse hacia todas las direcciones del viento. Por esta razón la dirección del viento no es relevante.

Las variables seleccionadas son:

- Sensores de la góndola:
 - Generación de potencia activa (kW)
 - Velocidad del viento (m/s)
 - Velocidad del generador (rpm)
 - Ángulo de paso (°)
 - Posición del rotor (°)
 - Temperatura (°C)
 - Presión (hPa)
- Sensores de la plataforma FINO:
 - Velocidad del viento 100, 90, 80, 70, 50, 40 m (m/s)
 - Presión 20 m (hPa)

5.2.2 IMPUTACIÓN DE VALORES PERDIDOS

Tras la selección de variables, es vital imputar los valores perdidos de las distintas variables para asegurar la continuidad de la serie temporal de cada a la predicción. En este apartado se han llevado a cabo dos procedimientos diferentes: uno para las variables explicativas y otro para las variables de interés.

Para la predicción de la serie temporal es necesario imputar los valores NaN al menos de la variable de interés (Potencia Eólica anterior) y las otras variables más representativas como la velocidad del viento en la góndola. Para imputar la potencia eólica se ha pensado utilizar la ecuación teórica de la potencia:

$$P = \frac{1}{2} A \rho v^3 C_p$$

Ecuación 3: Potencia eólica teórica

Donde $A = \pi r^2$, siendo r el radio del rotor, ρ es la densidad del aire tal que $\rho = P R T$, donde P es la presión en pascales, R es la constante del gas (en el caso del aire seco, $287,05 J kg K$ y T es la temperatura en Kelvin. Por último, v es la velocidad el viento en la góndola y C_p es el coeficiente de potencia que en la industria suele estar en el intervalo 0,35-0,45.

Sin embargo, al observar esto, el primer problema es que, si queremos imputar los valores de potencia, es necesario inicialmente imputar los valores perdidos de los sensores de velocidad del viento, presión y temperatura de la góndola.

Para ellos se puede hacer uso de las medidas de la plataforma meteorológica, que son las medidas más cercanas al encontrarse prácticamente a la misma altura de la góndola del aerogenerador y al estar a una distancia de en torno a 300 m. Sin embargo, estas variables, también poseen valores NaN. Por lo que se deciden complementar con las observaciones históricas meteorológicas ofrecidas por el módulo meteostat (<https://meteostat.net/es/about>) de Python, que permite establecer una coordenada (lat/lon) y devuelve las variables más representativas para esa coordenada con frecuencia horaria en el periodo de tiempo deseado.

Por lo tanto:

- Para predecir R4_T-B4_außen.Mean (temperatura en la góndola) se utiliza F1_temp(100).Mean (temperatura a 100m en la plataforma meteorológica) y la serie histórica de temperatura observada obtenida en meteostat.
- Para predecir R4_P-B4_außen.Mean (presión atmosférica en la góndola) se utiliza F1_baro(20).Mean (presión a 20m en la plataforma meteorológica) y la serie histórica de presión observada obtenida en meteostat.
- Para predecir Wind_speed_tower (velocidad del viento a la altura de la góndola), se utiliza F1_v(100).Mean, F1_v(90).Mean, F1_v(80).Mean, F1_v(70).Mean, F1_v(60).Mean, F1_v(50).Mean, y F1_v(40).Mean (velocidades del viento a 100, 90, 80, 70, 50, 40 m de altura en la plataforma meteorológica) y la serie histórica de velocidad del viento observada obtenida en meteostat.

Una vez definidas nuestras variables a usar para predecir estas variables de interés, es necesario definir el algoritmo. Su elección está supedita a la restricción de que, en nuestras variables explicativas con las que predecir cada una de estas variables, hay algunas filas que poseen valores NaN pues son los valores NaN de los sensores de la plataforma meteorológica. Por esta razón se debe utilizar un algoritmo que no se vea afectado por la presencia de estos valores y que permita su presencia en las variables explicativas durante el entrenamiento, este algoritmo es XGBoost (Chen & Guestrin,

2016) que funciona construyendo secuencialmente un conjunto de modelos de predicción débiles, normalmente árboles de decisión, de forma iterativa para producir un potente modelo compuesto con gran capacidad predictiva. Para cada variable de interés, se entrena el algoritmo para aquellos valores donde la Y no es NaN (las variables x's si pueden serlo), habiendo dividido esas muestras aleatoriamente en entrenamiento y prueba (80% - 20%) previamente para medir el desempeño del modelo. A continuación, se predicen los valores donde la variable Y es NaN. Las siguientes representaciones se ofrecen como ejemplo en el caso de Wind_speed_tower:




Figura 3: Desempeño del algoritmo XGBoost para la predicción de la velocidad del viento en la góndola

La Figura 3 muestra el desempeño del algoritmo para el conjunto de test.




Figura 4: Valores predichos para los valores perdidos de la velocidad del viento en la góndola

La Figura 4 muestra las predicciones realizadas para los valores NaN. Es fácil observar que los valores NaN se agrupan por bloques en determinados momentos temporales y que no se distribuyen aleatoriamente a lo largo de la serie. Esto dificulta su imputación y no permite llevar a cabo procedimientos típicos como la imputación con el valor anterior o el siguiente.

Este mismo procedimiento se lleva a cabo para el resto de las variables previamente comentadas. Las variables que se han utilizado como variables explicativas para el algoritmo XGBoost, se eliminan y no serán utilizadas de cara a la predicción final de la potencia eólica.

Una vez imputadas las variables necesarias para el cálculo de la potencia teórica (presión, temperatura, y velocidad del viento) necesitamos obtener el valor de C_p , que no es público. Por lo tanto, para aquellas observaciones donde la potencia eólica no es NaN, despejamos de la fórmula inicial este valor:

$$C_p = \frac{2P}{A \rho v^3}$$

Con esto obtenemos un valor de C_p para cada observación en la que Potencia Eólica anterior no es NaN. Sin embargo, es necesario elegir un valor de C_p constante. Para ello se obtienen las predicciones teóricas con cada uno de los C_p calculados en las muestras en las que Potencia

Eólica anterior nos es NaN, se computa la raíz cuadrada del error cuadrático medio entre las predicciones teóricas y los valores reales de Potencia Eólica anterior y se escoge el coeficiente C_p que minimiza dicho error. El C_p óptimo obtenido tiene un valor de 0,411, valor que se encuentra en el rango esperado

Una vez realizado esto, se calcula el valor teórico de la potencia para las muestras en las que Potencia Eólica anterior es NaN con dicho coeficiente y se imputan los NaN de la serie original con estas muestras.

Tras este proceso, faltan por imputar los valores perdidos en aquellas variables explicativas no meteorológicas, aquellas no poseen una variable equivalente ni en los sensores de la plataforma meteorológica ni en el paquete meteostat:

- Velocidad del generador (rpm)
- Ángulo de paso (°)
- Posición del rotor (°)

Atendiendo a Figura 1, se observa que la velocidad del generador es la variable que mayor correlación tiene con la potencia eólica, y que, además, la correlación de esta con las otras dos variables (ángulo de paso y posición del rotor) también es elevada. Por esta razón se utiliza de nuevo XGBoost para predecir los valores perdidos de la velocidad del generador utilizando el ángulo de paso y la posición del rotor como variables explicativas siguiendo el procedimiento explicado anteriormente.

Por último, se incluyen también las variables procedentes de la predicción numérica del tiempo: la velocidad del viento a la altura determinada por las capas del modelo previamente explicado.

5.2.3 IDENTIFICACIÓN Y TRATAMIENTO DE ATÍPICOS

Tras la selección de variables, es vital la identificación y el tratamiento de los atípicos en la variable de interés, en este caso, la potencia eólica. Para ello, inicialmente se ha representado la curva potencia eólica – velocidad del viento:




Figura 5: Curva inicial potencia - velocidad del viento

Se ha determinado hacer uso de esta representación, porque facilita la identificación visual de los atípicos. De acuerdo con la literatura, la curva de potencia ideal de una turbina es la siguiente:

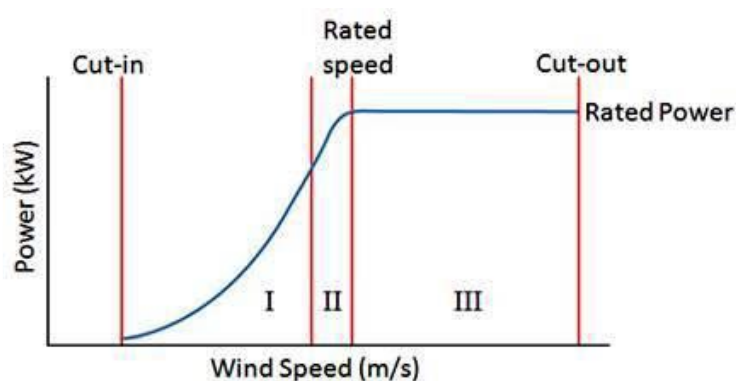


Figura 6: Curva de potencia ideal (Luo et al., 2017)

En la Figura 6, la curva ideal muestra tres regiones, tal y como explican Luo et al (2017):

1. La región I se compone de velocidades de viento bajas, por debajo de la potencia nominal.
2. La región II es una región de transición.
3. La Región III se compone de velocidades de viento elevadas en las que la turbina genera su potencia nominal controlando que la velocidad del viento de corte no sea alcanza y su funcionamiento detenido.

Teniendo esto en cuenta, en la Figura 6 se observan diferentes tipos de atípicos:

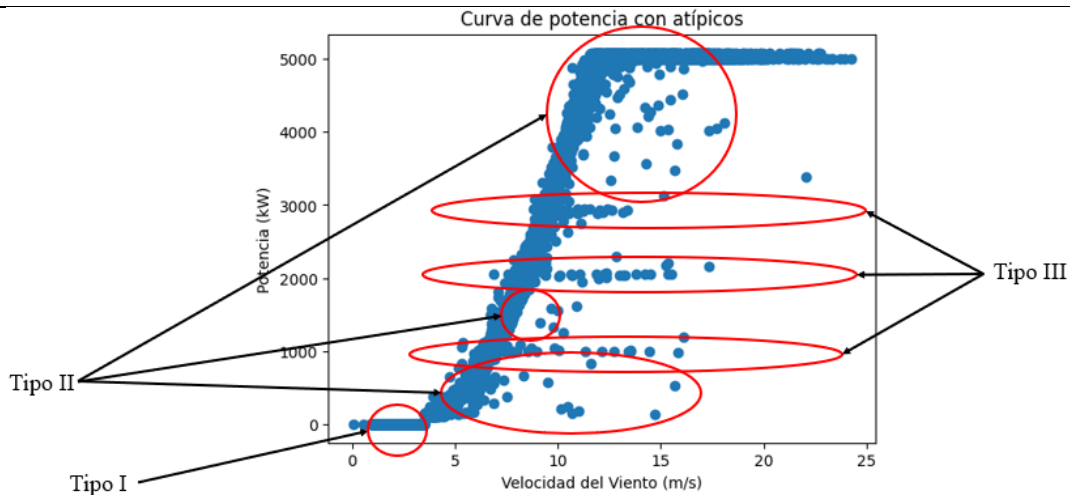


Figura 7: Tipos de atípicos

1. Tipo I: valores negativos, que, aunque son de una magnitud muy pequeña, existen valores negativos de potencia. De acuerdo con Shen et al (2019) las curvas de potencia medidas contendrán estos valores negativos a las velocidades de viento más bajas justo antes de la velocidad mínima de generación (final de la región I). Estos valores negativos representan el consumo de energía debido al arranque de la turbina, en el que el generador actúa como motor, consumiendo energía de la red. Siguiendo el procedimiento de Hanifi et al (2022), estos valores toman el valor 0.
2. Tipo II: transiciones a cero. Estos valores representan el fenómeno conocido como *curtailment*, son valores intermedios en la transición a 0, que se producen cuando la turbina se apaga debido a que la red no demanda más generación. Representan los valores muestreados por los sensores en dicha transición a 0.
3. Tipo III: errores de medida. De acuerdo con la literatura, este tipo de atípicos se dan debido a errores de medición de los sensores (Hanifi et al, 2022). Sin embargo, el hecho de que se concentren de esta manera esos atípico podría estar relacionado con alguna característica física de la turbina o las condiciones meteorológicas del momento. En cualquier caso, en el desarrollo del trabajo de ha tratado como atípicos.

Para la identificación de los atípicos de tipo II y tipo III se hace uso del algoritmo *isolation forest* (Liu et al, 2009). Este algoritmo aísla las observaciones seleccionando aleatoriamente una característica y luego eligiendo un valor de división aleatorio entre los

valores máximo y mínimo de la característica seleccionada. El funcionamiento es el siguiente:

1. Construcción del Bosque Aleatorio: el algoritmo construye múltiples árboles de decisión, conocidos como un "bosque de aislamiento". Cada árbol se construye a partir de una muestra aleatoria de los datos.
2. División en los Árboles: para cada árbol, el algoritmo divide los datos recursivamente. En cada paso, selecciona aleatoriamente una característica y un valor de división entre los valores máximos y mínimos de esa característica. Esta división continúa hasta que los datos están aislados (es decir, cada punto está aislado en su propia hoja) o se alcanza un límite de profundidad predefinido. Los atípicos requerirán menos divisiones que aquellos que no lo son ya que su valor difiere significativamente de las muestras comunes.
3. Longitud del Camino: la longitud del camino en el árbol, desde la raíz hasta el nodo terminal, sirve como medida de normalidad. Los caminos más cortos sugieren que el punto de datos probablemente es un atípico porque ha resultado más fácil su aislamiento.
4. Puntuación de atípicos: Después de construir el bosque, el algoritmo utiliza las longitudes de los caminos de los árboles para puntuar los atípicos. Una longitud media de camino más corta indica una mayor probabilidad de ser un atípico.

La Figura 8 muestra el uso de este algoritmo para la identificación de atípicos:

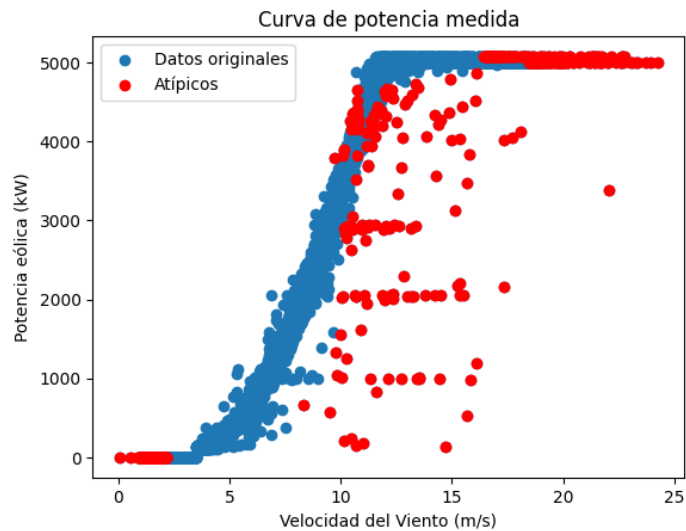


Figura 8: Atípicos detectados por Isolation Forest

Las muestras identificadas como atípicos han sido sustituidas por su valor teórico haciendo uso de la Ecuación 3, dando lugar a la siguiente curva de potencia:

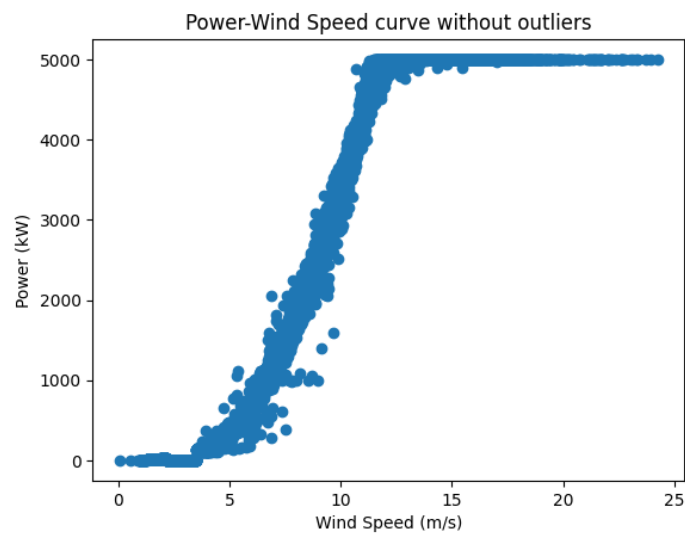


Figura 9: Curva de potencia sin atípicos

Esta curva representa los datos finales de potencia eólica, aunque el tratamiento de los atípicos no los ha eliminado por completo (se observan unos cuantos atípicos en torno para velocidades de viento de 10 m/s con una potencia eólica de 1000 kW), serán los usados para el entrenamiento de los modelos y la posterior predicción de potencia eólica. El único aspecto que destacar es que, para evitar un desempeño pobre de los modelos, las variables explicativas han sido normalizadas en el rango [0,1]:

$$x_{normalizada} = \frac{x - \min(x)}{x - \max(x)}$$

Ecuación 4: Normalización [0,1]

5.3 IDENTIFICACIÓN Y AJUSTE DE LOS MODELOS

En este apartado, se ofrecerá tanto la formulación teórica de los distintos modelos desarrollados, como la especificación escogida de estos en relación con sus hiperparámetros, que son aquellos parámetros que el modelo no puede aprender por sí mismo.

