



Universidad del
Rosario

Escuela de Ingeniería,
Ciencia y Tecnología

USO DE MODELOS DE APRENDIZAJE AUTOMÁTICO PARA LA PREDICCIÓN DE ENERGÍA EÓLICA Y SU USO POTENCIAL EN EL MERCADO DE CORTO PLAZO EN COLOMBIA

Presentado para obtener el título de

MAGÍSTER EN ENERGÍAS RENOVABLES

Luis Carlos Hernández Tocora
Nilson Adiel Gutiérrez Astudillo

Dirección:
Andrea Matiz Chicacausa

Universidad del Rosario
Escuela de Ingeniería, Ciencia y Tecnología
Maestría en Energías Renovables

RESUMEN

El desarrollo de tecnologías para producir electricidad con base en el aprovechamiento de recursos naturales como el viento y sol, considerados limpios, ilimitados y renovables, ha transformado la generación de energía eléctrica. Sin embargo, estas tecnologías enfrentan el desafío de integrar fuentes renovables en los sistemas eléctricos de potencia, caracterizados por su confiabilidad y seguridad en el suministro eléctrico. Este reto se debe principalmente a la intermitencia de estas fuentes renovables, en contraste con fuentes convencionales como la generación térmica, nuclear y las grandes centrales hidroeléctricas. [1].

La energía eólica se aprovecha de la velocidad del viento en diferentes regiones del mundo. Para su uso efectivo, es necesario que el viento cumpla con ciertas velocidades y perfiles horarios anuales. Las turbinas eólicas, equipadas con electrónica de potencia, convierten la energía cinética del viento en energía eléctrica a partir de un proceso electromecánico que asegura el aprovechamiento óptimo del recurso eólico [2].

La continuidad en los sistemas eléctricos de potencia es crucial para mantener la confiabilidad del sistema eléctrico en cualquier país. Dado que la energía eólica, presenta variaciones en su intensidad a lo largo del día, mes y año, resulta esencial implementar metodologías predictivas. Estas metodologías, basadas en la recopilación y análisis de datos, son fundamentales para prever la generación de energía eólica, contribuyendo así a la estabilidad, confiabilidad y seguridad de los sistemas eléctricos de potencia. Los modelos de predicción pueden basarse en datos meteorológicos o ser más avanzados al integrar el aprendizaje automático que permite procesar grandes cantidades de datos, identificar patrones no lineales y ajustar sus parámetros sin intervención manual. [3].

Con base en la revisión literaria sobre el pronóstico de potencia eólica, se identificaron los modelos de aprendizaje automático más empleados por su desempeño técnico en la predicción de series no lineales y temporales, entre ellos están el Soporte Vectorial de Regresión (SVR), Árbol de decisión, redes recurrentes como LSTM cuya sigla en inglés corresponde a Long Short-Term Memory (Memoria a Largo y Corto Plazo) y GRU cuya sigla en inglés significa Gated Recurrent Unit (Unidad Recurrente con Puertas). Adicionalmente,

se evalúa el comportamiento de los modelos implementados en la herramienta computacional MATLAB, utilizando datos reales de potencia activa registrados minuto a minuto durante el año 2014 en una turbina de referencia AREVA M5000-116 del parque eólico Alpha Ventus, ubicado en el mar del Norte, Alemania. Los registros de velocidad y dirección del viento provienen de las estaciones meteorológicas del mismo parque.

Aunque los datos utilizados corresponden a un parque eólico en operación fuera de Colombia, su estructura y dinámica permiten simular el comportamiento esperado de un parque nacional bajo condiciones similares de recurso y operación. Este enfoque resulta aplicable al contexto colombiano, donde registros de viento con resolución temporal comparable pueden emplearse para estimar la producción de energía en el corto plazo y optimizar la programación del despacho dentro del Mercado de Energía Mayorista (MEM), en concordancia con la regulación vigente expedida por la CREG y las políticas de integración de Fuentes No Convencionales de Energía Renovable (FNCER).

Con lo anterior, se realiza el preprocesamiento de los datos, etapa en la que se lleva a cabo su limpieza mediante la corrección o estimación de datos faltantes. Para este último caso, se reemplazan los registros incompletos por el valor válido anterior o se extrapolan empleando los datos más cercanos, mientras que los valores no numéricos son tratados con el mismo procedimiento.

Posteriormente, se organizan las variables de entrada, las cuales incluyen: velocidad del viento [m/s], dirección del viento [°], y las componentes u y v , donde u representa la componente vertical de la velocidad del viento y v la componente horizontal. También se consideran la hora del día, los retardos temporales (lags) que permiten capturar correlaciones en el tiempo y mejorar la predicción a corto plazo, y los promedios móviles (rolling), que tienen como propósito suavizar y resumir el comportamiento reciente de la serie para aumentar la robustez del modelo.

Finalmente, se procede a la simulación de los modelos de regresión, entre ellos la Soporte Vectorial de Regresión (SVR), los Árboles de Decisión y de Secuencia Temporal, la Red Neuronal Recurrente LSTM (Memoria a Largo y Corto Plazo) y la Red Neuronal GRU

(Unidad Recurrente con Puertas). Para cada modelo se realizaron ajustes de hiperparámetros mediante simulaciones previas, seleccionando aquellas configuraciones que ofrecieron el mejor desempeño en las métricas RMSE, MSE, MAE y R^2 .

Del total de los datos disponibles, se empleó el 70% para entrenamiento, el 15% para validación y el 15% para prueba, lo que permitió garantizar que el modelo aprendiera patrones representativos, ajustara correctamente sus parámetros evitando el sobreajuste y evaluara su desempeño con datos no vistos durante el entrenamiento.

Al analizar los resultados obtenidos con los datos de prueba, se evalúa el desempeño de los modelos mediante las métricas RMSE, MSE, MAE y R^2 , ampliamente utilizadas para medir la eficiencia de los modelos predictivos. Estas métricas se calcularon con el apoyo de la herramienta MATLAB, al igual que el entrenamiento y la simulación de los diferentes modelos, lo que permitió identificar de manera objetiva cuál de los modelos presenta el mejor ajuste y capacidad de predicción.

ABSTRACT

The development of technologies to generate electricity based on the use of natural resources such as wind and solar energy considered clean, unlimited, and renewable has transformed electric power generation. However, these technologies face the challenge of integrating renewable sources into power systems, which are characterized by their reliability and security of supply. This challenge arises mainly from the intermittency of renewable energy sources, in contrast to conventional technologies such as thermal, nuclear, and large hydroelectric generation [1].

Wind energy is harnessed from wind speeds in different regions of the world. For its effective use, the wind must meet certain annual speed thresholds and hourly profiles. Wind turbines, equipped with power electronics, convert the kinetic energy of the wind into electrical energy through an electromechanical process that ensures optimal utilization of the wind resource [2].

Continuity in electric power systems is crucial to maintaining system reliability in any country. Since wind energy exhibits variations in intensity throughout the day, month, and year, implementing predictive methodologies becomes essential. These methodologies, based on data collection and analysis, are fundamental for forecasting wind power generation, thereby contributing to the stability, reliability, and security of power systems. Prediction models can rely on meteorological data or employ more advanced approaches that integrate machine learning, which enables the processing of large datasets, the identification of nonlinear patterns, and the automatic adjustment of parameters without manual intervention [3].

Based on the literature review on wind power forecasting, the most widely used machine learning models were identified due to their technical performance in predicting nonlinear and time-dependent series. These include Support Vector Regression (SVR), Decision Trees, and recurrent neural networks such as LSTM, whose acronym corresponds to *Long Short-Term Memory*, and GRU, which stands for *Gated Recurrent Unit*. Additionally, the behavior of the implemented models was evaluated using the computational tool MATLAB,

employing real active power data recorded every minute during 2014 from an AREVA M5000-116 reference turbine at the Alpha Ventus wind farm, located in the North Sea, Germany. Wind speed and direction measurements were obtained from the meteorological stations of the same wind farm.

Although the data used originate from an operational wind farm outside Colombia, their structure and dynamics allow for simulating the expected behavior of a national wind farm under similar resource and operating conditions. This approach is applicable to the Colombian context, where wind records with comparable temporal resolution can be used to estimate short-term energy production and optimize scheduling within the Wholesale Energy Market (MEM), in accordance with current regulations issued by the CREG and policies for integrating Non-Conventional Renewable Energy Sources (FNCER).

Data preprocessing is then performed, which includes cleaning the dataset by correcting or estimating missing values. In the latter case, incomplete records are replaced by the most recent valid value or extrapolated using the closest available data, while non-numeric values are handled following the same procedure.

Subsequently, the input variables are organized. These include wind speed [m/s], wind direction [°], and the u and v components—where u represents the vertical component of wind speed and v the horizontal component. Other variables considered are the hour of the day, temporal lags that help capture time correlations and improve short-term prediction, and rolling averages intended to smooth and summarize recent behavior of the time series to increase model robustness.

Finally, the regression models are simulated, including Support Vector Regression (SVR), Decision Trees and Time Series Decision Trees, the LSTM Recurrent Neural Network (*Long Short-Term Memory*), and the GRU Neural Network (*Gated Recurrent Unit*). Hyperparameter tuning was performed for each model through preliminary simulations, selecting the configurations that offered the best performance according to the RMSE, MSE, MAE, and R^2 metrics.

From the total dataset, 70% was used for training, 15% for validation, and 15% for testing, ensuring that the model learned representative patterns, properly adjusted its parameters while avoiding overfitting, and evaluated its performance using data not seen during training.

When analyzing the results obtained with the test data, the performance of the models is assessed using the RMSE, MSE, MAE, and R^2 metrics, widely used to measure the efficiency of predictive models. These metrics were computed using MATLAB, along with the training and simulation of the different models, which allowed for objectively identifying which model presented the best fit and predictive capability.

TABLA DE CONTENIDO

LISTA DE TABLAS.....	9
LISTA DE GRÁFICAS	10
Capítulo 1 INTRODUCCIÓN.....	11
Capítulo 2 OBJETIVOS.....	14
1.1 Objetivo general	14
1.2 Objetivos específicos.....	14
Capítulo 3 JUSTIFICACIÓN Y DESCRIPCIÓN DEL PROBLEMA.....	15
Capítulo 4 MARCO TEÓRICO Y ESTADO DEL ARTE.....	20
Capítulo 5 METODOLOGÍA.....	26
Capítulo 6 ENTRENAMIENTO DE LOS MODELOS Y RESULTADOS.....	32
CONCLUSIONES	58
TRABAJOS FUTUROS	60
REFERENCIAS	61

LISTA DE TABLAS

Tabla 1. Resumen y características de los modelos a implementar.	18
Tabla 2. Resumen de los modelos encontrados en la literatura.	24
Tabla 3. Selección de variables para entrenamiento de modelos.....	28
Tabla 4. Entrenamiento, validación y prueba de datos.	29
Tabla 5. Variables para evaluar los modelos de predicción [30].....	30
Tabla 6. Ficha técnica turbina AREVA M5000-116 [31].	33
Tabla 7. Comparación de hiperparámetros modelo SVR.	36
Tabla 8. Ajuste de parámetros modelo Soporte Vectorial de Regresión.	37
Tabla 9. Comparación hiperparámetros modelo Árbol de decisión.....	41
Tabla 10. Ajuste de parámetros modelo Árbol de decisión.	41
Tabla 11. Comparación de hiperparámetros modelo LSTM.....	45
Tabla 12. Ajuste de parámetros modelo LSTM.	46
Tabla 13. Comparación de hiperparámetros modelo GRU.....	51
Tabla 14. Ajuste de parámetros modelo GRU.	52
Tabla 15. Resultados de las métricas para cada modelo.	56