5.3.1 MODELO ARIMA

El modelo autorregresivo integrado de media móvil (del inglés *autorregresive integrated moving average, ARIMA*) fue desarrollado Box y Jenkins (1972). Su idea parte de la concepción de que las series temporales a analizar son eventos aleatorios. Por esta razón, el análisis de la evolución pasada de la serie solo permite acercarse a un modelo probabilístico de este. Tal y como se ha anticipado previamente, la especificación del modelo es la siguiente:

$$\phi(B)(1 - B)^d y_t = \theta(B)\epsilon_t$$

Donde:

- y_t es el valor de la serie temporal en el tiempo t .
- B es el operador de retraso, tal que $By_t = y_{t-1}$.
- ϵ_t es el término del error en el tiempo t , que se asume como ruido blanco gaussiano.
- $\phi(B)$ es el polinomio autoregresivo (AR) de orden p .
- $(1 - B)^d$ es el operador de diferenciación de orden d .
- $\theta(B)$ es el polinomio de media móvil (MA) de orden q .

Específicamente, los polinomios $\phi(B)$ y $\theta(B)$ se definen como:

- $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$
- $\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$

Por lo tanto, la forma polinómica completa del modelo ARIMA(p, d, q) es:

$$\left(1 - \sum_{i=1}^p \phi_i B^i\right) (1 - B^d) y_t = \left(1 + \sum_{j=1}^q \theta_j B^j \epsilon_t\right)$$

Donde:

- B es el operador de retardo (*lag operator*).
- ϵ_t es el término del error en el tiempo t , que se asume como ruido blanco gaussiano.
- ϕ_i son los coeficientes del modelo autoregresivo (AR).
- θ_j son los coeficientes del modelo de media móvil (MA).

Una selección adecuada de estos parámetros es vital para la correcta especificación del modelo. El proceso llevado a cabo es el siguiente:

1. **Selección del parámetro d :** para la selección de este parámetro, inicialmente se ha representado la evolución temporal de la serie para explorar la posibilidad de identificar alguna tendencia que ya demuestre que la serie temporal no es estacionaria

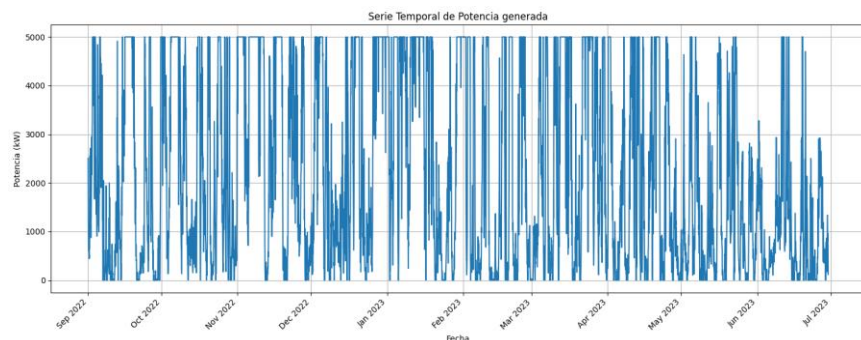


Ilustración 20: Serie temporal de potencia eólica

La representación no muestra tendencia, pero para confirmar la conclusión inicial, se ha representado la función de autocorrelación simple de la serie temporal

(ACF). Esta función define cómo se relacionan, las muestras de una serie temporal con las muestras precedentes (Box, Jenkins & Reinsel, 1994). En otras palabras, mide la correlación lineal de cada muestra de la serie con sus k retardos anteriores. La función se representa haciendo uso del correlograma, en el que el sombreado azul muestra el intervalo de confianza al 95% para el valor de la función en el retardo determinado:




Figura 10: Correlograma de la serie original

La Figura 10 muestra una lenta caída de los coeficientes, un comportamiento que indica no estacionariedad. Para asegurar esta conclusión, se ha llevado a cabo la prueba de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) en la que la hipótesis nula es que una serie temporal observable es estacionaria en media en oposición a la hipótesis alternativa de la existencia de una raíz unitaria (Kwiatkowski et al., 1992). El resultado de la prueba ofrece un valor del estadístico de contraste de 1,3317 y un p-valor de 0,01, lo que nos permite rechazar la hipótesis nula al 99% de confianza, es decir, la serie no es estacionaria. Atendiendo a este resultado se decide diferenciar la serie una primera vez, y se representa de nuevo su correlograma:

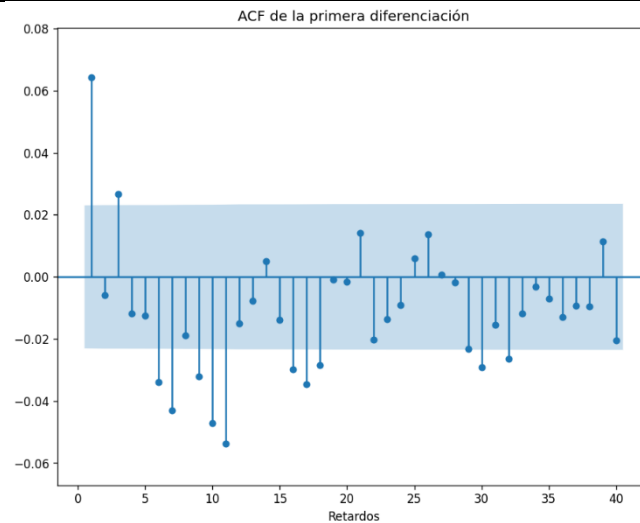


Figura 11: correlograma de la serie diferenciada

De nuevo, se realiza la prueba KPSS y se obtiene un valor del estadístico de 0,0030 y un p-valor de 0,1 lo que nos permite no rechazar la hipótesis nula al 95% de confianza, concluyendo que la serie temporal con un orden de diferenciación es estacionaria, y por tanto $d = 1$.

2. **Selección del parámetro p :** para la elección de este parámetro es necesario representar también la función de autocorrelación parcial (PACF). A diferencia de la función de autocorrelación simple, la de autocorrelación parcial mide el efecto ente una muestra y sus retardos, eliminando el efecto de los retardos intermedios. La figura muestra una distribución muy compleja por lo que se decide iniciar con un valor de $p = 1$.




Figura 12: Coeficientes de la PACF de la serie diferenciada

3. **Selección del parámetro q :** en este caso, de nuevo, atendemos al correlograma de la función de autocorrelación simple. Al igual que en el caso de p , la función de autocorrelación simple es muy compleja y no ofrece un valor claro del parámetro q , por lo que se decide partir también de $q = 1$.

Por lo tanto, el modelo será un modelo ARIMA(1,1,1). El resultado de la estimación del modelo es el siguiente:

```

=====
SARIMAX Results
=====
Dep. Variable:      Active_Power      No. Observations:      7248
Model:             ARIMA(1, 1, 1)      Log Likelihood         -55692.918
Date:              Tue, 11 Jun 2024      AIC                    111391.836
Time:              18:13:32          BIC                    111412.501
Sample:            0                  HQIC                   111398.945
                  - 7248
Covariance Type:   opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
ar.L1          -0.3974      0.091        -4.379      0.000        -0.575        -0.220
ma.L1           0.4594      0.089         5.184      0.000         0.286         0.633
sigma2         2.772e+05    1961.176    141.323      0.000        2.73e+05        2.81e+05
=====
Ljung-Box (L1) (Q):      0.10      Jarque-Bera (JB):      25396.22
Prob(Q):                 0.75      Prob(JB):              0.00
Heteroskedasticity (H):  1.01      Skew:                  0.25
Prob(H) (two-sided):    0.72      Kurtosis:              12.16
=====

Warnings:
[1] Covariance matrix calculated using the outer product of gradients (complex-step).

Test for Constraints
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
c0          -0.3974      0.091        -4.379      0.000        -0.575        -0.220
c1           0.4594      0.089         5.184      0.000         0.286         0.633
c2         2.772e+05    1961.176    141.323      0.000        2.73e+05        2.81e+05
=====

```

Ilustración 21: Resultado de la estimación del modelo ARIMA

Se observa que todos los parámetros, tanto los autorregresivos (ar.L1) y los de media móvil (ma.L1) del modelo son significativos al 99% de confianza. La validez predictiva del modelo se analizará posteriormente.

Tras el entrenamiento, también se ha llevado a cabo un análisis de los residuos para comprobar que son similares al ruido blanco y ver si el modelo sencillo captura la información de la serie. En primer lugar, se representa la serie temporal de los residuos en la que no se aprecia ningún patrón o tendencia visible:





Figura 13: Evolución temporal de los residuos

A continuación, se representa la función de autocorrelación simple y parcial de los residuos para estudiar si entre ellos existe correlación no capturada por el modelo:



En ambos casos se observa que existen correlaciones significativas, sin embargo, el valor de estas correlaciones es muy pequeño (entre $-0,025$ y $-0,05$), por lo que se decide mantener este modelo por su simplicidad. Adicionalmente, atendiendo al contraste de Jarque-Bera en Ilustración 21, se deduce que los residuos no están normalmente distribuidos, y por lo tanto no son ruido blanco gaussiano. Pese a esto, por simplicidad, al igual que en el caso de las correlaciones se ha decidido utilizar este modelo, ya que

eliminar toda la autocorrelación entre los residuos implicaría ordenes muy elevados de los parámetros.

5.4 REDES NEURONALES

Tal y como se ha anticipado durante el análisis del estado del arte, las redes neuronales están inspiradas en el sistema nervioso del ser humano, se basan en una red de neuronas en las que unas a otras se transfieren la información tras procesarla. Las redes neuronales representan el núcleo del conocido *deep learning*, un subconjunto de algoritmos dentro del aprendizaje automático o *machine learning*.

Imitando al sistema nervioso, las redes neuronales consisten en un conjunto de unidades de procesamiento, o "neuronas", organizadas en capas que transmiten señales entre sí. Una red neuronal típica incluye una capa de entrada, una o más capas ocultas, y una capa de salida. La capa de entrada recibe los datos brutos, que se procesan a través de las capas ocultas mediante una combinación de ponderaciones, sesgos y funciones de activación, para finalmente generar una salida en la capa de salida. Este proceso se asemeja al modo en que las neuronas biológicas procesan la información: reciben señales, las procesan y pasan la respuesta a otras neuronas.

5.4.1 REDES NEURONALES *FEED-FORWARD* TIPO *PERCEPTRÓN MULTICAPA*

El primer tipo de redes neuronales que se han analizado son las denominadas *feed-forward*, y más concretamente el perceptrón multicapa. En este tipo de red, la información discurre únicamente en un sentido y no existen bucles de realimentación en el procesamiento de esta a lo largo de la red (Sazli, 2006). En estas redes, cada neurona recibe una serie de entradas, las procesa y produce una salida. El funcionamiento de una neurona en una red neuronal *feed-forward* puede descomponerse en los siguientes pasos:

1. **Entradas:** Cada neurona recibe entradas de otras neuronas o, en el caso de la primera capa (la capa de entrada), directamente de los datos de entrada. Estas entradas se asocian con pesos, que son parámetros ajustables que determinan la importancia relativa de cada entrada para la salida de la neurona.
2. **Suma ponderada:** La neurona calcula una suma ponderada de sus entradas, multiplicando cada entrada por su peso correspondiente y sumando todos los

productos. A menudo, a esta suma se le añade un término adicional conocido como sesgo, que permite ajustar la salida de la neurona independientemente de sus entradas, proporcionando una mayor flexibilidad al modelo.

3. **Función de activación:** La suma ponderada se pasa luego a través de una función de activación, que es una operación no lineal. La función de activación determina si y cómo la señal de esa neurona se propaga a través de la red. La no linealidad introducida por la función de activación es crucial, ya que permite a la red aprender y modelar relaciones complejas entre los datos de entrada y salida. Algunas de las funciones más utilizadas son la tangente hiperbólica, la función sigmoidea o la función ReLU, cuyas expresiones se ofrecen más adelante.
4. **Salida:** La salida de la función de activación se convierte en la salida de la neurona. Esta salida puede ser enviada a neuronas en la siguiente capa de la red o, en el caso de las neuronas en la capa de salida, convertirse en parte de la salida global de la red.

La Ilustración 22 muestra un esquema de funcionamiento sencillo:

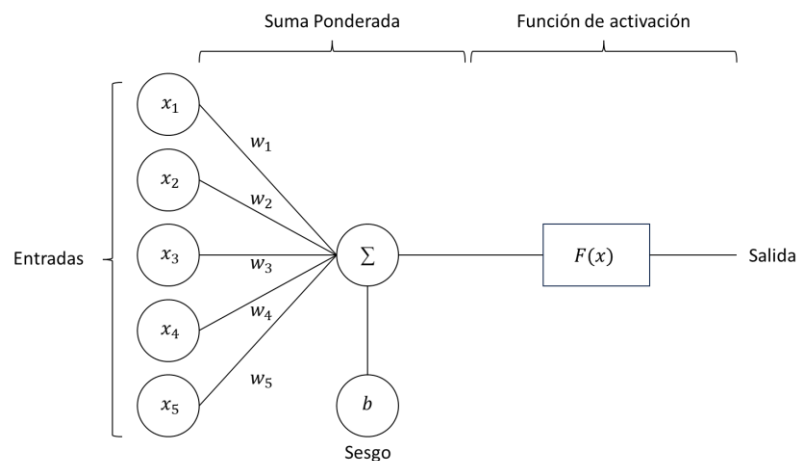


Ilustración 22: Esquema de funcionamiento de una neurona tipo perceptron

De esta forma la salida se expresa como:

$$y = F\left(\sum_{i=1}^5 x_i w_i + b\right)$$

El aprendizaje en las redes neuronales se realiza ajustando las ponderaciones o pesos y los sesgos de las conexiones entre neuronas. Durante el entrenamiento, se utiliza un

conjunto de datos para enseñar a la red la relación entre las entradas y las salidas deseadas.

El ajuste se realiza mediante algoritmos de optimización, siendo el más conocido el de retropropagación con descenso del gradiente, que minimiza la suma de los cuadrados de la diferencia entre las salidas predichas por la red y las salidas reales o deseadas. El proceso es el siguiente (Aggarwal, 2018):

1. **Inicialización:** Antes del entrenamiento, los pesos y sesgos de la red se inicializan, generalmente con valores pequeños aleatorios. Esto asegura que la red comience el aprendizaje con una configuración no sesgada.
2. **Propagación hacia adelante** (*Forward Propagation*): Durante este paso, una entrada se alimenta a la red y se propaga a través de las capas hasta generar una salida. En cada neurona, se calcula la suma ponderada de las entradas y se aplica la función de activación para producir una salida, que luego se pasa a la siguiente capa hasta alcanzar la capa de salida.
3. **Cálculo del error:** Una vez que la red ha producido una salida, se calcula el error comparando la salida de la red con la salida real o deseada. La función de error cuantifica la diferencia entre las dos, siendo el objetivo del entrenamiento es minimizar esta función de pérdida.
4. **Retropropagación del error** (*Backpropagation*): el error calculado se propaga de vuelta a través de la red, desde la capa de salida hasta las capas de entrada, utilizando la regla de la cadena para calcular el gradiente de la función de pérdida con respecto a cada peso y sesgo en la red. Este gradiente indica cómo deberían ajustarse los pesos y sesgos para minimizar el error.
5. **Actualización de pesos y sesgos:** Utilizando los gradientes calculados, los pesos y sesgos de la red se ajustan en la dirección que reduce el error. Este ajuste se realiza utilizando un algoritmo de optimización, siendo el más común el Descenso del Gradiente (Curry, 1944) o alguna de sus variantes como Adam (Kingma & Ba, 2014). El tamaño del paso de ajuste se controla mediante un parámetro denominado tasa de aprendizaje (*learning rate*). La ecuación para la actualización de los pesos es la siguiente:

$$w_{ij} \leftarrow w_{ij} - \eta \frac{\partial L}{\partial w_{ij}}$$

Donde:

- w_{ij} es el peso entre la neurona i y la neurona j .
- η es la tasa de aprendizaje (*learning rate*), un parámetro que determina el tamaño de los pasos que se toman en la dirección del gradiente.
- L es la función de pérdida o error (*loss function*) que mide cuán bien la red neuronal está haciendo su trabajo.
- $\frac{\partial L}{\partial w_{ij}}$ es el gradiente de la función de pérdida con respecto al peso w_{ij} .

6. **Iteración y convergencia:** Los pasos de propagación hacia adelante, cálculo del error, retropropagación y actualización se repiten para muchos ejemplos de entrenamiento, en múltiples pasadas o "épocas" (*epochs*) a través del conjunto de datos. Con cada iteración, los pesos y sesgos de la red se ajustan gradualmente para minimizar el error de salida. El proceso continúa hasta que la red alcanza un nivel satisfactorio de rendimiento, o hasta que se cumple un criterio de parada predefinido (como un número máximo de épocas o un umbral de error mínimo).

Perceptrón Multicapa (MLP)

Es un tipo de red *feed-forward* totalmente conectada. La Ilustración 23 muestra una representación gráfica de la arquitectura de la red. El proceso de entrenamiento es idéntico al descrito en el apartado anterior.

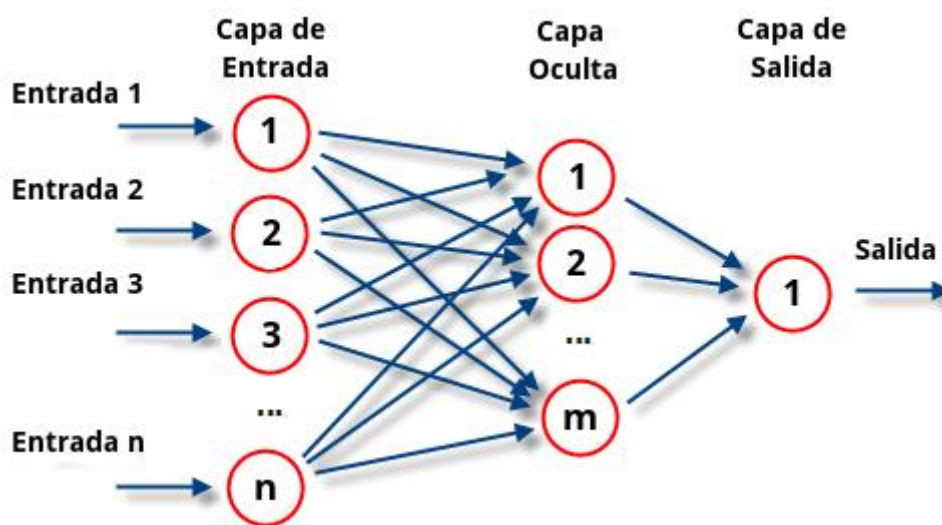


Ilustración 23: Esquema de una red MLP (Wikipedia, 2023)

En el caso del perceptrón multicapa, las funciones de activación típicamente usadas para los problemas de regresión son los siguientes:

- Función sigmoidea: $\sigma(z) = \frac{1}{1+e^{-z}}$
- Función tangente hiperbólica: $\tanh(z) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
- Función ReLU: $ReLU(z) = \max(0, z)$

5.4.2 REDES NEURONALES RECURRENTE

En este tipo de redes, a diferencia, de las anteriores, la información no viaja en un único sentido, si no que existen bucles en la arquitectura de la red que permiten transmitir la información no solo hacia la salida, si no hacia la propia red. La Ilustración 24 representa la diferencia entre estos tipos de redes:




Ilustración 24: Redes Recurrentes vs. Redes Feed-Forward («Programming With TensorFlow», 2021)

Estos bucles permiten a las redes neuronales recurrentes (RNN) poseer “memoria” durante un cierto período. Las neuronas pueden enviar información a través de estos bucles, lo que permite que la red mantenga un estado interno y procese secuencias de datos, considerando el contexto proporcionado por las entradas anteriores. Esta capacidad las hace especialmente adecuadas para tareas relacionadas con series temporales, procesamiento de lenguaje natural, reconocimiento de voz y cualquier tarea donde el contexto temporal o la secuencia de los datos sea relevante. De manera similar a cómo los modelos de media móvil (MA) en el análisis de series temporales requieren una recurrencia para modelar la dependencia de los errores pasados, las RNN utilizan su estructura recurrente para capturar dependencias temporales complejas en los datos.

El entrenamiento de las RNN se realiza comúnmente mediante un algoritmo llamado *Backpropagation Through Time* (BPTT) (Goodfellow et al., 2016). BPTT es una variante de la retropropagación estándar adaptada para manejar la naturaleza secuencial de las RNN y el proceso es el siguiente:

1. **Desenrollar la red en el tiempo:** Para aplicar la retropropagación, la RNN se "desenrolla" a lo largo de los pasos de tiempo, creando una cadena de copias de la red, cada una correspondiente a un paso de tiempo en la secuencia de entrada. La Ilustración 25 muestra un esquema simple de este proceso:




Ilustración 25: Esquema de desenrollamiento de RNN (Goyal et al., 2018)

2. **Cálculo de errores:** Se calcula el error en cada paso de tiempo, comparando la salida de la red con el valor esperado.
3. **Retropropagación del error:** El error se propaga hacia atrás a través de la red desenrollada, lo que implica calcular el gradiente del error con respecto a cada peso en cada paso de tiempo.
4. **Actualización de pesos:** Los pesos se ajustan en la dirección que minimiza el error, típicamente utilizando algoritmos similares a los mencionados en las redes *feed-forward*.

Red LSTM

Desarrollada por Hochreiter y Schmidhuber (1997), se caracteriza por su capacidad de memoria a largo plazo, que les permite recordar información durante largos periodos de tiempo, por esta razón su uso se ha popularizado en la predicción de series temporales. En el contexto de una red LSTM (*Long Short-Term Memory*), una neurona (también conocida como unidad o celda), a diferencia de las neuronas en una red neuronal *feed-forward* estándar, tiene una estructura más compleja que le permite capturar y retener información durante largos períodos, abordando el problema del desvanecimiento del

gradiente que enfrentan las redes neuronales recurrentes (RNN) tradicionales. Una neurona LSTM consta de varios componentes clave:

1. **Estado de la celda (C_t):** Actúa como una memoria que lleva información a lo largo de la secuencia. Permite que la red retenga información durante largos períodos.
2. **Estado oculto (h_t):** Es la salida de la celda LSTM en un momento específico.
3. **Puerta de entrada (i_t):** Determina qué parte de los datos que entran (x_t) a la celda se utilizará para actualizar el estado de esta.
4. **Puerta de olvido (f_t):** Esta puerta decide qué parte del estado anterior de la celda (C_{t-1}) debe olvidarse o retenerse. Controla la cantidad de información que debe eliminarse del estado de la celda con la entrada de nuevos datos.
5. **Puerta de salida (o_t):** Esta puerta determina qué cantidad de información del estado de la celda debe extraerse y enviarse a la siguiente celda LSTM.
6. **Estado de celda candidato (\tilde{C}_t):** Representa nueva información que podría agregarse al estado de la celda, calculada en función de la entrada actual y el estado oculto anterior.




Ilustración 26: Celda LSTM (Varsamopoulos et al., 2018)

Las operaciones realizadas en cada celda son las siguientes:

- **Puerta de olvido:** $f_t = \sigma \cdot (W_f \cdot [h_{t-1}, x_t] + b_f)$
- **Puerta de entrada:** $i_t = \sigma \cdot (W_i \cdot [h_{t-1}, x_t] + b_i)$
- **Estado de celda candidato:** $\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$
- **Actualización del estado de la celda:** $C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$
- **Puerta de salida:** $o_t = \sigma \cdot (W_o \cdot [h_{t-1}, x_t] + b_o)$

- **Estado oculto:** $h_t = o_t \cdot \tanh(C_t)$

Donde:

- σ representa la función sigmoidea.
- W_i, W_f, W_o y W_C son las matrices de pesos para cada una de las puertas y para el estado de la celda respectivamente.
- b_i, b_f, b_o y b_C son los vectores de sesgos para cada una de las puertas y para el estado de la celda respectivamente.
- h_{t-1} y h_t son los estados ocultos de los pasos temporales anteriores y actuales, respectivamente.
- x_t es la entrada en el paso temporal actual.

Una capa LSTM consta de múltiples neuronas LSTM dispuestas de tal manera que procesan secuencias de datos. Cada neurona (celda) en la capa procesa un paso temporal de la secuencia de entrada, y las salidas de las neuronas en cada paso temporal se pasan a las neuronas del siguiente paso temporal. La Ilustración 27 muestra una unidad desenrollada de ejemplo con tres celdas LSTM, ya que procesa tres pasos de tiempo:




Ilustración 27: Capa LSTM desenrollada (Understanding LSTM Networks -- Colah's Blog, s. f.)

El funcionamiento de la capa es el siguiente:

1. **Entrada:** La entrada a la capa LSTM es una secuencia de vectores, denotada como (x_1, x_2, \dots, x_T) , donde T es la longitud de la secuencia y cada x_t es el vector de entrada en el tiempo t , compuesto por el valor en el instante t de las variables explicativas seleccionadas. Si la secuencia consta de T pasos de tiempo, la entrada a la capa LSTM será una matriz de dimensiones $(T, N^\circ \text{ de variables explicativas})$

2. **Inicialización de estados:** al comienzo, en cada celda se inician los estados típicamente: $h_0 = 0; C_0 = 0$
3. **Propagación temporal:** para cada paso de tiempo t desde 1 hasta T , la capa LSTM procesa la entrada x_t utilizando las unidades de forma secuencial. Cada neurona procesa la entrada en un paso temporal específico t . La misma neurona LSTM (con pesos compartidos) se usa en todos los pasos temporales. En cada paso t , la neurona recibe el vector de entrada x_t , el estado oculto anterior h_{t-1} y el estado de la celda anterior C_{t-1} . La neurona realiza los cálculos para las puertas de olvido, entrada y salida, y actualiza el estado de la celda y el estado oculto, como se describió anteriormente.
4. **Generación de la secuencia de salida:** en cada paso de tiempo t , la capa genera una salida h_t que es un vector de N (en el ejemplo $N = 3$) dimensiones (uno por cada unidad LSTM). La salida para el paso t depende de las operaciones internas de todas las unidades LSTM.
5. **Secuencia de salida:** La secuencia de salida generada por la capa LSTM tendrá dimensiones (T, N) , es decir, una secuencia de T vectores de salida, cada uno de N dimensiones.

La Ilustración 28 muestra el funcionamiento de la unidad sin desenrollar:




Ilustración 28: unidad LSTM sin desenrollar

En el caso de que hubiese capas LSTM en cascada, los estados ocultos de la capa anterior $(h_1^{(n)}, h_2^{(n)}, h_3^{(n)}, \dots, h_T^{(n)})$ serán la entrada de la siguiente capa $(x_1^{(n+1)}, x_2^{(n+1)}, x_3^{(n+1)}, \dots, x_T^{(n+1)})$.




Ilustración 29: Capas LSTM en cascada (Nicholas et al., 2018)

Para obtener un/os valor/es finales, se añade una capa completamente conectada de tantas unidades como salidas se deseen. En el trabajo desarrollado, esta última capa posee nueve neuronas, cada una de ellas representa una hora en el horizonte temporal de predicción (de una a nueve horas en el futuro). Para la implementación de la red se ha usado Python, y más concretamente la función LSTM del paquete Keras (Chollet, 2015). Es necesario destacar dos parámetros de la función:

- *Return_sequences*: por defecto su valor es *False*, de manera que Keras devuelve únicamente el valor de h_t más reciente. Esto es adecuado solo en la capa LSTM de salida, para apilar capas LSTM, se debe cambiar el valor de este parámetro a *True*.
- *Stateful*: por defecto tiene un valor *False*. Cuando su valor se cambia a *True*, evita que el valor de los estados de la celda se reinicie con cada nuevo lote (*batch*) en el entrenamiento.

Red GRU

Las redes GRU son una variante de las redes LSTM y fueron introducidas por Cho et al. (2014). La estructura interna de la GRU es comparable a la de la LSTM, con la diferencia de que la GRU combina la puerta de entrada y la puerta de olvido de la red LSTM en una sola puerta de actualización. De esta manera, la red GRU, cuenta con dos puertas: la puerta de actualización, que regula cuánto de la información previa se mantiene en el estado actual; y la puerta de reinicio, que decide si la información anterior y el estado actual deben combinarse (Zhang et al., 2019). La Ilustración 30 muestra el funcionamiento de una celda GRU:




Ilustración 30: Celda GRU (Mahjoub et al., 2022)

Las operaciones realizadas en cada celda son las siguientes:

- **Puerta de actualización:** $z_t = \sigma \cdot (W_z \cdot [h_{t-1}, x_t] + b_z)$
- **Puerta de reinicio:** $r_t = \sigma \cdot (W_r \cdot [h_{t-1}, x_t] + b_r)$
- **Nuevo contenido de memoria:** $\tilde{h}_t = \tanh(W_a \cdot [h_{t-1}, x_t] + b_a)$
- **Estado oculto:** $h_t = (1 - z_t) \cdot \tilde{h}_{t-1} + z_t \cdot \tilde{h}_t$

El funcionamiento es similar al descrito en la sección Red LSTM. Sin embargo, la red GRU posee algunas ventajas e inconvenientes frente a esta:

<i>Ventajas</i>	<i>Inconvenientes</i>
Menor complejidad computacional	Menor capacidad de memoria a largo plazo
Eficacia en secuencias más cortas	

Tabla 5: Ventajas e inconvenientes de la red GRU.

Al igual que en el caso de la red LSTM, se ha hecho uso de la función del mismo nombre que la red, del paquete Keras para su implementación.

Adicionalmente, se ofrece una guía de implementación de la red GRU y la red LSTM en Keras, en el Anexo IV: Preparación de datos para redes LSTM y GRU.

Optimización de hiperparámetros

Cabe destacar que todas las redes desarrolladas comparten los siguientes hiperparámetros a optimizar para el correcto funcionamiento de estas:

1. **Número de capas:** determina cuántas capas ocultas tiene la red. Las redes con más capas pueden capturar relaciones más complejas, pero también son más propensas al sobreajuste (*overfitting*) y son computacionalmente más intensivas.
2. **Número de neuronas por capa:** define cuántas neuronas hay en cada capa oculta. Más neuronas pueden aumentar la capacidad de la red para aprender patrones complejos, pero también aumentan el riesgo de sobreajuste y el coste computacional.
3. **Tasa de Aprendizaje:** afecta la magnitud de los ajustes hechos a los pesos y sesgos con cada actualización durante el entrenamiento. Una tasa de aprendizaje muy alta puede hacer que el entrenamiento sea inestable, mientras que una muy baja puede hacer que el entrenamiento sea muy lento y posiblemente se quede atascado en mínimos locales.
4. **Función de Activación:** define cómo se transforman las sumas ponderadas de las entradas en la salida de una neurona. La elección de la función de activación puede afectar la velocidad y la calidad del entrenamiento.
5. **Función de Pérdida o error:** es la función que mide el error entre las salidas predichas y las reales. Ya que el problema es de regresión, se ha elegido el error cuadrático medio para todas las redes:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Donde n representa el número de muestras, y_i el valor real de la muestra i de la variable a estimar y, \hat{y}_i el valor estimado de la variable de interés.

6. **Algoritmo de Optimización:** es el método utilizado para ajustar los pesos y sesgos en respuesta al gradiente de la función de pérdida. En el caso de los modelos desarrollados se ha utilizado Adam por su mejora de eficiencia, la posibilidad de incluir tasas de aprendizaje adaptadas, la corrección automática de los sesgos y los escasos requisitos de memoria asociados a este algoritmo.
7. **Tamaño del Lote (*Batch Size*):** es el número de muestras de entrenamiento utilizadas para calcular el gradiente de la función de error antes de actualizar los pesos. Un tamaño de lote más pequeño puede proporcionar una estimación más ruidosa del gradiente, lo que puede ayudar a evitar mínimos locales, mientras que un tamaño de lote más grande proporciona una estimación más precisa, pero es computacionalmente más costoso.
8. **Número de Épocas (*epochs*):** es el número de veces que el algoritmo de aprendizaje trabajará a través de todo el conjunto de datos de entrenamiento.
9. **Regularización:** técnicas utilizadas para prevenir el sobreajuste. En los modelos desarrollados, se ha optado por *Dropout* (Srivastava et al., 2014) técnica que modifica la arquitectura de la red durante el entrenamiento. Este método tiene su propio hiperparámetro asociado: la tasa de *dropout*.

En todos los casos, se ha utilizado el paquete Optuna (Akiba et al., 2019) de Python para la optimización de estos hiperparámetros. Los valores posibles de los hiperparámetros se muestran en la tabla siguiente:

Hiperparámetro	Rango de Valores
Número de capas	[1,5]
Número de neuronas por capa	[1,200]
Tasa de Aprendizaje	[0.00001,0.001]
Función de Activación (solo en MLP)	{ sigmoidea, ReLU, tanh }
Tamaño de <i>Batch</i>	{ 1,2,4,8,16, 32, 64, 128, 256,512 }
<i>Dropout</i>	[0,0.5]

Tabla 6: Rango de Hiperparámetros

5.5 VALIDEZ PREDICTIVA

Una vez identificados y ajustados los modelos seleccionados, es necesario analizar la precisión de cada uno de ellos. Para ello se utilizarán los siguientes indicadores sobre el conjunto de *test* de los datos, que tal y como se ha explicado anteriormente, representa el 20% de la serie temporal y no ha sido utilizado para entrenar ninguno de los modelos. Los indicadores son los siguientes:

- Error cuadrático medio (MSE): $MSE = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2$.
- Raíz cuadrada del error cuadrático medio (RMSE): $RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2}$.
- Error medio absoluto (MAE): $MAE = \frac{1}{n} \sum_{t=1}^T |y_t - \hat{y}_t|$.