LISTA DE GRÁFICAS

Gráfica 1. Proceso operativo del mercado mayorista de energía en el corto plazo [13].	16
Gráfica 2. Promedio diario de las variables meteorológicas y de generación obtenido tras la limpieza de datos.	27
Gráfica 3. Muestra minutal de los cuatro primeros días del año 2014 después del proceso de limpieza de datos.	28
Gráfica 4. Curva de potencia de la turbina AREVA M5000-116 [31].	34
Gráfica 5. Distribución de Weibull datos de velocidad del viento.	34
Gráfica 6. Rosa de vientos datos de dirección de viento.	35
Gráfica 7. Comparación de hiperparámetros modelo Soporte Vectorial de Regresión.	37
Gráfica 8. Histograma y residuos modelo Soporte Vectorial de Regresión.	38
Gráfica 9. Comparación real vs predicción modelo Soporte Vectorial de Regresión.	39
Gráfica 10. Predicción Modelo Soporte Vectorial de Regresión.	40
Gráfica 11. Comparación de hiperparámetros modelo Árbol de decisión.	41
Gráfica 12. Histograma y residuos modelo Árbol de decisión.	42
Gráfica 13. Comparación real vs predicción modelo Árbol de decisión.	43
Gráfica 14. Predicción Modelo Árbol de decisión.	44
Gráfica 15. Comparación de hiperparámetros modelo LSTM.	45
Gráfica 16. Histograma y residuos modelo LSTM.	48
Gráfica 17. Comparación real vs predicción modelo LSTM.	49
Gráfica 18. Predicción Modelo LSTM.	50
Gráfica 19. Comparación de hiperparámetros modelo GRU.	51
Gráfica 20. Histograma y residuos modelo GRU.	53
Gráfica 21. Comparación real vs predicción modelo GRU.	54
Gráfica 22. Predicción Modelo GRU.	55
Gráfica 23. Desempeño comparativo de los modelos seleccionados.	56

Capítulo 1 INTRODUCCIÓN

Para el año 2022, la generación de electricidad mediante energía eólica experimentó el mayor crecimiento a nivel global, incrementándose un 17% (312 TWh). La producción aumentó de 1848 TWh en 2021 a 2160 TWh en 2022. Asimismo, la contribución de la energía eólica a la matriz eléctrica mundial se elevó, pasando del 6,6% al 7,6% [4].

Según el informe anual del Global Electricity Review 2023, el cual proporciona una visión general de la producción y el consumo de electricidad a nivel mundial se destacan datos del año 2022 en relación con la energía eólica, en ese año, se adicionaron cerca de 78 GW de capacidad eólica, representando el menor incremento en tres años, sin embargo, figura entre los años más productivos históricamente. Este progreso se alcanzó a pesar de las dificultades económicas y las perturbaciones en la cadena de suministro global, debilitadas por las crisis sanitarias y energéticas mundiales. A nivel mundial, se conectaron 77.6 GW de nueva capacidad eólica, incrementando la capacidad total instalada a 906 GW, lo que equivale a un aumento del 9% en comparación con el año anterior. [4,5].

De acuerdo con lo anterior, la energía eólica al igual que la solar son fundamentales para reducir emisiones en el ámbito eléctrico. Se prevé que estas fuentes representarán casi el 70% de la electricidad global para 2050, convirtiéndose en pilares del futuro sistema eléctrico. Por ende, es imprescindible una rápida expansión de estas energías en la presente década [4].

Es importante destacar que la energía eólica, como fuente renovable en la generación de energía eléctrica, tiene un potencial significativo y sus proyecciones en la matriz energética mundial están en aumento. Sin embargo, esta tecnología presenta una particularidad: la intermitencia, producto de su recurso principal, el viento. Por tanto, la variabilidad en la producción de energía eólica, causada por la compleja relación entre la generación de energía, la velocidad y la dirección del viento, subraya la necesidad de una predicción precisa para la selección óptima de ubicaciones de parques eólicos y para fomentar un desarrollo energético sostenible. No obstante, predecir la generación eólica es un desafío debido a su intermitencia, influenciada por diversos factores como la dirección del viento y la presión atmosférica. Con

la creciente disponibilidad de datos eólicos y el uso de modelos de aprendizaje automático se puede predecir la generación de energía eólica de manera más efectiva. [6].

En la literatura se han propuesto diversos métodos para la predicción de la energía o de la velocidad del viento en los últimos años, los cuales se basan en modelos de predicción meteorológica numérica, enfoques estadísticos, redes neuronales artificiales y técnicas híbridas aplicadas en diferentes escalas temporales [7].

Por otro lado, existen modelos de predicción basados en la regresión cuantil, que estima la probabilidad condicional de una variable aleatoria a través de cuantiles. Entre estos se encuentran la regresión pasiva-agresiva cuantil, el ajuste de curvas de regresión mediante la investigación y pronóstico del tiempo, la parametrización de parques eólicos y la red neuronal de regresión cuantil para la predicción de energía eólica. En los últimos años, los modelos de predicción espaciotemporales han ganado atención por su eficacia en incrementar la precisión de las predicciones. Estos modelos, al utilizar datos de diversas granjas y ubicaciones, requieren grandes cantidades de información y, por ende, métodos avanzados para manejar la alta dimensionalidad de dichas situaciones [8-12].

En la actualidad, la predicción de energía eólica se basa principalmente en métodos estadísticos y meteorológicos tradicionales. Aunque estos enfoques han demostrado ser útiles, su implementación implica altos costos operativos, ya que requieren procesos extensos de recolección, depuración y análisis de datos. Esta dependencia de grandes volúmenes de información y de recursos técnicos especializados incrementa los gastos asociados a la planificación y gestión eficiente de la generación eólica, limitando su aplicación en escenarios donde se demanda una respuesta rápida y adaptable [13].

Dado que la energía eólica depende de una variable intermitente como el viento, resulta fundamental abordar de manera adecuada la planificación y gestión de la generación proveniente de este tipo de plantas. En este contexto, uno de los principales desafíos consiste en programar eficientemente el despacho de energía en el Mercado de Energía Mayorista colombiano, garantizando una integración confiable de la generación eólica sin comprometer la estabilidad del sistema eléctrico.

En el Mercado de Energía Mayorista colombiano intervienen diferentes agentes, como generadores, transmisores, distribuidores y comercializadores, quienes desempeñan funciones orientadas a garantizar el suministro confiable de electricidad dentro del Sistema Interconectado Nacional (SIN). Entre estos agentes destacan los generadores, encargados de producir energía a partir de diversas fuentes (hidráulica, térmica, solar, eólica, entre otras) y de participar en un esquema competitivo del mercado, ya sea en el corto plazo o mediante contratos bilaterales [14]. En este sentido, el aspecto que concierne a este estudio se centra en el agente generador que utiliza la fuente eólica y participa en el mercado de corto plazo, escenario en el cual se aplican los modelos de predicción basados en aprendizaje automático.

Por su parte, los comercializadores actúan como intermediarios entre los generadores y los usuarios finales, comprando energía en el mercado y trasladando sus costos a los usuarios de acuerdo con las condiciones establecidas por la regulación. La administración del mercado y la operación del sistema están a cargo de XM, entidad responsable de coordinar el Centro Nacional de Despacho (CND), con el fin de garantizar el equilibrio permanente entre la oferta y la demanda, y asegurar la estabilidad del sistema eléctrico nacional [14].

Finalmente, en el mercado de corto plazo (horizontes de 24 horas), también conocido como bolsa de energía, los precios se determinan hora a hora con base en las ofertas de los generadores y la demanda real. Los generadores presentan ofertas horarias de precio y disponibilidad con base en sus pronósticos diarios de generación [14].

Capítulo 2 OBJETIVOS

1.1 Objetivo general

Identificar el modelo de aprendizaje automático con mejor capacidad predictiva de potencia eólica, considerando datos históricos de velocidad y dirección del viento de tal forma que su aplicación contribuya en los pronósticos de disponibilidad de potencia en el mercado del corto plazo en Colombia.

1.2 Objetivos específicos

- Hacer una revisión de literatura sobre modelos de aprendizaje automático aplicados al pronóstico de energía eólica, identificando aquellos con mejor desempeño para aplicaciones temporales en el corto plazo.
- Implementar los modelos de aprendizaje automático más representativos identificados en la revisión bibliográfica que permitan estimar la relación entre variables meteorológicas y potencia generada o que capturen dependencias temporales como es el caso de modelos de regresión y series temporales con aplicación en energía eólica.
- Evaluar y comparar el desempeño de los modelos previamente seleccionados mediante métricas típicas, con el fin de determinar su idoneidad y su potencial aplicación en el pronóstico de potencia a corto plazo.

Capítulo 3 JUSTIFICACIÓN Y DESCRIPCIÓN DEL PROBLEMA

La producción de energía eólica está intrínsecamente ligada a las condiciones meteorológicas, lo cual introduce una variabilidad y una imprevisibilidad significativas en su generación de energía. La incertidumbre en la predicción de la generación eólica plantea desafíos notables en la planificación y gestión operativa de proyectos eólicos, lo que a menudo resulta en un incremento de los costos [3].

En la actualidad, los modelos de predicción de energía eólica emplean técnicas estadísticas y meteorológicas convencionales. A pesar de su utilidad, estos modelos implican altos costos, dado que requieren tiempo y recursos considerables para la recopilación y análisis de datos, lo que aumenta los gastos asociados a la planificación y gestión efectiva de la producción eólica [13].

Por lo tanto, se identifica como problema central la necesidad de implementar modelos de predicción de energía eólica más eficientes, por ejemplo, técnicas de aprendizaje automático. Estos modelos buscan mejorar la capacidad de predecir el rendimiento de las turbinas bajo diversas condiciones meteorológicas, optimizando así la planificación y gestión de la producción eólica. Los modelos de aprendizaje automático, alimentados con datos de variables meteorológicas y registros históricos de producción de los parques eólicos, se entrenan para prever el comportamiento de los aerogeneradores y su generación energética [15-20].

En el contexto colombiano, el Mercado de Energía Mayorista viene funcionando como un mercado diario, el cual se caracteriza por una interacción donde los generadores venden y los comercializadores de energía compran energía hora a hora, de modo que los generadores presentan su precio y disponibilidad para cada hora del día siguiente y XM el operador del mercado ordena y cruza esas ofertas para atender la demanda del sistema. Sin embargo, este diseño ha sido eficaz en sistemas eléctricos hidro-térmicos como ha sido tendencia en las últimas décadas, debido a que estas tecnologías no presentan muchos cambios en la disponibilidad de los recursos en un horizonte intradiario, pero esto puede resultar

ineficiente con la inclusión de nuevas tecnologías basadas en Fuentes No Convencionales de Energía Renovable como lo son la energía eólica y solar [21].

En la gráfica 1, se describe el proceso operativo del mercado de energía en el corto plazo coordinado por XM y regulado por la GREG donde se asegura el equilibrio entre la generación y la demanda en tiempo real. Por un lado, los generadores eléctricos presentan sus ofertas horarias de precio y declaran la disponibilidad de sus unidades de generación a XM, lo cual, quiere decir cuanta energía pueden entregar al sistema. Con base en las ofertas recibidas, XM realiza el despacho económico nacional organizando las plantas desde la de menor costo hasta la de mayor costo, de modo que la generación total cubra la demanda prevista al menor costo posible. Por último, el Centro Nacional de Despacho supervisa en tiempo real la operación del sistema entre las 00:00 y las 24:00 horas, verificando que la energía generada y consumida se mantenga en equilibrio.



Gráfica 1. Proceso operativo del mercado mayorista de energía en el corto plazo [13].

En la resolución de la CREG 143 de 2021, se hace una breve recopilación de cómo ha venido funcionando el Mercado de Energía Mayorista a través de los años, donde se han contratado una serie de estudios para considerar un despacho más vinculante con mercados intradiarios lo cual permita a las fuentes de energía renovable no convencionales tener un mejor ajuste en sus despachos al ser de corto plazo (horas).

En el último año se han tenido particularmente dos circulares por parte de la CREG, donde la circular CREG 096 de 2024 presenta la propuesta de modernización del Mercado de Energía Mayorista caracterizado por un despacho vinculante e intradiario, de igual forma en la circular CREG 121 de 2024 se tiene en la agenda determinar los ajustes y lineamientos de la propuesta de modernización del mercado.

Por lo anterior, la propuesta de modernizar el mercado hacia una metodología intradiaria representa una oportunidad valiosa para aprovechar, en el corto plazo, las capacidades de los modelos de aprendizaje automático, de modo que sea posible obtener predicciones más precisas al momento de presentar la disponibilidad de los recursos energéticos de las plantas eólicas, basadas en las variables meteorológicas que caracterizan la generación de esta tecnología.

El objetivo de este documento consiste en evaluar diferentes modelos aprendizaje automático que se puedan aplicar en la predicción de energía eólica. Dado que los datos utilizados corresponden a registros históricos con valores de entrada y salida (velocidad y dirección del viento como variables predictoras y potencia generada como variable objetivo) se emplean modelos de aprendizaje supervisado, dentro de estos se incluyen modelos de regresión, árboles de decisión, soporte vectorial para regresión, entre otros. De igual forma se tienen modelos basados en redes neuronales, allí se encuentran redes neuronales recurrentes, perceptrón multicapa, LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), por último, se tienen modelos probabilísticos, en los cuales se encuentran modelos de regresión bayesiana, Gaussian Process Regression (GPR) entre los más nombrados [22].

A continuación, en la Tabla 1 se presenta un resumen de los modelos a implementar, junto con sus principales características y aplicaciones identificadas en la literatura.

Tabla 1. Resumen y características de los modelos a implementar.

Modelo	Descripción	Características principales	Ventajas	Desventajas	Aplicación en energía eólica	Horizonte de aplicación	Referencia
SVR	Modelo de regresión basado en el principio del margen máximo. Busca una función que minimice el error dentro de un margen (ϵ), penalizando las desviaciones mayores mediante un parámetro de regularización (C). Usa funciones <i>kernel</i> (RBF, lineal, polinómica) para capturar relaciones no lineales.	Modela relaciones no lineales. Requiere escalado de datos. Sensible a la elección de C y ϵ .	Robusto ante ruido. Buen rendimiento con pocos datos. Preciso en horizontes cortos.	Alto costo computacional con grandes volúmenes de datos. Difícil interpretación física.	Permite predecir la potencia generada a partir de variables como velocidad y dirección del viento, especialmente útil cuando los datos son limitados o el comportamiento es no lineal.	Corto plazo (minutos a 6 h)	[6], [7], [18], [19], [20]
Árbol de Decisión	Divide iterativamente los datos con base en criterios de pureza (varianza) hasta alcanzar nodos terminales o "hojas" que representan el valor de salida promedio.	Estructura jerárquica y explicativa. No requiere normalización. Captura interacciones no lineales.	Fácil interpretación. Bajo costo computacional. Rápida predicción.	Propenso al sobreajuste si el árbol es muy profundo.	Se aplica para estimar la potencia media generada bajo condiciones meteorológicas específicas y para identificar las variables más influyentes en la producción eólica.	Corto y mediano plazo	[7], [15], [17], [18], [22]
LSTM	Red neuronal recurrente con celdas de memoria y compuertas (<i>entrada, olvido, salida</i>) que retienen información relevante y descartan ruido, capturando dependencias temporales en los datos.	Modela dependencias a largo plazo. Ideal para series temporales. Aprende patrones dinámicos.	Alta precisión en datos secuenciales. Capta rampas de viento y ciclos horarios. Excelente generalización temporal.	Requiere gran cantidad de datos. Entrenamiento lento. Menor interpretabilidad.	Utilizada para pronosticar la potencia eólica en horizontes de horas, considerando la memoria temporal de variables meteorológicas (velocidad, dirección, temperatura).	Corto y mediano plazo (1–24 h)	[6], [8], [23], [24], [25], [26], [29]
GRU	Variante simplificada de LSTM con dos compuertas (actualización y reinicio) que reducen la complejidad del modelo manteniendo la capacidad de aprendizaje temporal.	Menos parámetros que LSTM. Entrenamiento más rápido.	Rápido entrenamiento. Buen equilibrio entre precisión y eficiencia. Adecuado para datos secuenciales.	Menor interpretabilidad. Puede subestimar cambios abruptos.	Adecuado para predicción intradía de generación eólica, permitiendo anticipar fluctuaciones en la potencia con menor carga computacional que LSTM.	Corto plazo (hasta 12 h)	[6], [8], [25], [26], [29]

De acuerdo con lo descrito anteriormente para cada modelo, se espera evaluar su desempeño mediante métricas, con el fin de determinar cuál presenta el mejor comportamiento en la predicción de la variable objetivo (potencia). De esta manera, la implementación de los modelos predictivos basados en aprendizaje automático propuestos en este documento podría aplicarse en parques eólicos colombianos una vez entren en operación, permitiendo estimaciones más precisas de la energía disponible para su oferta en el Mercado de Energía Mayorista en el corto plazo. Esto sería posible a partir del histórico de generación y de las variables meteorológicas medidas directamente en el sitio de implantación, lo que contribuiría a una programación del despacho de energía más eficiente y confiable.

En los siguientes capítulos se presenta, en primer lugar, el marco teórico y el estado del arte, donde se realiza una revisión de los estudios y metodologías más relevantes aplicadas a la predicción de energía eólica, identificando los principales enfoques utilizados, así como sus ventajas y limitaciones. Posteriormente, se desarrolla la metodología, en la cual se describen las etapas de procesamiento de los datos, la selección de variables, el entrenamiento de los modelos y los criterios empleados para su evaluación. Este apartado define la base técnica y el enfoque experimental del estudio. Finalmente, se presenta el capítulo de simulación y resultados, donde se exponen las configuraciones de los modelos implementados, los valores obtenidos en las métricas de desempeño y el análisis comparativo entre los diferentes modelos, destacando aquellos que presentan el mejor comportamiento para el contexto propuesto.

Capítulo 4 MARCO TEÓRICO Y ESTADO DEL ARTE

El uso de modelos de aprendizaje automático para la predicción de la producción de energía eólica busca incrementar la precisión en la estimación de la generación de energía, facilitando así una planificación más eficiente a la hora de ingresar estas plantas en la red eléctrica [23].

Los modelos de aprendizaje automático se caracterizan por emplear un conjunto de técnicas y algoritmos que les permiten resolver tareas complejas y pueden clasificar, predecir y sugerir acciones basadas en datos. Estos modelos toman datos históricos como lo es la velocidad y dirección del viento, la temperatura y la humedad, para realizar la predicción de la producción de energía, dentro de los cuales se pueden encontrar; modelos basados en redes neuronales, árboles de decisión, regresión lineal y no lineal, y métodos basados en el análisis de series de tiempo [23].

Debido a que la energía eólica es una fuente de energía renovable que aprovecha la velocidad del viento, y este a su vez es una variable que no es constante, se hace necesario el uso de modelos de aprendizaje automático capaces de capturar sus patrones no lineales y temporales. El uso de estos modelos permite mejorar la precisión en la estimación de la generación eléctrica, de tal forma que puede mejorar la planificación y la integración eficiente de la energía eólica al sistema eléctrico.

En 2019 Singh, M., & Kim, implementan el modelo LSTM como pronóstico de potencia a corto plazo a través de datos históricos de potencia, velocidad y dirección del viento, sin embargo, realizan una mejora incorporando la estructura de Mogrifier que precondiciona la entrada (variables que ingresan al modelo) y el estado oculto (información aprendida que se mantiene en memoria) mediante compuertas multiplicativas antes de las ecuaciones del LSTM, esta estructura optimiza el cálculo habitual del LSTM debido a que está en la capacidad de capturar dependencias temporales y no lineales, de esta forma entiende mejor la dinámica del viento y logra predicciones de potencias más precisas, este modelo mejora predicción de la generación de energía especialmente en lugares donde se tienen estaciones climáticas [24].

La participación de la energía eólica en el suministro de electricidad ha aumentado en las últimas dos décadas. El aumento en los niveles de penetración de fuentes de energía intermitentes, como la energía eólica, ha supuesto un desafío para las compañías eléctricas al momento de despachar las unidades de generación debido a que con el ingreso de estas tecnologías el recurso puede variar de un momento a otro afectando la confiabilidad del sistema. Por lo tanto, la necesidad de realizar pronósticos precisos para la generación de energía eólica se ha convertido en un tema crítico para los operadores del sistema eléctrico. Por esto, en el estudio se presenta la Red Neuronal Recurrente basada en Memoria a Corto y Largo Plazo (LSTM-RNN) un enfoque novedoso para pronosticar la generación de energía eólica de 1 a 24 horas [24].

A lo largo del tiempo, se han desarrollado diversas herramientas y metodologías para pronosticar la energía eólica. Algunas de ellas son métodos físicos que se basan en descripciones atmosféricas para realizar los pronósticos. Otro enfoque común implica utilizar datos de pronóstico meteorológico numérico (NWP) en modelos estadísticos de pronóstico. Se ha informado ampliamente sobre modelos estadísticos, como la regresión polinómica, ARMA (Media Móvil Autorregresiva) y ARIMA (Media Móvil Integrada Autorregresiva), para el pronóstico de la energía eólica. Sin embargo, con los avances en algoritmos inteligentes de aprendizaje automático, como las redes neuronales y las máquinas de vectores de soporte (SVM), estos también se han empleado en el pronóstico de series temporales de energía eólica. Algunos estudios han utilizado la velocidad y dirección del viento, así como los parámetros de las turbinas eólicas, en redes neuronales para pronosticar la energía eólica. Además, se ha empleado una red neuronal de propagación hacia adelante para predecir la energía eólica con un día de anticipación [25].

Sin embargo, los modelos de pronóstico de energía eólica basados en redes neuronales convencionales carecen de la capacidad para incorporar información, por lo tanto, no integran bien la historia reciente de las variables de entrada. Para abordar este problema y capturar esa dependencia temporal, se han utilizado redes neuronales recurrentes (RNN) en modelos de pronóstico de energía eólica.

En 2022 los autores Peng Lu, Lin Ye, Ming Pei, Yongning Zhao, Binhua Dai, Zhuo Li, presentan un modelo basado en redes neuronales recurrentes (RNN) con arquitectura LSTM para realizar pronósticos de corto plazo de la energía eólica. El modelo es entrenado utilizando datos de 9 meses y evaluado utilizando datos de 3 meses adicionales. Se utilizan 24 retardos los cuales equivalen a una ventana de 24 horas, elegida porque captura el ciclo diario del viento y optimiza la precisión del pronóstico sin sobrecargar el modelo, el cual cuenta con una capa oculta compuesta por 50 neuronas con lo cual se buscó maximizar la precisión del pronóstico y minimizar el error, manteniendo un costo computacional razonable [25].

La selección de las variables de entrada al modelo se realiza mediante un análisis de sensibilidad, probando diferentes combinaciones de variables, dentro de las cuales se tiene velocidad y dirección del viento, temperatura, presión, humedad y potencia. Se observa que la presión superficial tiene un efecto negativo en el rendimiento del modelo, mientras que la temperatura tiene un efecto positivo, mejorando su desempeño. Posteriormente, el modelo más preciso se utiliza para pronosticar la energía eólica en un horizonte que abarca desde 1 hora hasta 24 horas en el futuro [25], lo cual es ideal para la predicción de energía, en el mercado de energía mayorista de energía y su posible actualización a un mercado de energía intradiario.