Donde:

- T es el número de muestras temporales de la serie.
- y_t es valor real de la serie temporal en el instante de tiempo t .
- \hat{y}_t es el valor de la serie temporal predicho por los modelos en el instante de tiempo t .

Se priorizará el uso del MAE, ya que es menos sensible a valores atípicos y su interpretación es más sencilla y directa que la del MSE. Además, es el indicador más habitual encontrado en el análisis de la literatura existente sobre predicción eólica, ya que en la obtención del MAE todos los errores se penalizan de manera lineal. Esto se debe a que el MAE calcula el error absoluto, mientras que el MSE eleva al cuadrado el error, aumentando desproporcionadamente el impacto de los atípicos.

Como hemos visto en nuestro caso, es muy complicado eliminar completamente todos los valores atípicos, por lo que el MAE se establece como la medida de error principal.

Capítulo 6. RESULTADOS

En este capítulo, se incluirán los obtenidos de cada modelo y se compararán sus desempeños en la predicción de potencia eólica con un horizonte temporal de 1 a 9 horas. Como ya se ha comentado previamente, el conjunto de test donde se ha medido la validez predictiva de los modelos se corresponde con el 20% de los datos.

Excepto en los modelos puramente autorregresivos (persistencia y ARIMA), el procedimiento ha sido el siguiente:

1. Inicialmente se entrenan los modelos únicamente con las variables representadas por los datos de los sensores de la turbina, sin incluir los datos procedentes del modelo de predicciones meteorológicas. Se prueban tanto de forma individual, como las distintas combinaciones de estas, tanto con un componente autorregresivo, es decir, incluyendo los datos de la potencia eólica de periodos anteriores como variable de entrada, o sin él.
2. Tras esto, se realiza el mismo proceso, pero esta vez, incluyendo las variables de velocidad del viento procedentes de las predicciones del modelo meteorológico. Al igual que en el caso anterior, se comprueba el desempeño del modelo únicamente con una de estas variables, con combinaciones de estas variables y con combinaciones de estas variables con las variables procedentes de los sensores de la turbina.

El desempeño del modelo se analiza para horizontes temporales de nueve horas, que en las tablas a continuación, se indican de la siguiente manera:

[Nombre del indicador]_[Horizonte temporal]H

Por último, es importante destacar también, que para cada combinación de variables de entrada, el desempeño del modelo se ha comprobado variando el número de retardos horarios introducidos en cada iteración del entrenamiento. Los posibles valores para el número de retardos son: 1, 2, 3, 4, 5, 6, 12, 24 horas. En las tablas se destacarán los modelos que posean menor MAE con horizonte temporal de una hora.

6.1 MODELO DE PERSISTENCIA Y ARIMA

Se establecen como los modelos de referencia:

6.1.1 RMSE

Modelo	Características	Nº de Retardos	RMSE_1H	RMSE_2H	RMSE_3H	RMSE_4H	RMSE_5H	RMSE_6H	RMSE_7H	RMSE_8H	RMSE_9H
Persistencia	Autorregresivo	N/A	527.58	769.70	950.37	1108.44	1243.98	1363.59	1467.17	1556.18	1637.23
ARIMA	Autorregresivo	N/A	461.61	694.55	846.33	952.39	1044.07	1126.31	1193.88	1248.99	1307.36

Tabla 7: RMSE modelos de persistencia y ARIMA

En la tabla se observa algo lógico y que pasará en todos los modelos, a medida que aumenta el horizonte de predicción aumenta el error.

6.1.2 MAE

Modelo	Características	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	MAE_6H	MAE_7H	MAE_8H	MAE_9H
Persistencia	Autorregresivo	N/A	291.98	445.40	565.28	675.68	775.52	866.53	947.51	1017.38	1083.52
ARIMA	Autorregresivo	N/A	284.72	445.44	568.53	668.19	759.61	842.39	911.79	975.23	1039.54

Tabla 8: MAE modelos de persistencia y ARIMA

6.2 MODELO LSTM

Con el modelo LSTM, se han realizado pruebas con distintas combinaciones de variables. Inicialmente se ha incluido únicamente variables correspondientes a los sensores de la turbina, y a continuación variables procedentes de NWP (estas variables se han denominado W seguidas del

número de la capa del modelo NWP descrito anteriormente: W62, W63, W64). Adicionalmente, en este modelo se ha comprobado también el desempeño *stateful*, que tal y como se ha explicado previamente, no reinicia los estados de la red con cada lote del entrenamiento.

6.2.1 LSTM STATELESS

RMSE

V.Explicativas	Nº de Retardos	RMSE_1H	RMSE_2H	RMSE_3H	RMSE_4H	RMSE_5H	RMSE_6H	RMSE_7H	RMSE_8H	RMSE_9H
Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	427.97	638.01	789.08	908.34	1000.03	1081.28	1144.86	1192.49	1234.10
	2	431.39	640.13	788.45	907.85	998.93	1078.89	1144.39	1196.33	1242.34
	3	455.73	640.90	785.69	902.55	996.12	1085.11	1155.81	1209.79	1257.89
	4	469.71	649.41	786.18	899.58	991.27	1078.09	1147.87	1199.64	1242.92
	6	615.54	742.49	852.46	943.28	1023.35	1093.10	1145.48	1187.07	1220.26
	12	624.29	737.89	831.39	914.60	980.05	1046.79	1101.17	1145.47	1185.87
	24	645.66	891.64	1080.01	1219.63	1323.68	1419.10	1492.49	1543.18	1584.40
Viento Histórico	1	1265.30	1264.95	1264.73	1264.29	1264.23	1263.45	1263.37	1263.07	1262.48
	2	762.83	870.06	967.19	1046.07	1119.24	1164.68	1202.87	1240.59	1268.45
	3	547.28	720.62	855.07	964.36	1054.73	1132.14	1189.25	1230.41	1265.50
	4	527.29	697.02	823.82	934.52	1025.53	1107.33	1170.69	1213.58	1255.14
	6	569.05	734.47	856.47	959.13	1049.53	1131.02	1193.41	1240.11	1282.84
	12	928.60	1036.54	1132.60	1210.66	1280.40	1346.18	1393.55	1430.02	1459.12

	24	1823.00	1823.15	1815.70	1810.78	1823.71	1816.00	1831.13	1838.49	1834.72
Viento Histórico y Presión	1	772.14	929.51	1052.16	1142.21	1233.50	1320.51	1378.67	1427.70	1466.69
	2	578.53	748.90	872.01	977.97	1068.62	1142.86	1204.20	1246.42	1284.43
	3	580.34	733.90	855.89	964.98	1057.64	1133.96	1192.83	1241.13	1283.15
	4	574.97	709.34	821.05	914.24	995.40	1064.69	1121.35	1166.60	1205.61
	6	536.57	726.32	860.97	976.15	1072.39	1169.77	1240.33	1293.97	1343.45
	12	1868.63	1876.37	1871.18	1868.36	1868.69	1869.44	1866.87	1864.56	1864.46
	24	1874.58	1874.56	1871.79	1870.14	1870.37	1870.63	1871.25	1871.55	1871.71
Viento Histórico y Gen Speed	1	576.52	749.74	880.90	985.83	1070.46	1144.34	1200.70	1238.27	1275.74
	2	596.38	761.91	886.77	992.14	1081.66	1163.68	1225.62	1269.42	1307.00
	3	537.93	715.21	844.63	952.31	1041.18	1122.27	1187.83	1230.67	1272.86
	4	554.55	709.98	833.91	927.73	1009.20	1083.74	1138.52	1173.46	1209.33
	6	685.19	785.72	889.61	989.01	1071.66	1156.75	1210.84	1246.00	1279.28
	12	685.19	785.72	889.61	989.01	1071.67	1156.76	1210.84	1246.00	1279.29
	24	687.05	787.34	891.04	990.30	1072.85	1157.86	1211.89	1247.02	1280.28
Viento Histórico, Presión, Velocidad del Generador	1	663.76	808.10	923.88	1023.64	1110.60	1183.95	1240.37	1283.17	1331.39
	2	614.31	788.62	922.01	1033.95	1126.67	1208.21	1272.25	1322.88	1368.26
	3	630.39	772.56	886.54	989.22	1078.16	1160.98	1215.67	1252.89	1287.57
	4	549.70	700.54	821.67	930.27	1026.10	1111.62	1177.40	1224.11	1269.41
	6	945.73	1045.67	1133.67	1204.97	1285.10	1344.49	1392.49	1436.73	1469.96
	12	1196.91	1245.15	1287.59	1323.95	1361.36	1391.92	1415.33	1437.15	1454.79
	24	1877.13	1876.46	1873.04	1875.70	1868.29	1860.90	1856.22	1863.10	1864.24

	ICAI	ICADE	CIHS							
Viento Histórico y Potencia eólica	1	579.68	792.64	982.95	1100.00	1181.36	1241.84	1301.14	1326.84	1380.67
	2	523.16	760.69	927.14	1059.51	1170.91	1267.14	1339.59	1396.73	1448.18
	3	520.79	747.29	916.84	1044.48	1147.73	1228.76	1294.98	1344.49	1390.40
	4	592.08	732.74	852.09	953.76	1035.99	1108.82	1165.19	1214.49	1256.08
	6	511.80	702.62	839.81	948.85	1036.75	1114.82	1179.01	1228.64	1270.25
	12	1888.66	1893.95	1895.89	1893.25	1888.52	1877.68	1874.38	1863.30	1852.98
	24	572.74	754.99	896.36	998.93	1078.04	1149.63	1203.50	1253.19	1297.53
Viento Histórico, Presión, Velocidad del Generador, Potencia Eólica anterior y W63	1	601.60	770.04	909.25	1015.34	1128.65	1219.73	1281.98	1342.31	1376.97
	2	491.25	661.30	793.01	908.66	1003.84	1093.73	1165.54	1220.00	1270.28
	3	482.14	649.75	778.07	883.25	971.71	1051.44	1113.07	1159.04	1199.71
	4	592.05	736.26	857.07	957.68	1038.61	1113.03	1166.07	1210.80	1250.65
	6	468.00	653.70	800.06	925.03	1033.23	1126.95	1203.15	1263.25	1315.43
	12	1303.09	1302.42	1302.70	1302.51	1302.26	1301.89	1301.69	1301.48	1300.60
	24	1319.12	1319.13	1319.02	1318.89	1318.97	1319.10	1318.61	1318.60	1318.43
Viento Histórico, Presión, Velocidad del Generador, Potencia Eólica anterior y W62	1	527.62	726.08	874.85	991.88	1085.09	1167.30	1232.91	1282.45	1326.73
	2	715.35	904.94	1034.71	1147.46	1243.86	1330.49	1402.00	1459.76	1506.25
	3	436.83	632.33	781.01	910.18	1018.28	1119.13	1202.62	1267.12	1326.15
	4	457.71	659.67	811.11	933.07	1031.02	1120.48	1191.32	1247.17	1294.43
	6	457.70	659.66	811.10	933.06	1031.02	1120.48	1191.31	1247.17	1294.42
	12	457.69	659.65	811.10	933.06	1031.01	1120.48	1191.31	1247.16	1294.42
	24	457.68	659.65	811.09	933.05	1031.01	1120.47	1191.31	1247.16	1294.42
Viento Histórico, Presión, Velocidad del Generador y W64	1	578.90	771.35	926.02	1045.35	1135.70	1233.67	1290.24	1332.35	1392.04
	2	553.62	709.41	822.39	923.69	1006.08	1074.64	1131.20	1177.12	1219.88
	3	525.14	690.10	812.40	916.78	1009.60	1099.00	1170.35	1224.00	1272.24
	4	500.12	677.44	817.71	928.37	1021.23	1105.31	1171.26	1219.84	1263.46
	6	575.57	691.09	785.66	883.89	968.94	1051.86	1114.22	1160.16	1200.87
	12	497.34	644.56	755.22	856.76	945.80	1025.40	1088.17	1128.70	1164.73
	24	1707.35	1708.96	1701.64	1710.05	1706.48	1701.53	1691.20	1699.37	1709.74

	ICAI	ICADE	CIHS							
Viento Histórico y W64	1	475.35	678.74	833.06	954.13	1050.38	1137.13	1202.27	1243.61	1283.91
	2	492.96	665.57	792.89	903.24	995.14	1080.53	1146.75	1194.32	1233.96
	3	506.02	662.36	783.15	881.66	969.06	1050.53	1109.10	1149.28	1184.91
	4	493.69	706.51	858.76	984.18	1086.42	1179.86	1250.21	1294.25	1337.19
	6	492.23	668.94	813.11	934.52	1039.49	1129.19	1193.41	1240.28	1277.81
	12	1325.12	1325.94	1325.58	1325.49	1324.85	1325.35	1324.84	1324.58	1324.93
	24	1263.65	1263.37	1262.63	1263.05	1261.92	1261.92	1261.87	1261.77	1261.79
Viento Histórico y W63	1	450.29	656.76	811.51	939.38	1040.64	1130.96	1197.53	1245.68	1287.64
	2	628.40	764.75	869.15	953.25	1026.46	1080.66	1116.18	1149.92	1175.41
	3	1327.57	1326.78	1326.50	1327.51	1328.21	1328.87	1327.74	1327.25	1325.81
	4	465.93	655.38	789.28	909.82	1012.58	1102.69	1172.70	1219.01	1259.96
	6	493.13	675.63	818.27	935.10	1036.09	1125.13	1189.63	1238.22	1276.69
	12	546.26	723.64	862.07	973.20	1074.47	1156.98	1212.38	1258.71	1292.96
	24	951.18	977.61	1002.13	1022.60	1040.35	1056.16	1071.09	1087.34	1103.96
Viento Histórico y W62	1	478.14	680.17	827.64	943.58	1041.09	1130.19	1199.40	1245.48	1286.89
	2	458.57	653.70	799.03	917.60	1017.02	1101.55	1166.46	1213.15	1251.49
	3	455.48	663.42	811.98	934.33	1030.21	1121.26	1191.75	1235.60	1278.67
	4	467.91	658.00	799.34	921.14	1028.09	1123.05	1193.81	1241.44	1280.87
	6	476.34	677.60	823.41	946.25	1047.29	1142.03	1209.18	1250.34	1289.92
	12	496.05	661.93	789.63	906.41	1006.41	1101.87	1175.50	1222.32	1267.95
	24	561.31	711.03	826.24	917.58	994.10	1056.92	1102.68	1139.22	1167.20
Potencia Eólica, Viento Histórico y W64	1	450.94	644.36	795.02	912.25	999.46	1080.53	1146.50	1189.29	1233.14
	2	445.03	647.66	797.13	909.38	995.66	1068.64	1131.23	1169.18	1202.95
	3	444.45	664.20	825.38	948.67	1046.36	1134.49	1205.16	1259.09	1303.27
	4	435.39	630.40	780.62	903.49	1003.61	1089.62	1157.31	1208.19	1253.29
	6	470.16	628.91	758.60	867.99	953.77	1036.78	1103.49	1150.18	1190.15
	12	701.45	783.68	847.94	904.54	957.53	1004.77	1045.43	1077.57	1103.73
	24	469.72	649.78	784.15	901.36	989.85	1066.43	1122.47	1157.37	1185.99

Potencia Eólica, Viento Histórico y W63	1	441.83	625.45	763.47	877.45	969.21	1052.73	1117.29	1160.26	1203.13
	2	463.49	644.59	784.58	900.75	995.04	1077.69	1144.83	1190.31	1226.37
	3	507.85	659.78	779.40	878.96	956.18	1026.20	1081.35	1118.38	1147.98
	4	534.66	730.21	875.65	987.80	1083.82	1169.70	1242.81	1295.37	1339.06
	6	428.18	636.00	791.62	920.40	1019.68	1113.25	1185.87	1238.76	1284.28
	12	460.74	664.07	818.99	943.85	1043.22	1133.60	1209.02	1264.35	1310.89
	24	548.75	701.13	811.80	898.76	971.78	1037.14	1087.84	1124.96	1154.20
Potencia Eólica, Viento Histórico y W62	1	557.71	708.33	824.63	917.44	991.65	1058.07	1111.15	1149.88	1180.68
	2	521.10	663.68	779.37	876.74	948.28	1017.83	1076.71	1116.23	1148.70
	3	520.81	678.04	799.99	903.70	979.06	1050.06	1106.26	1140.49	1170.41
	4	525.51	666.53	784.77	883.00	952.00	1027.72	1087.39	1130.78	1168.26
	6	449.95	639.99	786.49	900.59	992.65	1077.62	1145.90	1194.56	1232.90
	12	448.41	646.79	805.95	916.06	999.25	1074.46	1130.63	1166.34	1198.64
	24	542.65	708.54	826.58	916.59	990.32	1055.43	1106.39	1142.09	1171.31