En la literatura se ha encontrado que en los últimos años se han llevado a cabo numerosos estudios para desarrollar modelos de pronóstico que utilicen diversas técnicas con el objetivo de mejorar la precisión del pronóstico de la energía eólica a corto plazo (WPF, por sus siglas en inglés). Estos modelos se pueden clasificar en dos categorías principales: enfoques de modelo único y enfoques de modelo en conjunto. Los enfoques de modelo único emplean métodos estadísticos o de aprendizaje automático para construir un único modelo a partir de un conjunto de datos de entrenamiento, mientras que los enfoques de modelo en conjunto desarrollan un modelo de pronóstico integrando los resultados iniciales de varios modelos individuales mediante métodos de ensamblaje [26].

Continuando con el estudio, se emplearon cuatro modelos basados en redes profundas para la primera etapa, con el objetivo de aprender las características de los datos (potencia, velocidad y dirección del viento, temperatura, presión, humedad y estados operativos del parque), teniendo en cuenta la estructura de entrada y salida. Luego, se aborda el problema de la extrapolación del modelo en la segunda etapa mediante la utilización del ensamblaje con regresión Ridge que combina las salidas para reducir el error. Para evitar el sobreajuste, se propone un nuevo algoritmo basado en ventana móvil que utiliza un conjunto de validación en la primera etapa para actualizar los datos de entrenamiento en ambas etapas, empleando dos procesos de ventana móvil distintos. Se realiza en tres parques eólicos y los resultados obtenidos demuestran que el modelo con una estructura de una entrada y múltiples salidas logra una mayor precisión en el pronóstico en comparación con los modelos existentes. Además, mediante el uso del método de regresión Ridge, se obtiene un modelo de ensamblaje aún mejor que puede mejorar la precisión de pronóstico en comparación con los métodos de aprendizaje automático existentes [26].

En resumen, el algoritmo de pronóstico de dos etapas propuesto puede generar resultados más precisos y estables que los algoritmos existentes, abordando tanto las estructuras de aprendizaje como el problema de la extrapolación del modelo en el campo del pronóstico de la energía eólica [26].

En los trabajos desarrollados entre el 2009 y 2011 por los autores Wei Gu, Rui Wang, Rong Sun, Qun Li, Han Xiaoqing, Yan Yong, se plantea un marco para cuantificar la integración de la energía eólica en un sistema de bus IEEE30, este sistema consiste en un flujo de potencia que contiene unidades de generación tanto convencionales como eólicas, cargas que se asemejan a la demanda en unidades de MVA y MVAr, líneas de transmisión y transformadores de potencia. Este modelo recolecta información tanto del sistema de potencia convencional como de los parques eólicos que están planeados para ser integrados en el sistema eléctrico [27-28].

En este estudio se tiene como objetivo optimizar la producción máxima de energía eólica en función de las velocidades del viento y el cálculo del flujo de potencia, de modo que se

modela la incertidumbre del viento mediante escenarios y optimiza el despacho conjunto sujeto a restricciones operativas maximizando el aprovechamiento del recurso eólico integrándolo al sistema eléctrico de manera que no se comprometa el flujo de potencia de la red existente. Así, se pretende que la energía eólica complemente a los generadores convencionales, asegurando un despacho óptimo de las unidades de aerogeneradores. Este enfoque busca un equilibrio entre la incorporación de fuentes de energía renovables y la estabilidad y eficiencia del sistema eléctrico existente [27-28].

De acuerdo con la literatura, se identifican diferentes enfoques y metodologías con diversas capacidades para realizar la predicción de energía en plantas eólicas. Por ello, en la tabla 2 se presenta un resumen de algunos de los modelos más utilizados.

Tabla 2. Resumen de los modelos encontrados en la literatura.

Estudio	Modelo utilizado	Desarrollo/Conclusiones	Referencia
Revisión bibliográfica global sobre inteligencia artificial y big data en pronóstico eólico.	ANN, SVM, LSTM, híbridos.	Identifica tendencias de investigación, destacando el crecimiento del uso de aprendizaje profundo y métodos híbridos en predicciones de corto plazo.	[6]
Revisión de métodos de pronóstico de velocidad y potencia eólica en diferentes horizontes temporales.	ARIMA, ANN, SVM, modelos híbridos.	Clasifica modelos según horizonte (corto, medio, largo); los SVM y ANN presentan mejor desempeño en el corto plazo.	[7]
Estado del arte sobre tecnologías modernas de pronóstico de generación eólica.	CNN, LSTM, híbridos.	Propone integrar técnicas de aprendizaje profundo con datos meteorológicos para mejorar la precisión horaria.	[8]
Mejora de predicciones agregadas día-ahead considerando correlaciones espaciales y temporales.	Modelos de regresión y ensamble probabilísticos.	Demuestra que incorporar correlaciones entre parques reduce el error en la predicción regional.	[9]
Enfoque probabilístico online basado en aprendizaje conjunto.	Ensemble Learning y Probabilistic Forecasting.	Los modelos probabilísticos mejoran la estimación de incertidumbre en escenarios de alta penetración eólica.	[10]
Predicción probabilística regional mediante regresión cuantil espaciotemporal.	Regresión Cuantil Espaciotemporal.	Introduce la dimensión espacial como factor clave para mejorar pronósticos regionales.	[11]
Pronóstico regional mediante regresión cuantil profunda.	Regresión Cuantil Profunda.	Combina redes neuronales profundas y cuantiles, mejorando la representación de incertidumbre.	[12]
Predicción de energía eólica con redes neuronales de dos capas ocultas.	ANN de múltiples capas.	Mejora la precisión frente a redes simples, mostrando sensibilidad al tamaño de ventana temporal.	[13]
Estimación de potencia eólica mediante técnicas estadísticas y aprendizaje automático.	SVR, KNN, Random Forest.	Muestra que SVR presenta mejor capacidad de generalización en conjuntos de datos reales.	[15]
Comparación de métodos de aprendizaje automático para generación renovable.	ANN, SVR, GPR.	SVR y GPR ofrecen mejor equilibrio entre precisión y costo computacional.	[18]
Predicción de energía eólica mediante técnicas de aprendizaje automático.	SVM, Árboles de decisión, ANN.	Concluye que los modelos híbridos y no lineales mejoran la predicción en horizontes horarios.	[19]
Revisión de métodos de pronóstico de velocidad y potencia.	ARIMA, ANN, SVM.	Reafirma que modelos no lineales (ANN, SVM) superan a los lineales para el corto plazo.	[20]
Predicción de generación eólica mediante el aprendizaje profundo.	Redes neuronales profundas.	Demuestra que las redes profundas reducen significativamente el error frente a modelos clásicos.	[23]
Predicción de corto plazo con redes LSTM.	LSTM.	LSTM mejora la precisión horaria frente a ANN tradicionales y capta dependencias temporales.	[24]
Predicción eólica basada en extracción de características meteorológicas y optimización.	LSTM optimizado.	Implementa selección de features y optimización bayesiana, mejorando RMSE y MAE.	[25]
Algoritmo de dos etapas para pronóstico de corto plazo.	CNN + LSTM.	La combinación de modelos mejora la robustez frente a cambios de régimen del viento.	[26]
Cálculo del límite de penetración eólica con flujo de potencia estocástico.	Modelos de optimización.	Evalúa cómo la variabilidad eólica afecta la estabilidad y el límite de penetración en redes eléctricas.	[27]
Evaluación de confiabilidad del sistema con penetración eólica.	Modelos de confiabilidad estocástica.	Determina que el exceso de penetración puede comprometer la reserva del sistema eléctrico.	[28]
Comparación entre aprendizaje automático y aprendizaje profundo en predicción eólica.	SVR, ANN, LSTM, GRU.	LSTM y GRU superan a SVR y ANN en precisión temporal y capacidad de aprender patrones reales.	[29]

De acuerdo con lo presentado en la tabla 2, existe una amplia variedad de modelos de predicción utilizados en el ámbito de la generación de energía eólica. Sin embargo, resulta fundamental comprender el contexto específico en el que estos modelos son aplicados. La selección de un modelo adecuado depende en gran medida del escenario específico de aplicación, donde se incluyen factores como la ubicación del parque eólico, las características meteorológicas de la zona, disponibilidad de datos, y los objetivos específicos de la predicción, ya sea para la gestión a corto, medio o largo plazo. La evaluación de un modelo de predicción usado en energía eólica no solo se mide por su desempeño predictivo, sino también por su capacidad para adaptarse a condiciones particulares del entorno en el que se utiliza.

En conclusión, la implementación de modelos de predicción para la producción de energía eólica basados en técnicas de aprendizaje automático representa una metodología cada vez más utilizada en las plantas eólicas. Estos modelos enfrentan desafíos de mejora continua, buscando contribuir de manera más eficiente en la predicción de la generación de energía. A medida que el sector de la energía eólica avanza, el desarrollo de nuevos modelos y la incorporación de la inteligencia artificial abrirán caminos hacia técnicas innovadoras que prometen una mayor eficiencia. Estas mejoras pueden ser fundamentales para optimizar la generación de energía eólica, asegurando así un aprovechamiento más efectivo de esta fuente renovable.

Capítulo 5 METODOLOGÍA

El desarrollo de este trabajo consiste en preparar adecuadamente los datos meteorológicos registrados en la zona donde se encuentra ubicada la turbina eólica, junto con los datos de generación, con el fin de simular modelos de aprendizaje automático como los son SVR, Árboles de decisión, LSTM y GRU de forma que se pueda evaluar el desempeño para uso en la predicción de energía eólica.

Por tanto, establecen los siguientes pasos para desarrollar el objetivo del documento:

- **Revisión de la literatura**

Se llevará a cabo un análisis exhaustivo de la literatura sobre la evolución de las técnicas de predicción de energía en parques eólicos, enfocándose en los avances en el análisis de datos meteorológicos obtenidos de dispositivos de medición y datos disponibles en plantas eólicas. Se recopilarán los modelos de aprendizaje automático que se utilizan a partir de la recolección de datos obtenidos del parque y la evaluación mediante métricas para comprender la precisión de las predicciones.

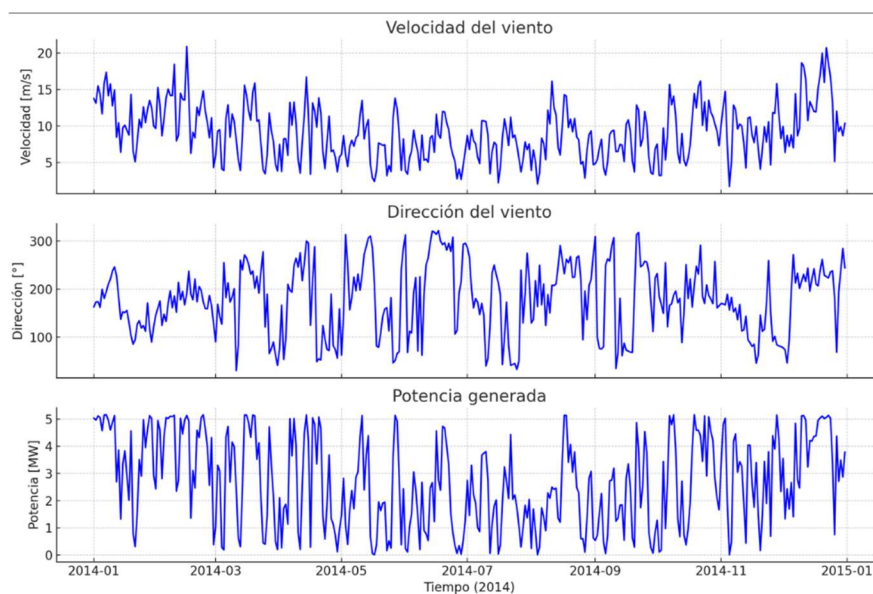
- **Recopilación y preprocesamiento de datos**

Se tomaron de referencia 525.600 registros minútales durante el año 2014 de velocidad del viento, dirección del viento tomada de las estaciones meteorológicas del parque y potencia generada a la salida de una turbina de 5 MW del parque eólico costa afuera denominado Alpha Ventus, ubicado en Alemania, Mar del Norte. No obstante, se mantuvo la integridad de la base de datos aplicando técnicas de extrapolación y completando los vacíos con el último dato real registrado, lo que permitió conservar la secuencia temporal de los datos.

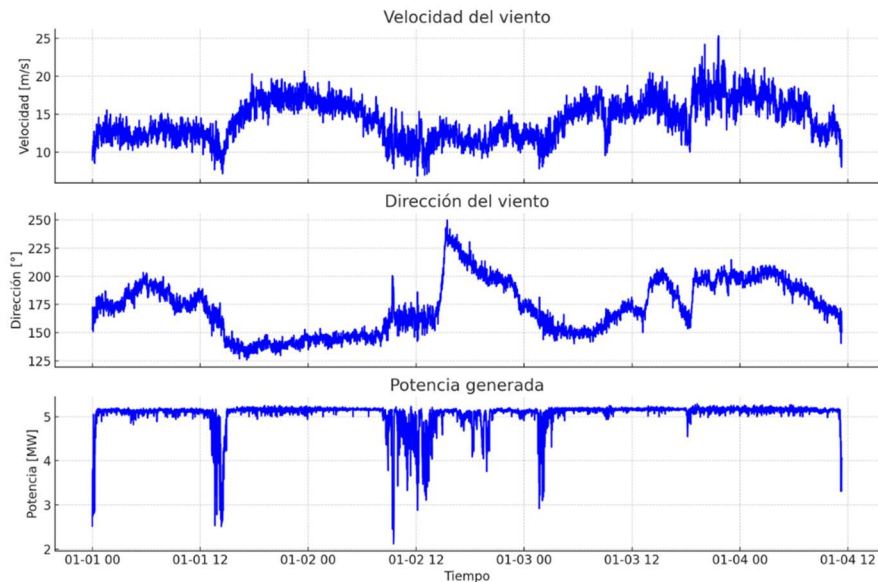
De acuerdo con lo anterior, se identificaron aproximadamente 31.545 valores atípicos (valores fuera del rango de las variables, valores negativos, letras) y vacíos. El error más representativo fue el valor 999999333 en las tres variables, el cual representó cerca del 81% de los datos atípicos, equivalente a 25.580 registros. Luego de aplicar la técnica

de extrapolación para completar la información, o en su defecto rellenar los datos faltantes con el valor inmediatamente precedente de la misma variable, en la gráfica 2 se observa el promedio diario de las diferentes variables obtenidas tras la limpieza de datos.

Adicionalmente, en la gráfica 3 se presenta un acercamiento a los cuatro primeros días del año 2014, mostrando los datos con resolución de un minuto después del proceso de limpieza. Se evidencia que dicha limpieza fue adecuada, ya que los valores se encuentran dentro de los rangos normales de potencia de la turbina, así como de velocidad y dirección del viento correspondientes al sitio de estudio.



Gráfica 2. Promedio diario de las variables meteorológicas y de generación obtenido tras la limpieza de datos.



Gráfica 3. Muestra minutal de los cuatro primeros días del año 2014 después del proceso de limpieza de datos.

En la tabla 3, se observan las variables de entrada y la variable de salida con las que se realizará el entrenamiento de los modelos.

Tabla 3. Selección de variables para entrenamiento de modelos.

Variable	Comentario
Fecha-Hora [dd-mm-AAAA hh:mm]	Registro de tiempo que denota el orden de los datos.
u [m/s]	Velocidad del viento con componente horizontal representada por $(Vel * \cos(dir))$. Variable de entrada.
v [m/s]	Velocidad del viento con componente vertical representada por $(Vel * \sin(dir))$. Variable de entrada.
Hora [hh:mm]	Representa la hora del día extraída de del registro de tiempo. Variable de entrada.
Velocidad_lag_5 [m/s]	Valor de velocidad de viento del pasado (5 minutos). Variable de entrada
Potencia_lag_5 [MW]	Valor de potencia generada del pasado (5 minutos). Variable de entrada.

Velocidad_roll_30 [m/s]	Valor promedio de velocidad de viento (últimos 30 minutos). Variable de entrada.
Potencia_roll_30 [MW]	Valor promedio de potencia generada (últimos 30 minutos). Variable de entrada.
Potencia [MW]	Potencia generada. Variable de salida.

- **Selección y entrenamiento del modelo**

Se contempla el uso de MATLAB para el entrenamiento, validación y testado de datos de los diferentes modelos seleccionados que tienen aplicación en predicciones de generación de energía eólica, dentro de los cuales, se tiene el modelo soporte vectorial de regresión, Árbol de Decisión, LSTM y GRU. En la tabla 4 se presenta el porcentaje de datos asignado a las etapas de entrenamiento, validación y prueba, distribuidos de manera cronológica, conforme a lo identificado en la revisión bibliográfica. En general, los estudios coinciden en que es fundamental disponer de una cantidad suficiente de datos para el entrenamiento, mientras que las etapas de validación y prueba se desarrollan con conjuntos de menor tamaño.

Tabla 4. Entrenamiento, validación y prueba de datos.

Modelo	Cantidad de datos	Porcentaje de datos
Entrenamiento	367920	70%
Validación	78840	15%
Prueba	78840	15%
Total	525600	100%

Por otro lado, para cada modelo seleccionado se realizaron simulaciones previas con el propósito de probar diferentes valores de hiperparámetros y, de esta forma, determinar con qué ajuste se obtenía el mejor desempeño al evaluar las métricas de rendimiento.

- **Validación y evaluación del modelo**

Se validará el modelo utilizando métricas estadísticas que suelen utilizarse en la evaluación de este tipo de modelos, como se puede observar en la tabla 5 para determinar su eficacia, dentro de estas métricas está: el RMSE, que refleja la magnitud de los errores del modelo; el MAE, que ofrece una medida promedio de los errores absolutos; y el coeficiente de determinación R^2 , que cuantifica qué tan bien las predicciones del modelo se ajustan a los datos reales.

Tabla 5. Variables para evaluar los modelos de predicción [30].

Variables	Descripción	Consideraciones
RMSE	Raíz del error cuadrático medio. El RMSE es siempre positivo y sus unidades coinciden con las unidades de la respuesta.	Se busca tener valores más pequeños del RMSE.
R^2	Coeficiente de determinación. R cuadrado es siempre menor que 1 y normalmente mayor que 0. Compara el modelo entrenado con el modelo en el que la respuesta es constante e igual a la media de la respuesta de entrenamiento. Si su modelo es peor que este modelo constante, R cuadrado es negativo.	Se busca un R^2 cercano a 1.
MSE	Error cuadrático medio. El MSE es el cuadrado del RMSE.	Se busca valores más pequeños del MSE.
MAE	Error medio absoluto. El MAE es siempre positivo y similar al RMSE, pero menos susceptible a los valores atípicos.	Se busca valores más pequeños del MAE.

- **Mejora y ajuste del modelo**

Basándose en los resultados de la fase de evaluación, se determinará si el modelo requiere ajustes o mejoras. Se detallarán los aspectos que pueden ser optimizados. Si no se requieren ajustes, se definirán las condiciones bajo las cuales opera el modelo y sus características específicas.

- **Conclusiones**

En esta fase final, se describirán los hallazgos clave, los desafíos enfrentados y los aprendizajes obtenidos durante la evaluación del modelo de predicción.

Capítulo 6 ENTRENAMIENTO DE LOS MODELOS Y RESULTADOS


En este capítulo, previo al entrenamiento, análisis y presentación de los resultados de los modelos, se incluye la información técnica de la turbina, complementada con la distribución Weibull de la velocidad de viento obtenida a partir de los datos de referencia de velocidad del viento correspondientes a la turbina de 5 MW, para comprender y entregar una mejor descripción del lugar de interés el cual se encuentra en la ubicación del parque Alpha Ventus al norte de Alemania. Con esto se calculan los valores de forma y escala que sirven para comprender la concentración y que frecuencia de velocidades del viento que se tienen en el lugar. De igual forma se obtiene la rosa de vientos a partir de los datos de dirección del viento para comprender las zonas y con qué frecuencia proviene el viento, en la práctica sirve para posicionar la turbina de forma estratégica y poder aprovechar en mayor medida la velocidad del viento de acuerdo con las direcciones predominantes.

En la tabla 6, se observan las características constructivas, eléctricas, mecánicas de la turbina eólica de la cual se obtuvieron los datos de potencia en sitio.

Tabla 6. Ficha técnica turbina AREVA M5000-116 [31].

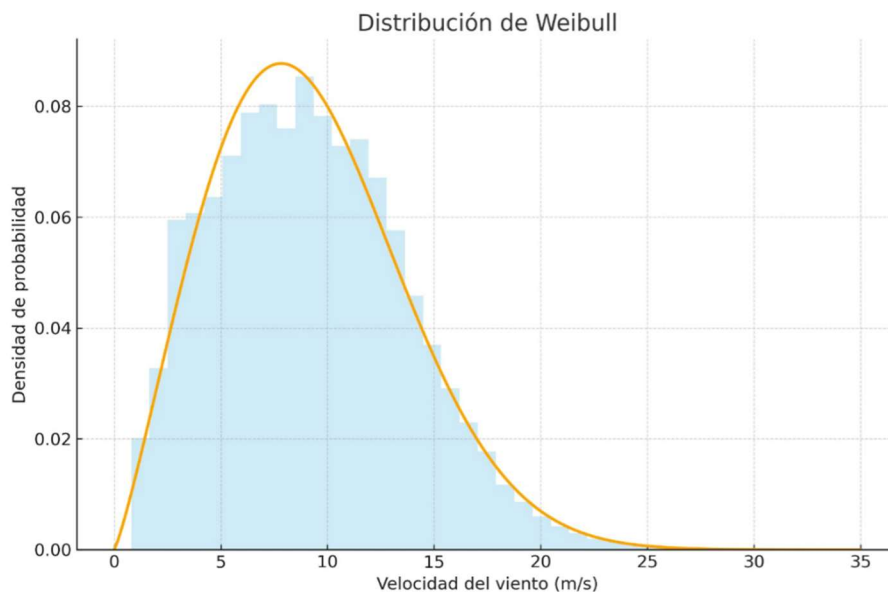
Categoría	Especificación
Fabricante	Areva (Francia)
Modelo	M5000-116
Potencia nominal	5 000 kW (5 MW)
Tipo de instalación	Offshore
Clase de viento	GL-TK 1 Offshore (DIBt III)
Número de palas	3
Control de potencia	Pitch
Área barrida del rotor	10 569 m ²
Área específica	2.12 m ² /kW
Diámetro del rotor	116 m
Fabricante del rotor	PN Rotor
Velocidad mínima del rotor	5.9 rpm
Velocidad máxima del rotor	14.8 rpm
Velocidad de corte (inicio)	4 m/s
Velocidad nominal	12.5 m/s
Velocidad de corte (parada)	25 m/s
Caja multiplicadora (Gear box)	Sí
Etapas	1
Relación de transmisión	10:01
Fabricante de la caja	RENK AG
Generador	Sincrónico de imanes permanentes (SYNC PM)
Número de generadores	1
Velocidad máxima del generador	148.5 rpm
Tensión nominal	3300 V
Altura del buje (hub)	90 m
Fabricante de la torre	Ambau
Peso de la góndola (nacelle)	246 ton
Peso del rotor + buje	110 ton
Peso de la torre	350 ton
Peso total aproximado	815 ton

En la gráfica 4, se observa la curva de potencia de la turbina AREVA M5000-116, a partir de la cual, y con base en la Tabla 6, es posible identificar fácilmente los valores de velocidad de arranque, nominal y de parada correspondientes a esta turbina.