Tabla 9: RMSE modelos LSTM stateless

MAE

V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	MAE_6H	MAE_7H	MAE_8H	MAE_9H
Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	265.38	409.28	528.85	626.30	711.85	788.24	854.43	915.28	965.37
	2	270.55	413.69	531.98	632.13	719.62	793.53	863.53	929.24	984.44
	3	300.21	428.01	547.39	646.00	738.08	814.97	887.50	957.64	1015.25
	4	321.92	445.29	556.48	647.77	731.47	805.16	873.79	938.29	986.14
	6	450.46	558.54	650.91	733.69	803.83	867.51	919.25	967.74	1004.73
	12	460.87	533.57	596.51	659.14	714.51	761.14	800.71	840.04	875.15
	24	460.87	533.57	596.51	659.14	714.51	761.14	800.71	840.04	875.15
Viento Histórico	1	926.97	927.10	926.71	925.91	924.51	923.81	922.18	921.71	921.80
	2	496.82	578.94	666.16	743.75	815.24	863.02	912.67	961.21	998.36
	3	356.34	471.94	581.58	676.68	761.87	828.77	889.77	947.33	987.14

	4	331.19	434.64	533.12	625.39	708.90	789.52	857.64	915.97	963.55
	6	361.74	465.89	563.37	653.62	744.40	825.42	895.22	959.39	1012.08
	12	739.73	833.83	927.22	992.35	1051.04	1107.48	1153.00	1199.31	1242.70
	24	1661.35	1661.47	1653.70	1648.67	1662.19	1654.31	1670.05	1677.84	1674.08
Viento Histórico y Presión	1	531.30	675.90	802.80	887.57	978.83	1070.47	1137.89	1202.06	1248.88
	2	399.19	525.30	627.31	724.30	808.86	878.76	944.21	1001.37	1050.57
	3	348.31	475.87	588.29	685.00	776.03	852.56	923.33	981.58	1030.20
	4	397.62	478.56	557.88	631.00	711.30	780.35	838.76	894.96	941.11
	6	319.53	454.84	576.85	685.31	779.80	880.94	965.19	1037.68	1094.72
	12	1708.39	1716.37	1710.94	1708.07	1708.60	1709.48	1706.92	1704.71	1704.73
	24	1714.54	1714.50	1711.58	1709.92	1710.35	1710.72	1711.46	1711.96	1712.25
Viento Histórico y Gen Speed	1	346.71	466.53	573.60	660.92	738.24	808.59	872.17	928.47	976.83
	2	376.78	494.44	603.76	697.67	779.88	853.51	923.52	983.60	1028.11
	3	323.64	445.55	556.80	650.73	734.97	808.89	880.13	941.50	991.67
	4	363.73	455.73	541.64	613.88	691.42	760.76	819.95	863.99	908.08
	6	502.84	578.00	657.85	737.98	812.21	883.61	941.56	982.83	1023.57
	12	512.84	588.00	667.85	747.98	822.21	893.61	951.56	992.83	1033.57
	24	522.84	598.00	677.85	757.98	832.21	903.61	961.56	1002.83	1043.57
Viento Histórico, Presión, Velocidad del Generador	1	419.57	568.16	691.89	786.04	864.12	953.81	1009.66	1089.30	1149.31
	2	382.63	504.62	628.39	733.44	830.14	914.62	990.14	1056.58	1114.63
	3	425.19	505.43	591.86	663.62	743.44	830.96	891.34	942.83	992.18
	4	364.63	444.05	532.56	621.10	714.40	803.05	878.54	942.36	1001.74
	6	785.00	875.05	957.87	1025.25	1104.40	1157.11	1204.96	1247.41	1282.77
	12	933.41	937.55	956.31	993.89	1029.98	1066.94	1102.20	1135.48	1164.61
	24	1717.01	1716.35	1712.75	1715.64	1708.08	1700.56	1695.90	1703.16	1704.41
Viento Histórico y Potencia eólica	1	293.52	536.80	702.99	801.76	881.29	945.24	1017.36	1060.12	1122.64
	2	334.96	504.79	641.84	749.34	847.91	926.92	999.08	1068.51	1122.93
	3	330.37	486.48	621.15	725.72	821.57	893.13	963.07	1027.30	1083.77
	4	415.26	510.51	617.50	699.08	778.50	848.26	906.55	963.78	1015.37
	6	369.56	499.97	611.18	703.45	789.07	864.29	928.45	987.86	1036.12
	12	1729.10	1734.55	1736.50	1733.82	1729.12	1718.02	1714.70	1703.41	1692.90
	24	424.87	554.54	665.48	753.92	832.97	899.50	960.68	1016.49	1063.19

Viento Histórico, Presión, Velocidad del Generador, Potencia Eólica anterior y W63	1	353.35	479.31	592.47	687.03	814.02	914.83	990.76	1076.12	1119.21
	2	310.12	414.32	518.26	617.53	711.28	796.88	880.60	955.89	1020.11
	3	301.31	414.80	524.47	612.84	698.21	771.25	834.74	892.21	941.42
	4	433.07	542.36	644.32	721.81	796.38	867.69	922.41	972.26	1014.62
	6	297.18	428.77	553.04	663.50	767.88	860.34	941.08	1016.72	1077.86
	12	895.86	895.93	895.74	895.33	894.26	893.52	892.87	892.11	891.89
	24	892.17	891.97	892.07	891.54	890.83	890.14	889.47	888.71	888.47
Viento Histórico, Presión, Velocidad del Generador, Potencia Eólica anterior y W62	1	366.41	492.77	610.56	703.28	791.87	871.87	945.34	1008.24	1061.95
	2	511.81	625.16	722.27	810.86	891.71	969.12	1047.24	1123.14	1178.65
	3	273.68	398.27	520.52	635.16	739.69	829.50	918.41	1002.41	1070.71
	4	294.52	424.12	543.48	648.76	741.08	825.04	902.82	973.59	1029.65
	6	289.52	419.12	538.48	643.76	736.08	820.04	897.82	968.59	1024.65
	12	284.52	414.12	533.48	638.76	731.08	815.04	892.82	963.59	1019.65
	24	279.52	409.12	528.48	633.76	726.08	810.04	887.82	958.59	1014.65
Viento Histórico, Presión, Velocidad del Generador y W64	1	370.54	512.39	650.79	755.56	847.38	952.55	1018.49	1073.91	1143.79
	2	354.17	461.37	551.34	636.39	718.02	784.85	850.04	905.78	961.41
	3	343.55	418.92	510.94	600.90	698.92	788.88	872.44	950.83	1013.78
	4	331.43	432.71	542.01	644.05	734.66	813.36	885.10	949.62	1002.89
	6	418.89	452.30	512.17	583.31	661.73	739.25	801.47	861.13	915.77
	12	318.51	415.95	494.43	568.57	639.46	706.70	768.14	816.61	859.07
	24	1542.24	1543.86	1536.18	1544.92	1541.31	1536.30	1525.73	1534.35	1545.11
Viento Histórico y W64	1	266.28	405.33	500.12	576.28	647.80	720.04	770.73	798.48	831.56
	2	306.99	406.94	486.35	554.23	622.75	690.44	743.53	777.04	809.93
	3	328.14	432.32	512.61	571.36	633.76	693.16	736.61	763.93	788.72
	4	293.91	412.51	512.18	591.96	664.20	739.58	797.04	829.84	867.61
	6	302.11	406.03	494.07	571.80	642.25	715.23	760.77	796.17	831.78
	12	890.37	890.33	890.53	890.33	889.54	888.91	888.50	887.77	887.30

	24	934.71	933.48	933.82	930.14	930.95	929.06	926.59	925.16	924.58
Viento Histórico y W63	1	269.88	390.12	485.87	570.23	645.39	714.95	765.55	798.34	834.03
	2	395.85	489.10	561.05	622.90	678.96	717.88	745.87	774.81	798.48
	3	889.01	889.49	889.86	889.63	889.05	888.27	887.91	887.39	886.97
	4	278.84	390.09	478.83	555.26	629.25	703.99	758.87	789.89	823.04
	6	302.19	409.50	495.40	569.68	642.80	711.52	758.21	791.19	824.79
	12	309.79	422.79	508.72	590.41	667.19	735.04	778.73	815.00	851.43
	24	702.62	720.26	739.30	752.04	768.07	777.98	792.16	808.16	822.86
Viento Histórico y W62	1	285.03	407.41	501.06	570.12	641.04	710.69	764.47	791.90	823.50
	2	275.77	399.07	491.97	568.53	642.67	708.96	755.76	788.70	825.38
	3	270.23	393.98	489.37	563.72	637.82	711.15	769.07	799.81	836.46
	4	291.04	397.55	489.26	566.76	642.10	719.35	772.27	808.75	843.33
	6	284.53	398.28	494.27	570.64	642.38	716.64	769.45	804.26	836.91
	12	317.66	409.04	488.38	563.07	630.70	700.72	757.51	790.39	824.64
	24	365.01	458.08	535.22	599.54	658.55	708.14	742.77	769.68	791.78
Potencia Eólica, Viento Histórico y W64	1	282.98	395.90	488.95	563.29	634.07	699.46	754.45	786.04	828.75
	2	285.62	400.69	501.38	573.74	643.80	699.00	748.73	777.87	807.91
	3	258.78	388.47	489.97	569.36	647.99	718.43	772.59	814.14	857.88
	4	276.00	400.11	495.64	572.88	651.29	719.28	770.25	812.16	855.29
	6	283.32	384.12	471.68	540.98	610.76	678.34	730.64	768.86	805.48
	12	418.47	493.48	550.06	593.12	639.48	680.33	709.88	733.88	760.87
	24	296.45	401.52	492.11	570.00	636.51	697.75	743.61	769.69	793.63

Potencia Eólica, Viento Histórico y W63	1	272.93	386.92	482.45	561.52	632.56	698.04	748.98	782.88	824.16
	2	281.11	393.44	485.38	555.26	626.86	693.72	746.80	781.46	813.91
	3	308.41	412.08	496.01	561.98	624.56	682.90	728.81	762.43	793.47
	4	320.97	435.51	528.45	608.24	675.26	746.07	802.70	848.57	888.63
	6	262.43	386.87	488.30	567.86	645.05	716.88	773.12	817.45	858.66
	12	273.73	398.81	496.34	575.21	646.58	721.45	780.31	826.43	863.44
	24	328.75	430.46	509.76	574.05	629.36	680.10	715.07	742.22	769.24
Potencia Eólica, Viento Histórico y W62	1	342.04	432.26	509.13	572.10	624.26	677.91	719.00	747.87	778.55
	2	305.66	400.21	481.30	546.72	602.71	661.05	709.07	740.28	772.64
	3	323.19	412.82	496.10	562.67	617.70	675.12	721.51	745.69	777.38
	4	315.11	412.10	497.16	563.47	623.14	682.63	729.49	765.33	798.14
	6	277.10	388.30	481.74	552.49	625.42	690.41	739.82	772.33	808.90
	12	277.05	388.89	488.14	557.27	622.83	685.75	731.44	755.88	786.13
	24	341.37	442.31	514.15	577.05	635.20	687.77	723.02	748.30	774.86

Tabla 10: MAE modelos LSTM stateless

6.2.2 LSTM STATEFUL

En este caso, únicamente se han comprobado las mejores 5 combinaciones de variables del caso *stateless*:

RMSE

V.Explicativas	Nº de Retardos	RMSE_1H	RMSE_2H	RMSE_3H	RMSE_4H	RMSE_5H	RMSE_6H	RMSE_7H	RMSE_8H	RMSE_9H
Potencia Eólica, Viento Histórico y W64	3	487.22	651.86	780.72	884.68	961.64	1031.27	1086.48	1122.58	1154.14
Potencia Eólica, Viento Histórico y W63	6	469.72	649.78	784.15	901.36	989.85	1066.43	1122.47	1157.37	1185.99

Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	470.16	628.91	758.60	867.99	953.77	1036.78	1103.49	1150.18	1190.15
Viento Histórico y W64	1	463.49	644.59	784.58	900.75	995.04	1077.69	1144.83	1190.31	1226.37
Viento Histórico y W63	1	507.85	659.78	779.40	878.96	956.18	1026.20	1081.35	1118.38	1147.98
Viento Histórico y W62	3	534.66	730.21	875.65	987.80	1083.82	1169.70	1242.81	1295.37	1339.06

Tabla 11: RMSE modelos LSTM stateful

MAE

V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	MAE_6H	MAE_7H	MAE_8H	MAE_9H
Potencia Eólica, Viento Histórico y W64	3	300.21	401.93	492.07	557.36	614.93	669.79	710.64	736.06	763.19
Potencia Eólica, Viento Histórico y W63	6	296.45	401.52	492.11	570.00	636.51	697.75	743.61	769.69	793.63
Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	283.32	384.12	471.68	540.98	610.76	678.34	730.64	768.86	805.48
Viento Histórico y W64	1	281.11	393.44	485.38	555.26	626.86	693.72	746.80	781.46	813.91
Viento Histórico y W63	1	308.41	412.08	496.01	561.98	624.56	682.90	728.81	762.43	793.47
Viento Histórico y W62	3	320.97	435.51	528.45	608.24	675.26	746.07	802.70	848.57	888.63

Tabla 12: MAE modelos LSTM stateful

6.3 GRU

De nuevo, en este caso, únicamente se han comprobado las mejores 5 combinaciones de variables del caso LSTM *stateless*:

6.3.1 RMSE

V.Explicativas	Nº de Retardos	RMSE_1H	RMSE_2H	RMSE_3H	RMSE_4H	RMSE_5H	RMSE_6H	RMSE_7H	RMSE_8H	RMSE_9H
Potencia Eólica, Viento Histórico y W64	3	403.51	622.39	788.37	917.86	1014.00	1106.89	1178.16	1230.40	1272.03
Potencia Eólica, Viento Histórico y W63	6	470.01	650.30	782.94	886.32	965.95	1037.42	1095.31	1132.73	1162.73
Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	455.80	648.87	789.97	894.21	971.97	1038.78	1089.93	1124.92	1154.33
Viento Histórico y W64	1	886.97	925.36	963.35	1000.23	1034.29	1066.12	1092.82	1114.10	1133.73
Viento Histórico y W63	1	1093.99	1114.72	1137.61	1158.95	1179.25	1198.04	1215.51	1226.18	1236.73
Viento Histórico y W62	3	772.74	856.97	932.41	1001.30	1054.80	1106.87	1144.58	1170.07	1190.85

Tabla 13: RMSE modelos GRU

6.3.2 MAE

V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	MAE_6H	MAE_7H	MAE_8H	MAE_9H
Potencia Eólica, Viento Histórico y W64	3	235.31	363.56	466.41	546.04	620.02	693.33	750.90	788.85	823.60
Potencia Eólica, Viento Histórico y W63	6	296.88	404.02	493.33	559.15	624.11	677.92	718.37	749.63	782.58
Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	276.82	393.94	485.10	555.43	618.25	672.42	713.10	741.57	769.54
Viento Histórico y W64	1	546.84	578.67	610.01	641.82	670.98	696.94	719.19	737.67	753.18
Viento Histórico y W63	1	712.18	722.30	735.89	750.52	763.80	776.85	787.94	794.36	801.21
Viento Histórico y W62	3	488.25	531.76	577.29	624.29	664.07	703.88	732.62	754.24	772.65

Tabla 14: MAE modelos GRU

6.4 MLP

Se ha llevado a cabo la misma forma de proceder.