Gráfica 4. Curva de potencia de la turbina AREVA M5000-116 [31].

En la gráfica 5 se presenta la distribución de Weibull, la cual permite identificar que las velocidades de viento más frecuentes en el sitio se encuentran en el intervalo de 6 a 12 m/s. Este rango resulta relevante para la selección de la turbina y para aprovechar al máximo su operación de acuerdo con su curva de potencia. No obstante, en este caso ya se cuenta con la referencia de la turbina instalada en el parque eólico.

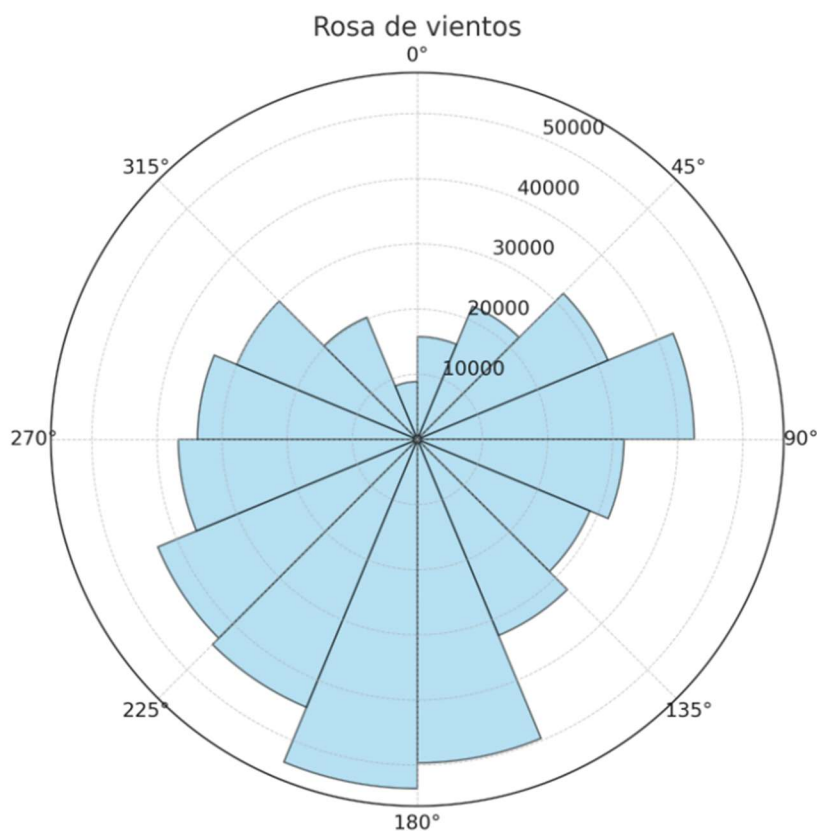


Gráfica 5. Distribución de Weibull datos de velocidad del viento.

De la gráfica 5, se obtienen los siguientes factores:

- Factor de forma (k): 2.18, lo cual indica que la distribución tiene una forma más simétrica y se acerca a la distribución normal. En este caso, los valores medios de velocidad del viento son más frecuentes, predecibles y estable.
- Factor de escala (A): 10.37 m/s, lo cual indica la velocidad promedio del lugar seleccionado.

De igual forma, en la gráfica 6 se presente la rosa de vientos para los datos de dirección de viento tomados de referencia, de los cuales se tiene que la mayor frecuencia de estos datos se encuentra cercanos a la dirección sur, siendo esta la dirección predominante para posicionar de manera óptima la turbina.



Gráfica 6. Rosa de vientos datos de dirección de viento.

A continuación, se presentan las gráficas correspondientes para cada modelo, las cuales permiten realizar el análisis y la comparación entre los modelos.

Modelo Soporte Vectorial de Regresión


Este modelo se apoya en la función Kernel Gaussiana, la cual permite operar en un espacio con datos que contienen muchas variables, sin necesidad de calcular dicho espacio de forma explícita, lo que le permite al modelo aprender relaciones no lineales entre las variables de entrada y salida. Dentro de la función Kernel, se encuentra la función Kernel Gaussiana, la cual es comúnmente utilizada en regresión para aplicaciones eólicas porque modela relaciones suaves y continuas como las hay entre los datos de viento y potencia.

En la tabla 7 y en la gráfica 7 se observa la variación de los hiperparámetros y los resultados obtenidos de las métricas de evaluación del modelo de Soporte Vectorial de Regresión (SVR). De acuerdo con lo reportado en la literatura, se realizaron ajustes en los parámetros (C), (ϵ), con el fin de seleccionar la configuración que alcanzara el mejor desempeño en las métricas evaluadas.

Para interpretar adecuadamente los valores de error (RMSE, MSE y MAE) es importante considerar que la variable objetivo, la Potencia generada, se encuentra expresada en unidades de megavatios (MW).

Tabla 7. Comparación de hiperparámetros modelo SVR.

Hiperparámetros	RMSE	MSE	MAE	R2
SVR_1: C=1, ϵ =0.10	0.3587	0.12867	0.21008	0.96383
SVR_2: C=10, ϵ =0.05	0.35784	0.12805	0.20401	0.96400
SVR_3: C=20, ϵ =0.03	0.35918	0.12901	0.20214	0.96373
SVR_4: C=30, ϵ =0.02	0.36039	0.12988	0.2034	0.96349



Gráfica 7. Comparación de hiperparámetros modelo Soporte Vectorial de Regresión.

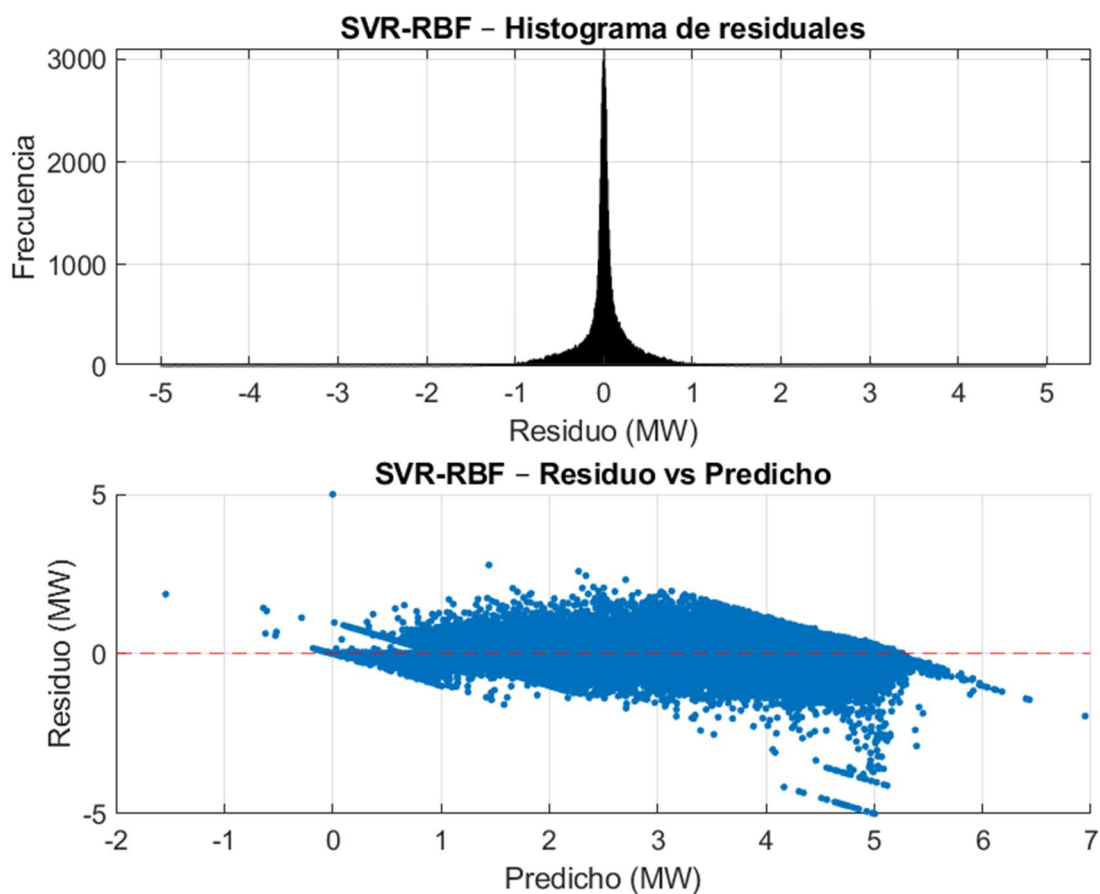
En la tabla 8 se observa el ajuste del SVR_2, que obtuvo mejor desempeño en las métricas evaluadas para realizar las respectivas simulaciones.

Tabla 8. Ajuste de parámetros modelo Soporte Vectorial de Regresión.

Parámetro	Ajuste	Comentario
Función Kernel	Gaussiana	Introduce no linealidad para captar relaciones entre variables de entrada y salida.
Escala Kernel	Auto	Se controla el grado de curvatura, con este ajuste, Matlab estima la dispersión acorde a la dispersión de los datos para equilibrar sesgo/varianza.
BoxConstraint (C)	10	Regula que tanto permite desviaciones el modelo, con este ajuste se penalizan los datos atípicos moderadamente.
Epsilon (ϵ)	0.05	Se calibra y define que errores considera tolerables, con este ajuste se tiene tubo de insensibilidad aproximadamente del 5% MW.


En la gráfica 8 se observa el histograma residual y los residuos versus lo predicho. En la primera parte se muestra cómo se distribuyen los errores al momento de realizar las

predicciones frente a los datos reales, donde la mayor concentración de valores se encuentra cercana a cero, lo cual indica que el modelo comete errores pequeños tanto hacia arriba como hacia abajo, con una dispersión muy concentrada alrededor de los 0,2 MW. Por otro lado, al analizar los residuos frente a los valores predichos se observa una dispersión creciente donde, para potencias bajas, los residuos son positivos lo cual indica que el modelo se queda corto, mientras que en potencias altas los residuos se vuelven negativos en otras palabras el modelo se pasa. Esto quiere decir que el SVR tiende a sobrepredecir en niveles altos de potencia, evidenciando un sesgo leve en el rango nominal. En términos generales, el comportamiento es bueno en el centro, aunque tolerable en los extremos, debido a la dispersión de los residuos que hace crecer los errores con la potencia.



Gráfica 8. Histograma y residuos modelo Soporte Vectorial de Regresión.


En la gráfica 9, correspondiente a los valores reales frente a los valores predichos, se observa que los puntos se alinean en torno a la línea diagonal, lo cual indica un ajuste global adecuado. Sin embargo, en potencias cercanas a la nominal (alrededor de 5 MW) los puntos se ubican por debajo de la línea roja, mostrando que el modelo subpredice en esa zona, mientras que para potencias bajas tiende a sobrepredicir. Esto sugiere que el modelo no termina de capturar correctamente la potencia nominal de generación, por lo que conviene limitar sus salidas a valores menores o iguales a la potencia nominal.



Gráfica 9. Comparación real vs predicción modelo Soporte Vectorial de Regresión.

Finalmente, en la gráfica 10, donde se muestra la serie temporal de los últimos 2000 puntos equivalentes a día y medio de información, el modelo sigue de forma adecuada la tendencia de los datos reales. No obstante, se aprecia que, ante rampas ascendentes

rápidas, el SVR presenta un ligero retraso y, en las zonas altas de generación sobreestima ligeramente la potencia. Este comportamiento es esperable en modelos no secuenciales, por lo que su desempeño general se considera bueno, aunque con oportunidad de mejora en la respuesta dinámica.



Gráfica 10. Predicción Modelo Soporte Vectorial de Regresión.

Modelo Árbol de Decisión

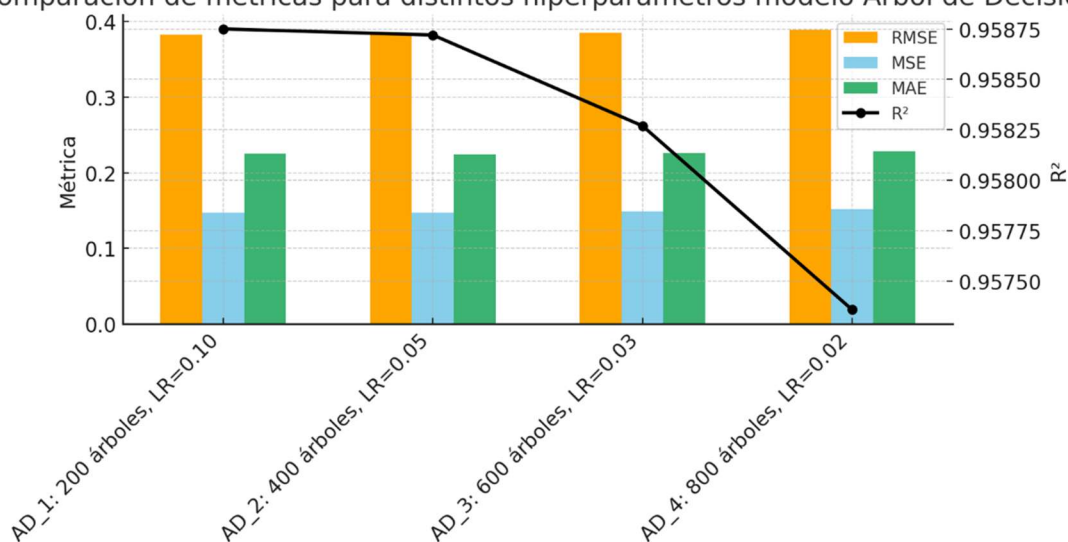
En este caso se utiliza un ensamble secuencial de árboles de decisión utilizando el método LSBoost, el cual es una técnica de aprendizaje que utiliza el enfoque gradient boosting para minimizar el MSE, esta configuración de integrar el método LSBoost con un ensamble secuencial de árboles busca corregir los errores paso a paso, capturando no linealidades de manera secuencial lo cual sirve de entrenamiento para cada nuevo árbol aprendiendo del cálculo de los errores previos en los anteriores árboles.

En la tabla 9 y en la gráfica 11 se observa la variación de los hiperparámetros y los resultados obtenidos de las métricas de evaluación del modelo.

Tabla 9. Comparación hiperparámetros modelo Árbol de decisión.

Hiperparámetros	RMSE	MSE	MAE	R2
AD 1: 200 árboles, LR=0.10	0.38307	0.14674	0.2251	0.95875
AD 2: 400 árboles, LR=0.05	0.38318	0.14683	0.22441	0.95872
AD 3: 600 árboles, LR=0.03	0.38525	0.14842	0.22573	0.95827
AD 4: 800 árboles, LR=0.02	0.38946	0.15168	0.22834	0.95736

Comparación de métricas para distintos hiperparámetros modelo Árbol de Decisión



Gráfica 11. Comparación de hiperparámetros modelo Árbol de decisión.


En la tabla 10 se observa el ajuste seleccionado (AD_1), del cual se tuvo mejor desempeño en las métricas seleccionadas.

Tabla 10. Ajuste de parámetros modelo Árbol de decisión.

Parámetro	Ajuste	Comentario
Método	LSBoost	Se utiliza el método LSBoost como técnica de aprendizaje en conjunto para minimizar el error MSE.
Número de árboles	200	Con este valor se equilibra el tiempo de respuesta y el sobreajuste que puede llegar a tener el modelo.

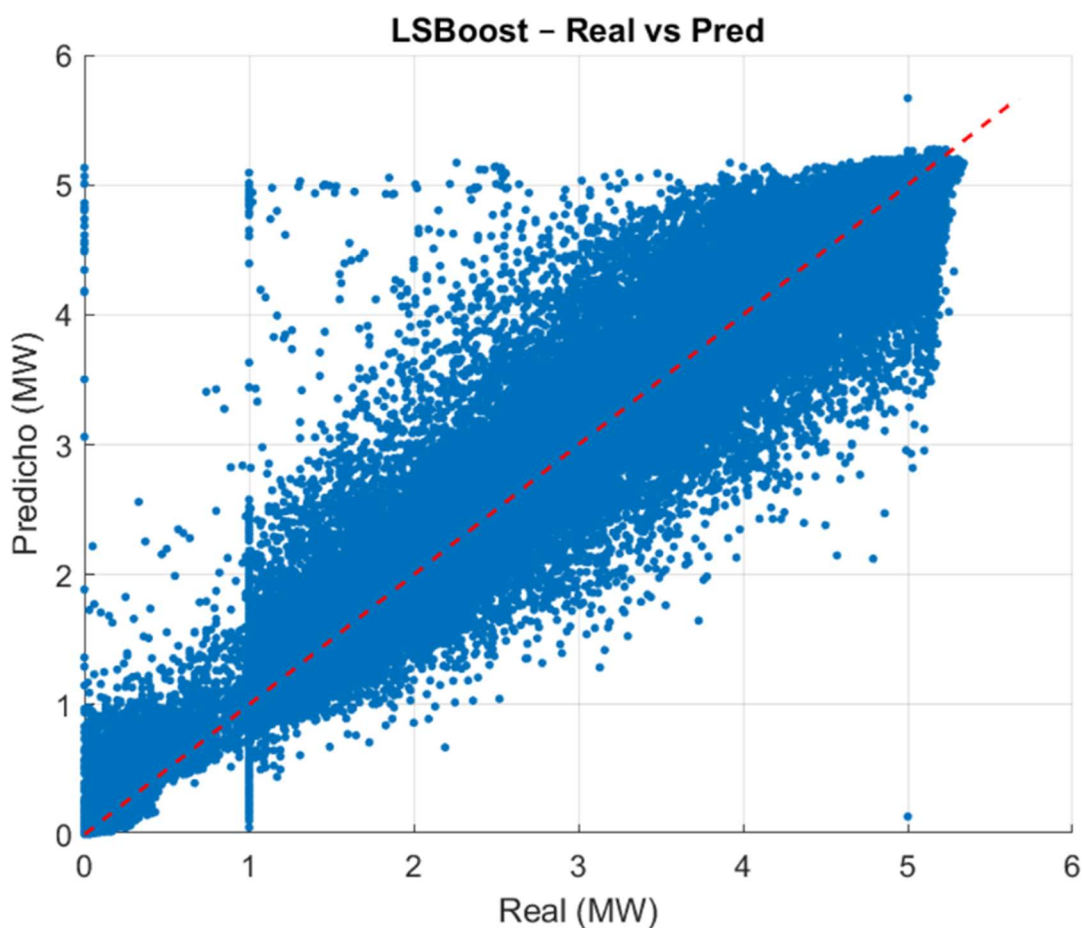
LearnRate (tasa de aprendizaje)	0.1	Este ajuste permite un balance entre el tiempo que puede tomar el aprendizaje y la precisión del modelo, de acuerdo con el número de árboles seleccionados.
------------------------------------	-----	---

En la gráfica 12, se representa el histograma de residuales y los residuos frente a lo predicho, se aprecia una distribución centrada en cero, con un pico pronunciado que demuestra una buena precisión global. Sin embargo, las colas son más pobladas que en el SVR, lo que significa que este modelo es más sensible a valores atípicos. Además, se mantiene el mismo patrón de sesgo; residuos negativos para potencias altas, lo cual indica sobrepredicción en el rango nominal. Aun así, la calibración general es buena y el comportamiento puede considerarse tolerable.



Gráfica 12. Histograma y residuos modelo Árbol de decisión.

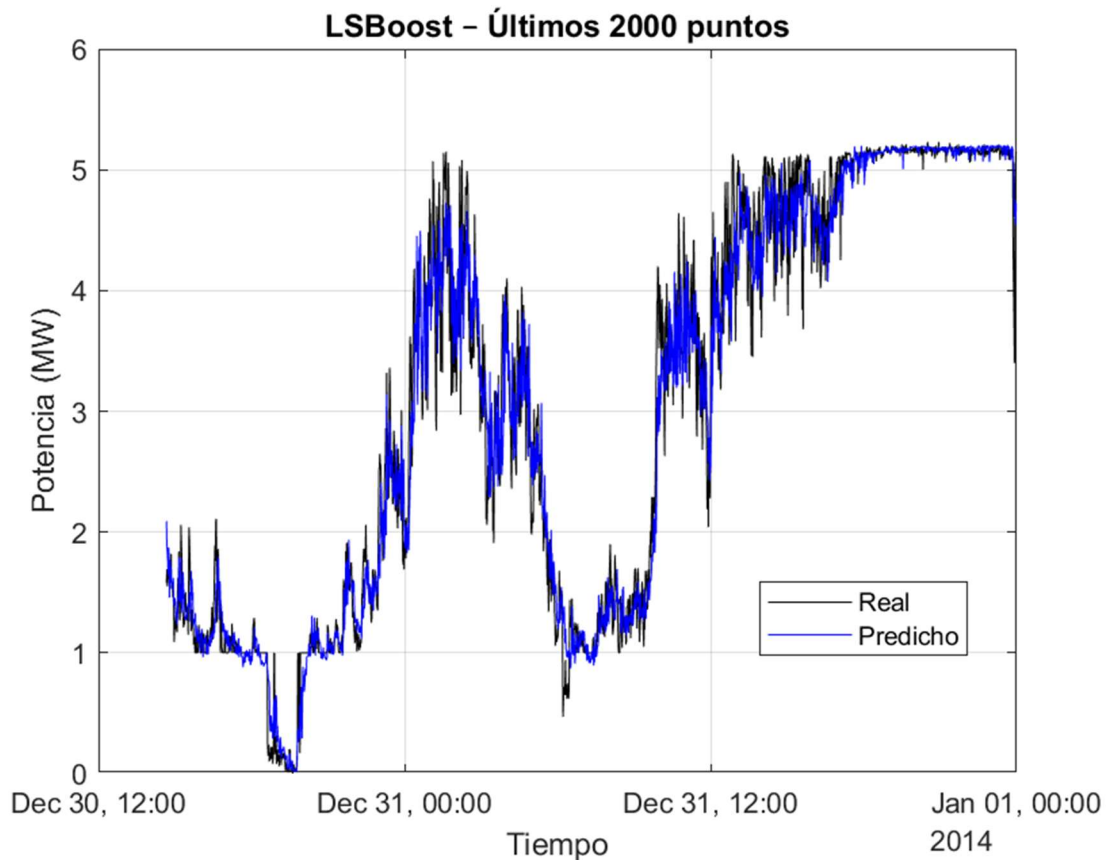
En la gráfica 13, donde se comparan los valores reales contra los predichos, los puntos siguen la diagonal con relativa fidelidad, aunque existe una mayor dispersión. Se conserva la tendencia observada anteriormente: sobrepredicción en potencias bajas y subpredicción en potencias altas. En términos generales, el modelo muestra un ajuste aceptable, aunque presenta una ligera desviación al no contar con una restricción que impida generar valores fuera del rango físicamente posible.



Gráfica 13. Comparación real vs predicción modelo Árbol de decisión.

Por último, en la gráfica 14 donde se tiene la serie temporal de lo real versus lo predicho, se observa que el modelo reproduce adecuadamente el comportamiento real de la potencia, pero con un nivel de ruido mayor y una respuesta algo más irregular en las transiciones rápidas. Esto refleja que el modelo capta la forma global de generación, aunque presenta picos locales y sobreajustes propios de los ensambles de árboles. En

conjunto, su rendimiento se considera tolerable, destacando que requiere mayor regularización para estabilizar las predicciones, lo cual se traduce en que el modelo es bueno para los datos que ya conoció, pero levemente errático con datos nuevos.