6.4.1 RMSE

V.Explicativas	Nº de Retardos	RMSE_1H	RMSE_2H	RMSE_3H	RMSE_4H	RMSE_5H	RMSE_6H	RMSE_7H	RMSE_8H	RMSE_9H
Potencia Eólica, Viento Histórico y W64	3	414.21	614.63	780.63	913.45	1010.13	1097.27	1173.69	1228.40	1275.17
Potencia Eólica, Viento Histórico y W63	6	415.09	620.62	787.03	916.10	1015.22	1107.57	1178.55	1231.51	1273.40
Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	422.66	646.83	801.78	920.01	1003.43	1088.63	1141.81	1188.65	1219.36
Viento Histórico y W64	1	444.02	657.64	810.55	932.07	1025.92	1111.86	1176.04	1217.90	1258.53
Viento Histórico y W63	1	437.76	637.99	788.64	909.76	1001.62	1091.44	1157.10	1200.83	1243.89
Viento Histórico y W62	3	431.15	600.30	737.46	849.21	936.00	1019.08	1081.06	1121.62	1161.96

Tabla 15: RMSE modelos MLP

6.4.2 MAE

V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	MAE_6H	MAE_7H	MAE_8H	MAE_9H
Potencia Eólica, Viento Histórico y W64	3	261.82	366.05	470.09	554.35	622.95	688.29	746.67	788.48	825.88
Potencia Eólica, Viento Histórico y W63	6	265.30	364.76	469.08	549.79	626.67	701.63	754.82	796.38	1273.40
Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	243.97	387.47	485.30	566.00	624.75	692.40	735.76	767.53	1219.36
Viento Histórico y W64	1	260.31	383.28	484.29	564.43	636.51	705.09	756.97	787.44	1258.53
Viento Histórico y W63	1	260.88	382.58	484.93	564.37	636.73	702.88	751.61	780.64	1243.89

Viento Histórico y W62	3	266.59	368.57	468.51	540.82	608.50	669.55	717.15	735.72	1161.96
------------------------	---	--------	--------	--------	--------	--------	--------	--------	--------	---------

Tabla 16: MAE modelos MLP

6.5 VISIÓN GENERAL

A modo de resumen, se ofrecen a continuación la tabla con los diez mejores modelos según su MAE a una hora:

Modelo	V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	MAE_6H	MAE_7H	MAE_8H	MAE_9H
GRU	Potencia Eólica, Viento Histórico y W64	3	235.31	363.56	466.41	546.04	620.02	693.33	750.90	788.85	823.60
MLP	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	243.97	387.47	485.30	566.00	624.75	692.40	735.76	767.53	1219.36
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W64	3	258.78	388.47	489.97	569.36	647.99	718.43	772.59	814.14	857.88
MLP	Viento Histórico y W64	1	260.31	383.28	484.29	564.43	636.51	705.09	756.97	787.44	1258.53
MLP	Viento Histórico y W63	1	260.88	382.58	484.93	564.37	636.73	702.88	751.61	780.64	1243.89
MLP	Potencia Eólica, Viento Histórico y W64	3	261.82	366.05	470.09	554.35	622.95	688.29	746.67	788.48	825.88
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W63	6	262.43	386.87	488.30	567.86	645.05	716.88	773.12	817.45	858.66
MLP	Potencia Eólica, Viento Histórico y W63	6	265.30	364.76	469.08	549.79	626.67	701.63	754.82	796.38	1273.40
LSTM Stateless	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	265.38	409.28	528.85	626.30	711.85	788.24	854.43	915.28	965.37
LSTM Stateless	Viento Histórico y W64	1	266.28	405.33	500.12	576.28	647.80	720.04	770.73	798.48	831.56

Tabla 17: Mejores modelos según MAE a 1 hora

También se ofrece a continuación, una tabla de los 10 modelos que de media en los 9 horizontes temporales comenten menos error:

Modelo	V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	MAE_6H	MAE_7H	MAE_8H	MAE_9H	Media
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W62	2	305.66	400.21	481.30	546.72	602.71	661.05	709.07	740.28	772.64	579.96
GRU	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	276.82	393.94	485.10	555.43	618.25	672.42	713.10	741.57	769.54	580.69
LSTM Stateful	Potencia Eólica, Viento Histórico y W64	3	300.21	401.93	492.07	557.36	614.93	669.79	710.64	736.06	763.19	582.91
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W64	6	283.32	384.12	471.68	540.98	610.76	678.34	730.64	768.86	805.48	586.02
LSTM Statefull	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	283.32	384.12	471.68	540.98	610.76	678.34	730.64	768.86	805.48	586.02
GRU	Potencia Eólica, Viento Histórico y W64	3	235.31	363.56	466.41	546.04	620.02	693.33	750.90	788.85	823.60	587.56
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W62	12	277.05	388.89	488.14	557.27	622.83	685.75	731.44	755.88	786.13	588.15
GRU	Potencia Eólica, Viento Histórico y W63	6	296.88	404.02	493.33	559.15	624.11	677.92	718.37	749.63	782.58	589.55
MLP	Potencia Eólica, Viento Histórico y W64	3	261.82	366.05	470.09	554.35	622.95	688.29	746.67	788.48	825.88	591.62
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W62	3	323.19	412.82	496.10	562.67	617.70	675.12	721.51	745.69	777.38	592.46

Tabla 18: modelos de media con un horizonte de 9 horas

Por último, teniendo en cuenta que entre la primera y la segunda sesión del mercado intradiario hay 3 horas y que entre el resto hay 5 horas, se incluyen a continuación los 10 mejores modelos que de media tienen menos error con un horizonte temporal de 3 y 5 horas respectivamente:

Modelo	V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	Media
GRU	Potencia Eólica, Viento Histórico y W64	3	235.31	363.56	466.41	355.10
MLP	Potencia Eólica, Viento Histórico y W64	3	261.82	366.05	470.09	365.99
MLP	Potencia Eólica, Viento Histórico y W63	6	265.30	364.76	469.08	366.38
MLP	Viento Histórico y W62	3	266.59	368.57	468.51	367.89
MLP	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	243.97	387.47	485.30	372.25
MLP	Viento Histórico y W64	1	260.31	383.28	484.29	375.96
MLP	Viento Histórico y W63	1	260.88	382.58	484.93	376.13
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W64	3	258.78	388.47	489.97	379.07
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W63	6	262.43	386.87	488.30	379.20
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W64	6	283.32	384.12	471.68	379.71

Tabla 19: Mejores modelos de media con un horizonte de 3 horas

Model	V.Explicativas	Nº de Retardos	MAE_1H	MAE_2H	MAE_3H	MAE_4H	MAE_5H	Media
GRU	Potencia Eólica, Viento Histórico y W64	3	235.31	363.56	466.41	546.04	620.02	446.27
MLP	Viento Histórico y W62	3	266.59	368.57	468.51	540.82	608.50	450.60
MLP	Potencia Eólica, Viento Histórico y W64	3	261.82	366.05	470.09	554.35	622.95	455.05
MLP	Potencia Eólica, Viento Histórico y W63	6	265.30	364.76	469.08	549.79	626.67	455.12
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W64	6	283.32	384.12	471.68	540.98	610.76	458.17
LSTM Stateful	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	283.32	384.12	471.68	540.98	610.76	458.17
MLP	Viento Histórico, Presión, Velocidad del Generador y Potencia Eólica anterior	1	243.97	387.47	485.30	566.00	624.75	461.50
LSTM Stateless	Potencia Eólica anterior, Viento Histórico y W62	6	277.10	388.30	481.74	552.49	625.42	465.01

MLP	Viento Histórico y W64	1	260.31	383.28	484.29	564.43	636.51	465.77
MLP	Viento Histórico y W63	1	260.88	382.58	484.93	564.37	636.73	465.90

Tabla 20: Mejores modelos con un horizonte de 5 horas

Capítulo 7. CONCLUSIONES

Tras haber realizado un estudio exhaustivo del parque, las variables significativas para la producción eólica y los distintos modelos seleccionados, se han alcanzado las siguientes conclusiones:

1. **Cualquiera de los modelos: MLP, GRU, y LSTM supera la capacidad predictiva de los dos modelos de referencia seleccionados:** persistencia y ARIMA. Esta se hace evidente al observar las tablas resúmenes que recogen el desempeño de los mejores modelos con un horizonte de una hora, tres horas, 5 horas y 9 horas. Los modelos ARIMA y de persistencia no se encuentran en ningún caso entre los 10 mejores.
2. **La inclusión de las predicciones meteorológicas procedentes de los modelos NWP han mejorado el desempeño de los modelos.** En las tablas resúmenes de los diez mejores modelos para cada horizonte temporal, predominan los modelos con combinaciones de variables que incluyen estas predicciones, esto ocurre en todos los horizontes temporales.
3. **De cara a operar en el mercado intradiario continuo, destacan el modelo GRU entrenado con las variables: Potencia Eólica, Viento Histórico y W64.** Este modelo tiene la menor media de error en horizontes temporales de 1, 3 y 5 horas.
4. **Para operar en el mercado intradiario y evitar correcciones en cada una de las sesiones, el modelo LSTM entrenado con las variables: Potencia Eólica anterior, Viento Histórico y W62.** Este modelo es el que menor media de error tiene para el horizonte temporal de 9 horas.
5. **Los modelos LSTM stateful no son adecuados para la predicción de la potencia eólica,** pese a que intuitivamente pudieran parecer los más adecuados para la predicción de la serie temporal, solo aparecen 3 veces entre los diez mejores modelos para los diferentes horizontes temporales (2 veces en horizontes de 9 horas, y 1 vez en horizontes de 5 horas). Considerando esto, y su elevado coste computacional, no representan la mejor opción.

-
6. **Las redes MLP ofrecen una alternativa simple, pero de calidad.** Estos modelos se encuentran entre los mejores 10 modelos para distintos horizontes temporales, en 17 ocasiones. En ninguna de ellas son los mejores, pero su simplicidad y bajo coste computacional pueden convertirlos en una opción deseable para operar en el mercado intradiario.

Teniendo estas conclusiones en consideración, se han alcanzado el principal objetivo de la motivación del trabajo: ofrecer un modelo adecuado para predecir la potencia eólica de cara a un uso correctivo de las ofertas de los generados en el mercado intradiario.

Como trabajo futuro, se propone la búsqueda de modelos, bien sea a partir del mejor modelo GRU ofrecido tengan buen desempeño para el mercado intradiario continuo, donde los horizontes de predicción son mucho menores.

Capítulo 8. REFERENCIAS

1. *About RAVE - RAVE: Research at Alpha Ventus.* (s. f.). <https://rave-offshore.de/en/about-rave.html>
2. Aggarwal, C. C. (2018). *Neural Networks and Deep Learning: A textbook.*
<https://link.springer.com/content/pdf/10.1007/978-3-319-94463-0.pdf>
3. Ahrens, C. D., & Henson, R. (2015). *Meteorology today.* Cengage Learning.
4. Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). OpTUNA: a next-generation Hyperparameter Optimization Framework. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1907.10902>
5. B. Bailey, M. Brower, y J. Zack, "Short-term wind forecasting: development and application of a mesoscale model," Proceedings of the European Wind Energy Conference, EWEC'99, Nice, France: 1999, págs. 1062-1095.
6. B. Bilal et al., "Wind turbine power output prediction model design based on artificial neural networks and climatic spatiotemporal data," 2018 IEEE International Conference on Industrial Technology (ICIT), Lyon, France, 2018, pp. 1085-1092, doi: 10.1109/ICIT.2018.8352329.
7. Box, G. E. P., & Jenkins, G. M. (1972). Time series analysis forecasting and control. *Econometrica*, 40(5), 970. <https://doi.org/10.2307/1912100>
8. Box, G.E.P., Jenkins, G.M. and Reinsel, G.C. (1994) Time Series Analysis; Forecasting and Control. 3rd Edition, Prentice Hall, Englewood Cliff, New Jersey.
9. Castellani, F., Astolfi, D., Mana, M., Burlando, M., Meißner, C., & Piccioni, E. (2016). Wind Power Forecasting Techniques in complex Terrain: ANN vs.

ANN-CFD Hybrid Approach. *Journal of physics*, 753, 082002.

<https://doi.org/10.1088/1742-6596/753/8/082002>

10. Chen, Tianqi & Guestrin, Carlos. (2016). XGBoost: A Scalable Tree Boosting System. 785-794. 10.1145/2939672.2939785.
11. Cho, K., Van Merriënboer, B., Gülçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1406.1078>
12. Chollet, F. (2015) keras, GitHub. <https://github.com/fchollet/keras>
13. *Country rankings*. (s.f.). <https://www.irena.org/Data/View-data-by-topic/Capacity-and-Generation/Country-Rankings>
14. Curry, H. B. (1944). The method of steepest descent for non-linear minimization problems. *Quarterly of Applied Mathematics*, 2(3), 258-261.
<https://doi.org/10.1090/qam/10667>
15. *Data - RAVE: Research at Alpha Ventus*. (s. f.). <https://rave-offshore.de/en/data.html>
16. De Giorgi, M. G., Ficarella, A., & Tarantino, M. (2011). Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods. *Energy*, 36(7), 3968-3978.
<https://doi.org/10.1016/j.energy.2011.05.006>
17. Demolli, H., Dokuz, A. Ş., Ecemiş, A., & Gökçek, M. (2019). Wind power forecasting based on daily wind speed data using machine learning algorithms. *Energy Conversion and Management*, 198, 111823.
<https://doi.org/10.1016/j.enconman.2019.111823>

18. Deng, X., Shao, H., Hu, C., Jiang, D., & Jiang, Y. (2020). Wind power Forecasting methods Based on Deep Learning: A survey. *Cmes-computer Modeling in Engineering & Sciences*, 122(1), 273-301.
<https://doi.org/10.32604/cmes.2020.08768>
19. Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427. <https://doi.org/10.2307/2286348>
20. Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A., & Vapnik, V. (1996). Support vector regression machines. *Neural Information Processing Systems*, 9, 155-161. <https://papers.nips.cc/paper/1238-support-vector-regression-machines.pdf>
21. ENEL. (s. f.). *Aerogenerador*. Enel Green Power.
<https://www.enelgreenpower.com/es/learning-hub/energias-renovables/energia-eolica/aerogenerador>
22. Erdem, E., & Shi, J. (2011). ARMA based approaches for forecasting the tuple of wind speed and direction. *Applied Energy*, 88(4), 1405-1414.
<https://doi.org/10.1016/j.apenergy.2010.10.031>
23. Foley, A., Leahy, P., Marvuglia, A., & McKeogh, E. (2012). Current methods and advances in forecasting of wind power generation. *Renewable Energy*, 37(1), 1-8. <https://doi.org/10.1016/j.renene.2011.05.033>
24. *FLORIS Wake Modeling & Wind Farm Controls — FLORIS*. (s. f.).
<https://nrel.github.io/floris/intro.html>
25. Fu, Y., Hu, W., Tang, M., Yu, R., & Liu, B. (2018). Multi-step Ahead Wind Power Forecasting Based on Recurrent Neural Networks. *IEEE*.
<https://doi.org/10.1109/appeec.2018.8566471>

-
26. *Generation*. (s. f.). <http://www.ercot.com/gridinfo/generation>
27. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
28. Goyal, P., Pandey, S., & Jain, K. (2018). Unfolding recurrent neural networks. En *Apress eBooks* (pp. 119-168). https://doi.org/10.1007/978-1-4842-3685-7_3
29. Hanifi, S., Liu, X., Lin, Z., & Lotfian, S. (2020). A Critical Review of Wind Power Forecasting Methods—Past, Present and Future. *Energies*, 13(15), 3764. <https://doi.org/10.3390/en13153764>
30. Hanifi, S., Lotfian, S., Zare-Behtash, H., & Cammarano, A. (2022). Offshore Wind Power Forecasting—A new hyperparameter Optimisation algorithm for deep learning models. *Energies*, 15(19), 6919. <https://doi.org/10.3390/en15196919>
31. Hanifi, S., Zare-Behtash, H., Cammarano, A., & Lotfian, S. (2023). Offshore wind power forecasting based on WPD and optimised deep learning methods. *Renewable Energy*, 218, 119241. <https://doi.org/10.1016/j.renene.2023.119241>
32. Heinermann, J., & Krämer, O. (2016). Machine learning ensembles for wind power prediction. *Renewable Energy*, 89, 671-679. <https://doi.org/10.1016/j.renene.2015.11.073>
33. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
34. Iberdrola. (2017, 12 diciembre). *Wind, the best commitment to our future*. Iberdrola. <https://www.iberdrola.com/sustainability/wind-power-evolution-europe>
35. I. Marti, T.S. Nielsen, H. Madsen, J. Navarro, A. Roldan, D. Cabezón, y C. Barquero (2001). *Prediction Models in Complex Terrain, Proceedings of the European Wind Energy Conference*, Copenhagen, Denmark, págs. 875- 878.

36. I. Marti, D. Cabezón, J. Villanueva, M. Sanisidro, Y. Loureiro, E. Cantero, y J. Sanz (2001). *LocalPred and RegioPred. Advanced tools for wind energy prediction in complex terrain.*
37. Jafarian, M., & Ranjbar, A. M. (2010). Fuzzy modeling techniques and artificial neural networks to estimate annual energy output of a wind turbine. *Renewable Energy*, 35(9), 2008-2014. <https://doi.org/10.1016/j.renene.2010.02.001>
38. J.W. Zack, M.C. Brower, y B.H. Bailey (2000). *Validating of the Forewind model in wind forecasting applications*, Talk on the EUWEC Special Topic Conference Wind Power for the 21st Century, Kassel, Germany.
39. J. Zeng and W. Qiao, "Support vector machine-based short-term wind power forecasting," 2011 IEEE/PES Power Systems Conference and Exposition, Phoenix, AZ, USA, 2011, pp. 1-8, doi: 10.1109/PSCE.2011.5772573.
40. J. Zhang, J. Yan, D. Infield, Y. Liu, Lien F. Sang, Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model, *Appl. Energy* 241 (2019) 229–244.
41. Kaplan, Y. A. (2015). Overview of wind energy in the world and assessment of current wind energy policies in Turkey. *Renewable & Sustainable Energy Reviews*, 43, 562-568. <https://doi.org/10.1016/j.rser.2014.11.027>
42. Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1412.6980>
43. Kisvari, A., Lin, Z., & Liu, X. (2021). Wind power forecasting – a data-driven method along with gated recurrent neural network. *Renewable Energy*, 163, 1895-1909. <https://doi.org/10.1016/j.renene.2020.10.119>

44. Kwiatkowski, D., Phillips, P. C., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root. *Journal Of Econometrics*, 54(1-3), 159-178. [https://doi.org/10.1016/0304-4076\(92\)90104-y](https://doi.org/10.1016/0304-4076(92)90104-y)
45. K. L. Jørgensen y H. R. Shaker, "Wind Power Forecasting Using Machine Learning: State of the Art, Trends and Challenges," 2020 IEEE 8th International Conference on Smart Energy Grid Engineering (SEGE), Oshawa, ON, Canada, 2020, pp. 44-50, doi: 10.1109/SEGE49949.2020.9181870.
46. Ko, M., Lee, K., Kim, J., Hong, C., Zhang, D., & Hur, K. (2021). Deep concatenated residual network with bidirectional LSTM for One-Hour-Ahead wind power forecasting. *IEEE Transactions on Sustainable Energy*, 12(2), 1321-1335. <https://doi.org/10.1109/tste.2020.3043884>
47. Landberg, L., & Watson, S. J. (1994). Short-term prediction of local wind conditions. *Boundary-Layer Meteorology*, 70(1-2), 171-195.
<https://doi.org/10.1007/bf00712528>
48. Lantz, B. (2013). *Machine learning with R*. Packt Pub Limited.
49. Lin, Z., & Liu, X. (2020). Wind power forecasting of an offshore wind turbine based on high-frequency SCADA data and deep learning neural network. *Energy*, 201, 117693. <https://doi.org/10.1016/j.energy.2020.117693>
50. Liu, Fei Tony & Ting, Kai & Zhou, Zhi-Hua. (2009). Isolation Forest. 413 - 422. 10.1109/ICDM.2008.17.
51. Luo, N., Pujol, T., Pacheco, L., González, J. R. P., Bramon, J., & Massaguer, A. (2017). Development of small-scale wind energy systems adaptable to climatic conditions using chattering torque control - PI pitch control and CAES strategy. *Renewable Energy & Power Quality Journal*, 1(15), 494-499.
<https://doi.org/10.24084/repqj15.369>

52. Lydia, M., Kumar, S., Selvakumar, A. I., & Lydia, M. (2014). A comprehensive review on wind turbine power curve modeling techniques. *Renewable & Sustainable Energy Reviews*, 30, 452-460.
<https://doi.org/10.1016/j.rser.2013.10.030>
53. Lydia, M., Kumar, S., Selvakumar, A. I., & Lydia, M. (2016). Linear and non-linear autoregressive models for short-term wind speed forecasting. *Energy Conversion and Management*, 112, 115-124.
<https://doi.org/10.1016/j.enconman.2016.01.007>
54. Mabel, M. C., & Fernandez, E. (2008). Analysis of wind power generation and prediction using ANN: a case study. *Renewable Energy*, 33(5), 986-992.
<https://doi.org/10.1016/j.renene.2007.06.013>
55. Mahjoub, S., Chrifi-Alaoui, L., Marhic, B., & Delahoche, L. (2022). Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks. *Sensors*, 22(11), 4062. <https://doi.org/10.3390/s22114062>
56. Mártil, I., & Mártil, I. (2022, 21 diciembre). *En el interior de un generador eólico*. Material Eléctrico - CdeComunicacion.es. <https://material-electrico.cdecomunicacion.es/opinion/ignacio-martil/2020/10/18/interior-de-un-generador-eolico>
57. M. Negnevitsky, P. Mandal and A. K. Srivastava, "An overview of forecasting problems and techniques in power systems," 2009 IEEE Power & Energy Society General Meeting, Calgary, AB, Canada, 2009, pp. 1-4, doi: 10.1109/PES.2009.5275480.
58. Nazir, M. S., Alturise, F., Alshmrany, S., Nazir, H. M. J., Bilal, M., Abdalla, A. N., Sanjeevikumar, P., & Ali, Z. M. (2020). Wind Generation Forecasting

- Methods and Proliferation of Artificial Neural Network: A Review of Five years Research trend. *Sustainability*, 12(9), 3778. <https://doi.org/10.3390/su12093778>
59. Neshat, M., Nezhad, M. M., Abbasnejad, E., Mirjalili, S., Tjernberg, L. B., Garcia, D. A., Alexander, B., & Wagner, M. (2021). A deep learning-based evolutionary model for short-term wind speed forecasting: A case study of the Lillgrund Offshore Wind Farm. *Energy Conversion and Management*, 236, 114002. <https://doi.org/10.1016/j.enconman.2021.114002>
60. Nicholas, L., Ooi, S. Y., Pang, Y. H., Hwang, S. O., & Tan, S. (2018). Study of long short-term memory in flow-based network intrusion detection system. *Journal Of Intelligent & Fuzzy Systems*, 35(6), 5947-5957. <https://doi.org/10.3233/jifs-169836>
61. Nielsen, T. S., Madsen, H., Nielsen, H. A., Giebel, G., & Landberg, L. (2002). Prediction of Regional Wind Power. In Proceedings of the 2002 Global Windpower Conference, Paris, France <http://www.imm.dtu.dk/pubdb/p.php?1733>
62. Nielsen, H. A., Nielsen, T. A. S., Madsen, H., Pindado, M. J. S. I., & Martí, I. (2007). Optimal combination of wind power forecasts. *Wind Energy*, 10(5), 471-482. <https://doi.org/10.1002/we.237>
63. Popescu, M. C., Balas, V. E., Perescu-Popescu, L., & Mastorakis, N. (2009). Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, 8(7), 579-588.
64. Programming with TensorFlow. (2021). En *EAI/Springer Innovations in Communication and Computing*. <https://doi.org/10.1007/978-3-030-57077-4>
65. Reinert, D. R., Prill, F. P., Frank, H. F., Denhard, M. D., Baldauf, M. B., Schraff, C. S., Gebhardt, C. G., Marsigli, C. M., & Zängl, G. Z. (2023). *DWD*

Database Reference for the Global and Regional ICON and ICON-EPS

Forecasting System (2.2.2) [Deutscher Wetterdienst].

https://www.dwd.de/EN/ourservices/nwp_forecast_data/nwp_forecast_data.html

66. Renani, E. T., Elias, M. F. M., & Rahim, N. A. (2016). Using Data-driven Approach for Wind Power Prediction: A Comparative study. *Energy Conversion and Management*, 118, 193-203.

<https://doi.org/10.1016/j.enconman.2016.03.078>

67. Salehinejad, Hojjat & Sankar, Sharan & Barfett, Joseph & Colak, Errol & Valaee, Shahrokh. (2017). Recent Advances in Recurrent Neural Networks.

68. Sazli, M. H. (2006). A brief review of feed-forward neural networks.

Communications Faculty Of Sciences University Of Ankara. Series A2-A3: Physics, Engineering Physics, Electronic Engineering And Astronomy, 50(1), 11-17. https://doi.org/10.1501/commua1-2_0000000026

69. Schmidhuber, J., & Hochreiter, S. (1997). Long short-term memory. *Neural Compute*, 9(8), 1735-1780.

70. Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673-2681.

<https://doi.org/10.1109/78.650093>

71. Shen, X., Fu, X., & Zhou, C. (2019). A combined algorithm for cleaning abnormal data of wind turbine power curve based on change point grouping algorithm and quartile algorithm. *IEEE Transactions on Sustainable Energy*, 10(1), 46-54. <https://doi.org/10.1109/tste.2018.2822682>

72. Singh, S., Bhatti, T. S., & Kothari, D. P. (2007). Wind power estimation using artificial neural network. *Journal of Energy Engineering*, 133(1), 46-52.

73. Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929-1958.
<https://jmlr.csail.mit.edu/papers/volume15/srivastava14a/srivastava14a.pdf>
74. Su, Y., Yu, J., Tan, M., Wu, Z., Xiao, Z., & Hu, J. (2019). A LSTM Based Wind Power Forecasting Method Considering Wind Frequency Components and the Wind Turbine States. IEEE. <https://doi.org/10.1109/icems.2019.8921671>
75. *THE 17 GOALS / Sustainable Development*. (s.f.). <https://sdgs.un.org/goals>
76. Tambke, J., Lange, M., Focken, U., Wolff, J., & Bye, J. A. T. (2004). Forecasting offshore wind speeds above the North Sea. *Wind Energy*, 8(1), 3-16.
<https://doi.org/10.1002/we.140>
77. Torres, J. L., García, A., De Blas, M., & De Francisco, A. (2005). Forecast of hourly average wind speed with ARMA models in Navarre (Spain). *Solar Energy*, 79(1), 65-77. <https://doi.org/10.1016/j.solener.2004.09.013>
78. *Understanding LSTM Networks -- colah's blog*. (s.f.). <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
79. United Nations. (s. f.). What is renewable energy? | United Nations. <https://www.un.org/en/climatechange/what-is-renewable-energy>
80. Varsamopoulos, Savvas & Bertels, Koen & Almudever, Carmen. (2018). Designing neural network based decoders for surface codes.
81. *What are GRIB files and how can I read them - Copernicus Knowledge Base - ECMWF Confluence Wiki*. (2023, 22 noviembre).
<https://confluence.ecmwf.int/display/CKB/What+are+GRIB+files+and+how+can+I+read+them>
82. Wikipedia. (2023, 29 septiembre). *Perceptrón multicapa*. Wikipedia, la enciclopedia libre. https://es.wikipedia.org/wiki/Perceptr%C3%B3n_multicapa

83. Wu, Z., & Huang, N. E. (2009). ENSEMBLE EMPIRICAL MODE DECOMPOSITION: A NOISE-ASSISTED DATA ANALYSIS METHOD. *Advances in Adaptive Data Analysis*, 01(01), 1-41.
<https://doi.org/10.1142/s1793536909000047>
84. Yeşilbudak, M., Sağıroğlu, Ş., & Çolak, İ. (2017). A novel implementation of kNN classifier based on multi-tupled meteorological input data for wind power prediction. *Energy Conversion and Management*, 135, 434-444.
<https://doi.org/10.1016/j.enconman.2016.12.094>
85. Yin, X., & Zhao, X. (2019). Big data driven multi-objective predictions for offshore wind farm based on machine learning algorithms. *Energy*, 186, 115704.
<https://doi.org/10.1016/j.energy.2019.07.034>
86. Zhang, T., Song, S., Li, S., Ma, L., Pan, S., & Han, L. (2019a). Research on Gas Concentration Prediction Models Based on LSTM Multidimensional Time Series. *Energies*, 12(1), 161. <https://doi.org/10.3390/en12010161>
87. Zhao, P., Wang, J., Xia, J., Dai, Y., Yingxin, S., & Ye, J. (2012). Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China. *Renewable Energy*, 43, 234-241.
<https://doi.org/10.1016/j.renene.2011.11.051>
88. Zheng, C., Li, C. Y., Pan, J., Liu, M. Y., & Xia, L. (2016). An overview of Global Ocean Wind Energy resource Evaluations. *Renewable & Sustainable Energy Reviews*, 53, 1240-1251. <https://doi.org/10.1016/j.rser.2015.09.063>
89. Zu, X., & Song, R. (2018). Short-term wind power prediction Method based on WaVELet packet decomposition and improved GRU. *Journal of physics*, 1087, 022034. <https://doi.org/10.1088/1742-6596/1087/2/022034>

Capítulo 9. ANEXOS

9.1 ANEXO I: ESPECIFICACIÓN TÉCNICA DE LOS AEROGENERADORES

Senvion 5M

- Diámetro del rotor: 126 m
- Número de palas: 3
- Altura mínima de la góndola: 90 m
- Altura máxima de la góndola: 120 m
- Potencia nominal: 5 MW
- Velocidad de rotación del Rotor: 6,9-12,1 rpm;
- Velocidad del viento de conexión 3,5 m/s
- Velocidad nominal del viento: 13 m/s
- Velocidad del viento de desconexión: 30 m/s
- Velocidad del extremo de la pala: 80 m/s a una velocidad del rotor de 12,1 rpm (aprox. 288 km/h)
- Vida útil: 20 años
- Masa de la góndola sin rotor ni buje: aprox. 290 toneladas
- Caja de cambios: Winergy con 3 niveles
- Generador: asíncrono
- Velocidad máxima del generador: 1170 rpm
- Tensión de Salida: 660-950 V
- Puesta en servicio: 2004




Ilustración 31: Curva de potencia Servion 5M

Adwen AD-5116

- Diámetro del rotor: 116 m
- Número de palas: 3
- Altura mínima de la góndola: 90 m
- Altura máxima de la góndola: 120 m
- Potencia nominal: 5 MW
- Velocidad de rotación del Rotor: 5,9-14,8 rpm
- Velocidad del viento de conexión: 3,5 m/s
- Velocidad nominal del viento: 12,5 m/s
- Velocidad del viento de desconexión: 25 m/s
- Velocidad de punta de pala: 90 m/s (324 km/h)
- Vida útil: 20 años
- Masa de la góndola sin rotor ni buje: 200 toneladas
- Caja de cambios: Renk de un nivel
- Generador: síncrono
- Velocidad del Generador: 148,5 rpm
- Tensión de salida: 3300 V
- Puesta en servicio: 2004


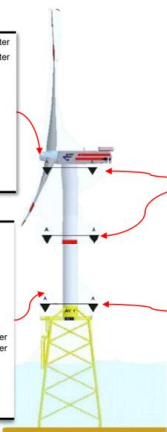


Ilustración 32: Curva de potencia Adwen AD-5116

9.2 ANEXO II: LISTA COMPLETA DE LOS SENSORES

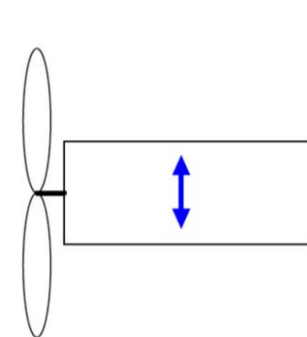
Turbina 4

Sensores en la torre



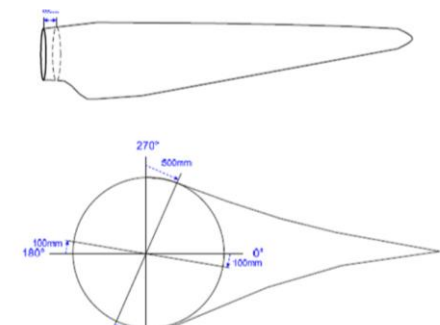
R4_N-A23o(x)	Inclination angle x-direction (294° and 114°)	Inclinometer
R4_N-A23o(y)	Inclination angle y-direction (24° and 204°)	Inclinometer
R4_B-A23o(x)	Acceleration x-direction 105°	ICP
R4_B-A23o(y)	Acceleration y-direction 105°	ICP
R4_B-A23o(x)	Acceleration x-direction 105°	ICP
R4_B-A23o(y)	Acceleration y-direction 105°	ICP
R4_B-A23o(x)_135	Acceleration x-direction	ICP
R4_B-A23o(y)_135	Acceleration y-direction	ICP
R4_T_A23o	Temperature	
R4_P_A23o	Air-Pressure	
R4_H_A23o	Humidity	
R4_B-A12u(x)	Acceleration x-direction 105°	ICP
R4_B-A12u(y)	Acceleration y-direction 105°	ICP
R4_B-A12u(x)_135	Acceleration x-direction 135°	ICP
R4_B-A12u(y)_135	Acceleration y-direction 135°	ICP
R4_B-A12m(x)	Acceleration x-direction 105°	ICP
R4_B-A12m(y)	Acceleration y-direction 105°	ICP
R4_B-A12o(x)	Acceleration x-direction 105°	ICP
R4_B-A12o(y)	Acceleration y-direction 105°	ICP
R4_B-A12o(x)_135	Acceleration x-direction 135°	ICP
R4_B-A12o(y)_135	Acceleration y-direction 135°	ICP
R4_N-A12u(x)	Inclination angle x-direction (105° and 330°)	Inclinometer
R4_N-A12u(y)	Inclination angle y-direction (60° and 240°)	Inclinometer
R4_T_A12u	Temperature	
R4_P_A12u	Air-Pressure	
R4_H_A12u	Humidity	
R4_T_A12o	Temperature	
R4_P_A12o	Air-Pressure	
R4_H_A12o	Humidity	
R4_DT_A23o_1_2	Tower Bending Moment (15° and 195°)	DMS
R4_DT_A23o_3_4	Tower Bending Moment (105° and 285°)	DMS
R4_DT-A23o2_1_2	Tower Bending Moment (0° and 180°)	DMS
R4_DT-A23o2_3_4	Tower Bending Moment (90° and 270°)	DMS
R4_DT-A23ot	Torsion (138° and 318°)	DMS
R4_F_A23o1_strain	Strain 105°	FOS
R4_F_A23o1_temp	Temperature 105°	FOS
R4_F_A23o2_strain	Strain 195°	FOS
R4_F_A23o2_temp	Temperature 195°	FOS
R4_F_A23o3_strain	Strain 285°	FOS
R4_F_A23o3_temp	Temperature 285°	FOS
R4_F_A23o4_strain	Strain 15°	FOS
R4_F_A23o4_temp	Temperature 15°	FOS
R4_D_A12o_1_2	Tower Bending Moment (105° and 285°)	DMS
R4_D_A12o_3_4	Tower Bending Moment (15° and 195°)	DMS
R4_F_A12o1_strain	Strain 105°	FOS
R4_F_A12o1_temp	Temperature 105°	FOS
R4_F_A12o2_strain	Strain 195°	FOS
R4_F_A12o2_temp	Temperature 195°	FOS
R4_F_A12o3_strain	Strain 285°	FOS
R4_F_A12o3_temp	Temperature 285°	FOS
R4_F_A12o4_strain	Strain 15°	FOS
R4_F_A12o4_temp	Temperature 15°	FOS
R4_DT_A12u_1_2	Tower Bending Moment (15° and 195°)	DMS
R4_DT_A12u_3_4	Tower Bending Moment (105° and 285°)	DMS
R4_DT_A12ut	Tower Torsion	DMS
R4_F_A12u1_strain	Strain 105°	FOS
R4_F_A12u1_temp	Temperature 105°	FOS
R4_F_A12u2_strain	Strain 195°	FOS
R4_F_A12u2_temp	Temperature 195°	FOS
R4_F_A12u3_strain	Strain 285°	FOS
R4_F_A12u3_temp	Temperature 285°	FOS
R4_F_A12u4_strain	Strain 15°	FOS
R4_F_A12u4_temp	Temperature 15°	FOS

Sensores en la góndola




R4_B-B4(x)	Acceleration in x-direction	ICP
R4_B-B4(y)	Acceleration in y-direction	ICP
R4_B-B4(z)	Acceleration in z-direction	ICP
R4_Generatordrehzahl_B4_50Hz	Generator revolutions	Control
R4_Pitchwinkel_ist_B4_50Hz	Pitch angle	Control
R4_elektrische_Leistung_B4_50Hz	Electrical power	Control
R4_Windgeschwindigkeit_B4_50Hz	Wind speed	Control
R4_T-B4_Ansaug-Entfeuchter	Air temperature (Lufttemperatur)	Temperature & Humidity sensor
R4_H-B4_Ansaug-Entfeuchter	Humidity (Luftfeuchtigkeit)	Temperature & Humidity sensor
R4_P-B4_Ansaug-Entfeuchter	Air Pressure	Barometer
R4_T-B4_Umgebung-Umrichter	Air temperature (Lufttemperatur)	Temperature & Humidity sensor
R4_H-B4_Umgebung-Umrichter	Relative humidity	Temperature & Humidity sensor
R4_P-B4_Umgebung-Umrichter	Absolute pressure	Barometer
R4_T-B4_Ansaug-Gondelkuehler	Air temperature (Lufttemperatur)	Temperature & Humidity sensor
R4_H-B4_Ansaug-Gondelkuehler	Relative humidity	Temperature & Humidity sensor
R4_P-B4_Ansaug-Gondelkuehler	Absolute pressure	Barometer
R4_Azimuthwinkel_B4_50Hz	Azimuth angle	Control
R4_T-B4_aussen	Temperature outside nacelle	
R4_P-B4_aussen	Air pressure outside nacelle	
R4_H-B4_aussen	Humidity outside nacelle	

Sensores en las aspas



R4_D-B5b1a1	Blade1-Edgewise bending moment 0°	DMS
R4_D-B5b1a2	Blade1-Flapwise bending moment 90°	DMS
R4_D-B5b1_Edge_0	Blade1-Edgewise bending moment 0°	FOS
R4_D-B5b1_Flap_90	Blade1-Flapwise bending moment 90°	FOS
R4_D-B5b1_Edge_180	Blade1-Edgewise bending moment 180°	FOS
R4_D-B5b1_Flap_270	Blade1-Flapwise bending moment 270°	FOS
R4_D-B5b2_Edge_0	Blade2-Edgewise bending moment 0°	FOS
R4_D-B5b2_Flap_90	Blade2-Flapwise bending moment 90°	FOS
R4_D-B5b2_Edge_180	Blade2-Edgewise bending moment 180°	FOS
R4_D-B5b2_Flap_270	Blade2-Flapwise bending moment 270°	FOS
R4_D-B5b3_Edge_0	Blade3-Edgewise bending moment 0°	FOS
R4_D-B5b3_Flap_90	Blade3-Flapwise bending moment 90°	FOS
R4_D-B5b3_Edge_180	Blade3-Edgewise bending moment 180°	FOS
R4_D-B5b3_Flap_270	Blade3-Flapwise bending moment 270°	FOS
R4_D-B5b1_Temp_0	Temperatur_0_Grad	PT-100
R4_D-B5b1_Temp_90	Temperatur_90_Grad	PT-100
R4_D-B5b1_Temp_180	Temperatur_180_Grad	PT-100
R4_D-B5b1_Temp_270	Temperatur_270_Grad	PT-100

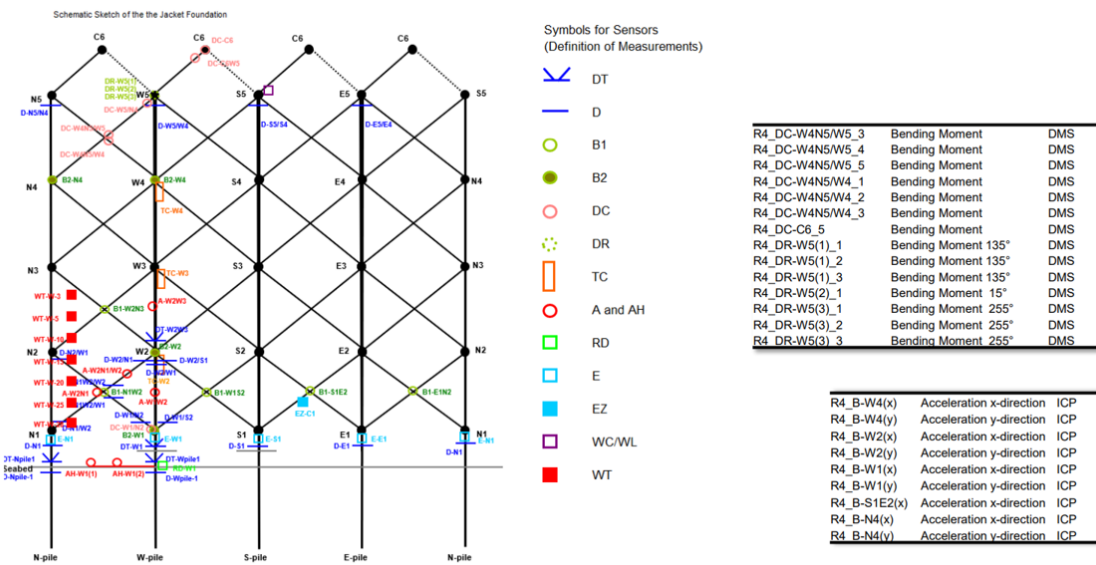
Sensores en el rotor



R4_DT-B4w_1_2	Bending moment 0° and 180°	DMS
R4_DT-B4w_3_4	Bending moment 90° and 270°	DMS
R4_DT-B4wt	Torsion	DMS
R4_Rotorposition_B4_Angle		Inductive sensor


4

Sensores en los cimientos *jacket*

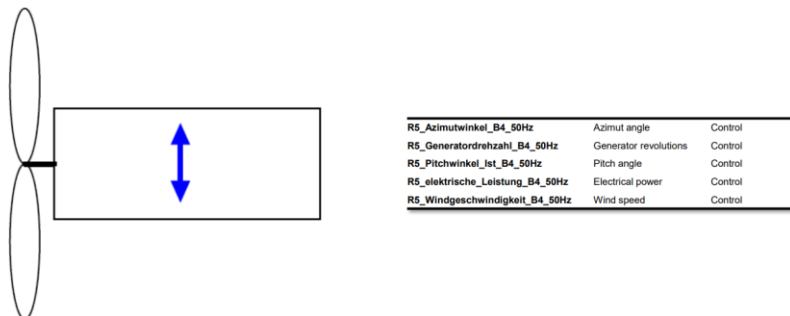


Turbina 5

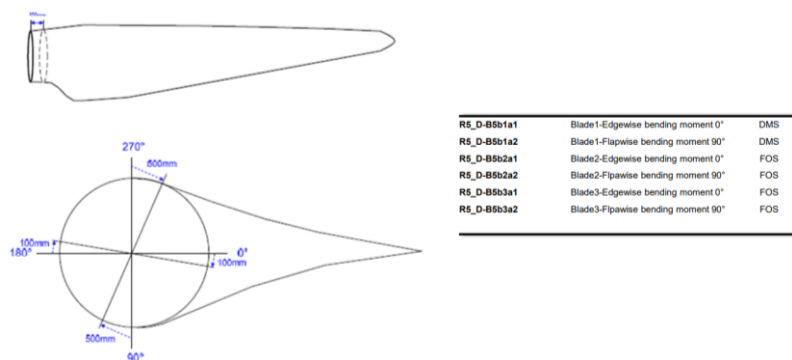
Sensores en la torre




Sensores en la góndola



Sensores en las aspas



Sensores en el rotor



Sensores en los cimientos *jacket*

En este caso, los sensores son equivalentes a los del aerogenerador 4.

9.3 ANEXO III: ALTURA DE LOS NIVELES DEL MODELO ICON-D2

level idx.	height [m]	level idx.	height [m]	level idx.	height [m]	level idx.	height [m]
1	20 700.926	18	8 446.611	35	3 639.535	52	964.048
2	18 707.630	19	8 073.640	36	3 434.414	53	855.630
3	17 459.836	20	7 715.350	37	3 235.976	54	752.427
4	16 432.216	21	7 370.787	38	3 044.029	55	654.479
5	15 538.089	22	7 039.106	39	2 858.399	56	561.856
6	14 738.074	23	6 719.557	40	2 678.926	57	474.652
7	14 009.789	24	6 411.462	41	2 505.461	58	393.002
8	13 338.901	25	6 114.219	42	2 337.870	59	317.092
9	12 715.508	26	5 827.280	43	2 176.032	60	247.172
10	12 132.398	27	5 550.148	44	2 019.836	61	183.592
11	11 584.105	28	5 282.374	45	1 869.185	62	126.857
12	11 066.360	29	5 023.548	46	1 723.991	63	77.745
13	10 575.747	30	4 773.294	47	1 584.179	64	37.606
14	10 109.477	31	4 531.269	48	1 449.686	65	10.000
15	9 665.235	32	4 297.157	49	1 320.458		
16	9 241.077	33	4 070.672	50	1 196.457		
17	8 835.344	34	3 851.546	51	1 077.658		

Ilustración 33: Altura de los niveles del modelo ICON-D2 (Reinert et al., 2023)

9.4 ANEXO IV: PREPARACIÓN DE DATOS PARA REDES LSTM Y GRU

Para llevar a cabo la implementación de estas redes en Keras, es necesario tener en consideración la forma en la que los datos deben estar organizados para alimentar estas redes. La implementación de estas redes requiere que los datos se introduzcan en forma de matriz tridimensional según la siguiente estructura: (Nº de muestras, Nº pasos de tiempo, Nº variables explicativas). La Ilustración 34 muestra un ejemplo de como se ha de realizar este proceso.

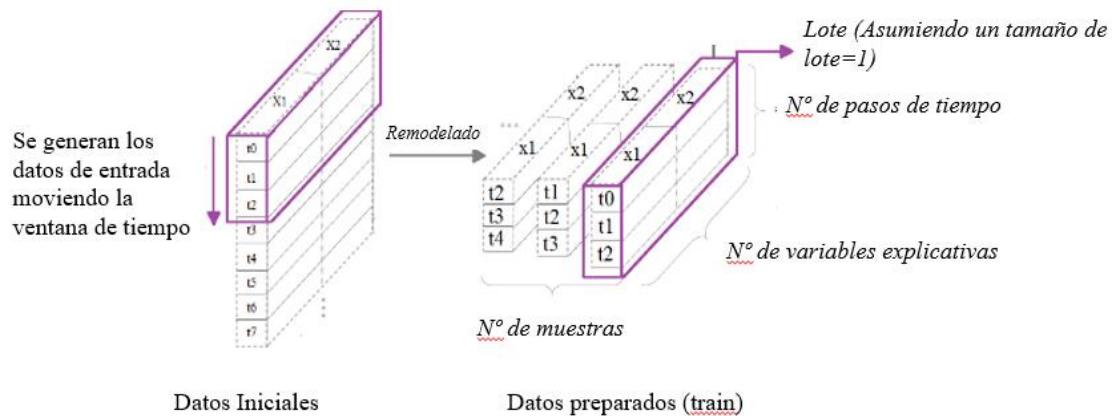


Ilustración 34: Preparación de datos para redes LSTM y GRU

En primer lugar, se han de generar las secuencias con el número de pasos de tiempo deseados. En el caso de este trabajo, dado que los datos son horarios, los valores posibles de número de pasos de tiempo son: [1, 2, 3, 4, 6, 12, 24].

Durante este proceso, es también vital seleccionar los instantes temporales correspondientes, es decir, suponiendo que quisiéramos predecir la potencia eólica en el instante t_3 con un único paso de tiempo de las variables explicativas, todas aquellas variables que proceden de la turbina han de ser del instante de tiempo anterior (t_2) (ya que la información del instante t_3 de esas variables aún no está disponible). En el caso de las predicciones meteorológicas (NWP) si se utilizarán los valores del instante t_3 . El Código 1 muestra como se ha implementado este proceso:

```

n Ahead=9 # Nº de periodos futuros a predecir
timesteps = 1 # Nº de pasos de tiempo a incluir en cada secuencia
X_orig=filtered_df.iloc[:,[0,1]] # Selección de variables explicativas con in-
formación de los sensores de la turbina para la predicción
y_orig=filtered_df.iloc[:,0] # Selección de la potencia eólica como variable a
predecir
variables_NWP_Z = filtered_df.iloc[:,4].to_numpy() # Selección de variables
NWP para la predicción
variables_turbina_X = X_orig.to_numpy()
potencia_eolica_y = y_orig.to_numpy()
X = []
y = []

for i in range(len(variables_turbina_X) - timesteps-n Ahead):
    # Generación de cada secuencia con las variables de la turbina
    row = [variables_turbina_X[i+j] for j in range(timesteps)]
    # Concatenación de las variables adicionales NWP
    z_features = [variables_NWP_Z[i+j+1] for j in range(timesteps)] # Se
seleccionan los mismos instantes temporales que la potencia eólica
    row = np.column_stack((row, z_features))

    X.append(row)
    # Selección de los instantes de tiempos correctos de la potencia eólica
    label = potencia_eolica_y[i + timesteps:i+timesteps+n Ahead]
    y.append(label)

# Conversión de las listas a vectores de numpy
X = np.array(X, dtype=object)
y = np.array(y)

# Se realiza el remodelado
if all(elem.shape == X[0].shape for elem in X):
    n_features = X[0].shape[1]
    X = np.stack(X)

```

Código 1: Preparación de datos

9.5 ANEXO V: ALINEACIÓN CON LOS ODS

El objetivo principal de este trabajo ha sido recopilar, analizar y comparar diferentes modelos de aprendizaje automático para la predicción de la generación eléctrica en un parque eólico marino, con el fin de identificar los más precisos y eficientes. Este análisis busca mejorar la capacidad de predicción de la energía generada, facilitando así la toma

de decisiones en el mercado eléctrico y contribuyendo a la estabilidad y eficiencia del sistema energético.

El trabajo se enmarca principalmente en el contexto de dos Objetivos de Desarrollo Sostenible (ODS) promulgados por la ONU: el objetivo número 7 y el objetivo número 13:

- **Objetivo número 7: Energía asequible y no contaminante.**
 - Este trabajo contribuye directamente a este objetivo al mejorar la precisión en la predicción de la generación de energía eólica, una fuente de energía renovable. Una mejor predicción permite una integración más eficiente de la energía eólica en la red, reduciendo la dependencia de fuentes de energía fósil y ayudando a asegurar un suministro de energía más limpio y sostenible. Además, facilita a las empresas generadoras de energía optimizar sus operaciones y reducir costos, lo que puede traducirse en precios de energía más bajos para los consumidores.
- **Objetivo número 13: Acción por el clima.**
 - Al centrarse en la predicción y optimización de la energía eólica marina, este trabajo promueve el uso de una fuente de energía renovable que no emite gases de efecto invernadero. Esto ayuda a mitigar los efectos del cambio climático al reducir la huella de carbono del sector energético. La mejora en la predicción de la generación eólica también contribuye a una mayor estabilidad de la red eléctrica, permitiendo una mayor integración de otras fuentes renovables y reduciendo la necesidad de recurrir a fuentes de energía de respaldo que suelen ser más contaminantes.