Gráfica 14. Predicción Modelo Árbol de decisión.

Modelo LSTM


Este modelo de Red recurrente LSTM con memoria se caracteriza por tener puertas de entrada, olvido y salida, las cuales son mecanismos de control interno del modelo donde su función es decidir cuanta información entra, cuanta se conserva, cuanta se elimina o sale hacia la siguiente capa, con esto se pueden capturar dependencias temporales y variaciones graduales en los datos. Para este caso se toma sesenta muestras minútales consecutivas del pasado que equivalen a una hora de datos para predecir el valor futuro,

de modo que aprende cómo evoluciona la variable en estos sesenta pasos antes de hacer la predicción; este intervalo permite capturar adecuadamente la evolución reciente de la variable, considerando que los cambios en la velocidad del viento suelen manifestarse de manera gradual dentro de este horizonte temporal, lo anterior es importante para captar patrones temporales de las variables de entrada, se puede aumentar el valor de la ventana (sesenta muestras minútales), pero esto aumenta la complejidad y el riesgo de incluir ruido irrelevante en el modelo.

En la tabla 11 y en la gráfica 15 se observa la variación de los hiperparámetros de acuerdo con lo encontrado en la literatura para el modelo LSTM con sus respectivos resultados de las métricas de evaluación.

Tabla 11. Comparación de hiperparámetros modelo LSTM.

Hiperparámetros	RMSE	MSE	MAE	R2
LSTM_1: U=32, FC=16, ME=15, MBS=256	0.22937	0.052611	0.1426	0.98521
LSTM_2: U=64, FC=32, ME=20, MBS=256	0.19874	0.039499	0.12108	0.9889
LSTM_3: U=96, FC=32, ME=25, MBS=256	0.1899	0.036062	0.11933	0.98987



Gráfica 15. Comparación de hiperparámetros modelo LSTM.

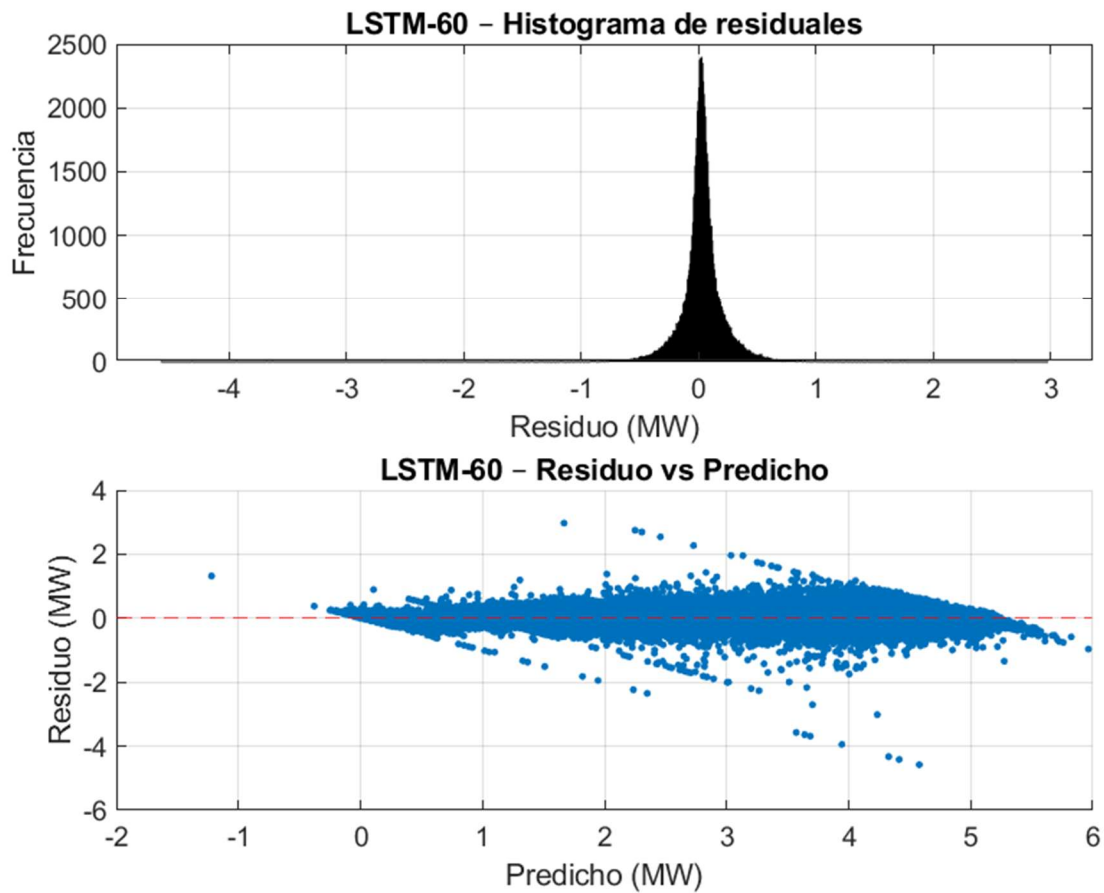
En la tabla 12 se observa los valores ajustados para realizar la respectiva simulación del modelo LSTM, donde el ajuste LSTM_3 tuvo un mejor desempeño de acuerdo con los resultados de evaluación de las métricas seleccionadas.

Tabla 12. Ajuste de parámetros modelo LSTM.

Parámetro	Ajuste	Comentario
LstmLayer (U)	96	Es la capa recurrente que memoriza dependencias temporales, representa cantidad de neuronas que procesan la secuencia, este valor tiene un equilibrio entre capacidad y uso computacional.
FullyConnectedLayer	32	Es una capa intermedia que toma la salida del lstmLayer (64) y lo proyecta en un espacio más pequeño ayudando a mejorar lo aprendido antes de predecir la salida final.
FullyConnectedLayer	1	Transforma la salida anterior (32) en único valor escalar de modo que convierte la representación abstracta en el valor numérico final.
ReluLayer	ReLu	Uso de esta función para añadir no linealidad y permite que la red aprenda relaciones complejas lo cual evita saturación de gradientes y acelera el entrenamiento del modelo.
SeqLen	60	La red ve 60 pasos temporales previos antes de predecir, capturando rampas y persistencias sin recursos adicionales computacionales.
Optimizer	Adam	Optimiza la conexión entre neuronas ajustando el gradiente adaptativamente, de forma que converge rápido y es estable.
MaxEpochs	25	Hace referencia al número de iteraciones para realizar validaciones, sin embargo, si la validación se estabiliza puede detenerse en una menor iteración.

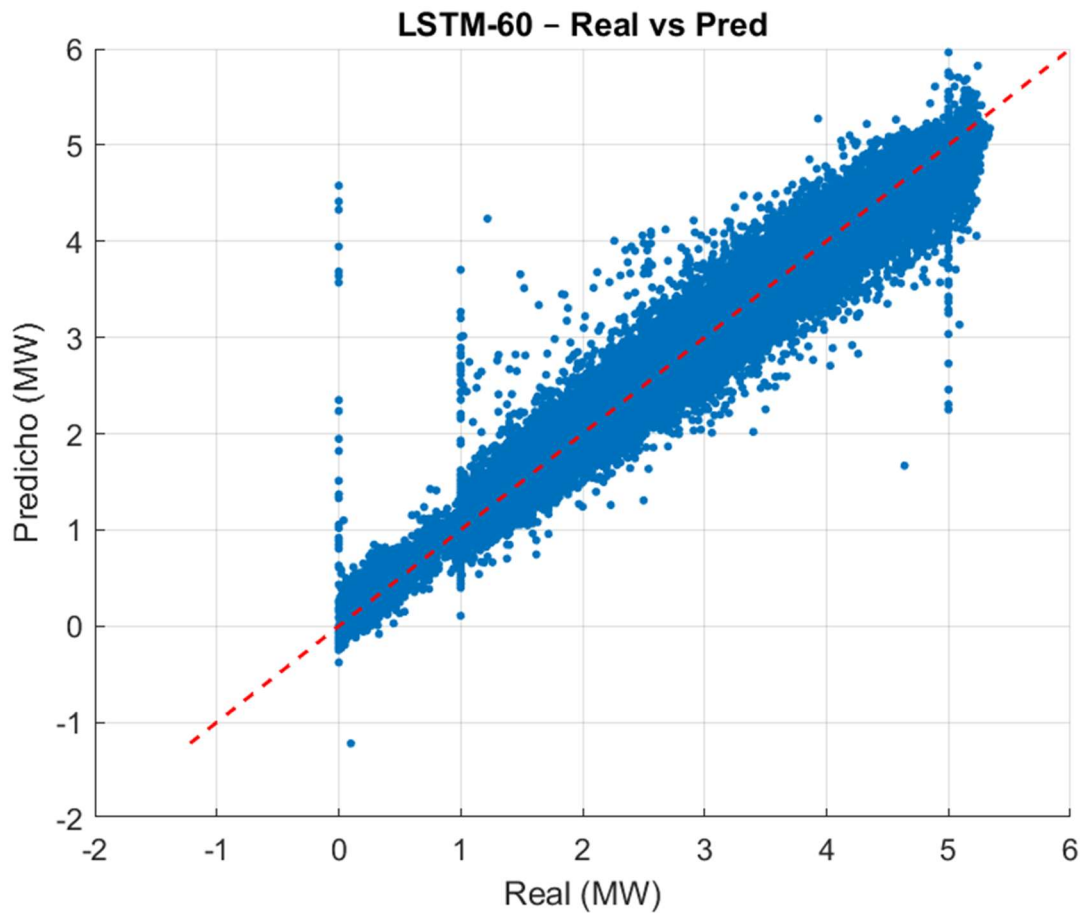
MiniBatchSize	256	Tiene que ver con la cantidad de secuencias procesadas por iteración antes de actualizar las conexiones entre neuronas, con este ajuste se equilibra la estabilidad del gradiente y eficiencia de cálculo.
---------------	-----	--

En la gráfica 16 se muestra el histograma residual junto con los residuos versus lo predicho. La mayor densidad de residuos se concentra en torno a cero, indicando un excelente nivel de calibración y una clara reducción en la dispersión de errores respecto a los modelos anteriores. En el histograma los residuos se concentran de una manera más estrecha y simétrica, lo que significa que el modelo no solo reduce el sesgo, sino que también mejora la estabilidad de los errores en todo el rango de potencia. Aunque se percibe un leve sesgo negativo en potencias altas, este es menor en magnitud. En conjunto, el comportamiento del LSTM se evalúa como muy bueno.




Gráfica 16. Histograma y residuos modelo LSTM.

En la gráfica 17, correspondiente a los valores reales frente a los predichos, los puntos azules se distribuyen de forma más compacta alrededor de la diagonal roja. Esto indica que el modelo ha logrado aprender mejor la relación no lineal entre las variables de entrada y la potencia generada, reduciendo los desvíos tanto en bajas como en altas potencias. Aunque todavía se observan algunos puntos que superan los 5 MW, el modelo generaliza de forma adecuada. En esta gráfica el desempeño se considera muy bueno.



Gráfica 17. Comparación real vs predicción modelo LSTM.

En la gráfica 18 se presenta la serie temporal, en la cual se observa un seguimiento que refleja de muy bien el comportamiento real de potencia, con menor retraso en las rampas y mejor estabilidad en los picos de potencia. La red LSTM logra reproducir la dinámica intradiaria con precisión, suavizando las oscilaciones más pequeñas sin perder detalle de la señal. Por tanto, se puede concluir que este modelo ofrece un rendimiento muy bueno, mostrando un balance adecuado entre precisión y estabilidad temporal.



Gráfica 18. Predicción Modelo LSTM.

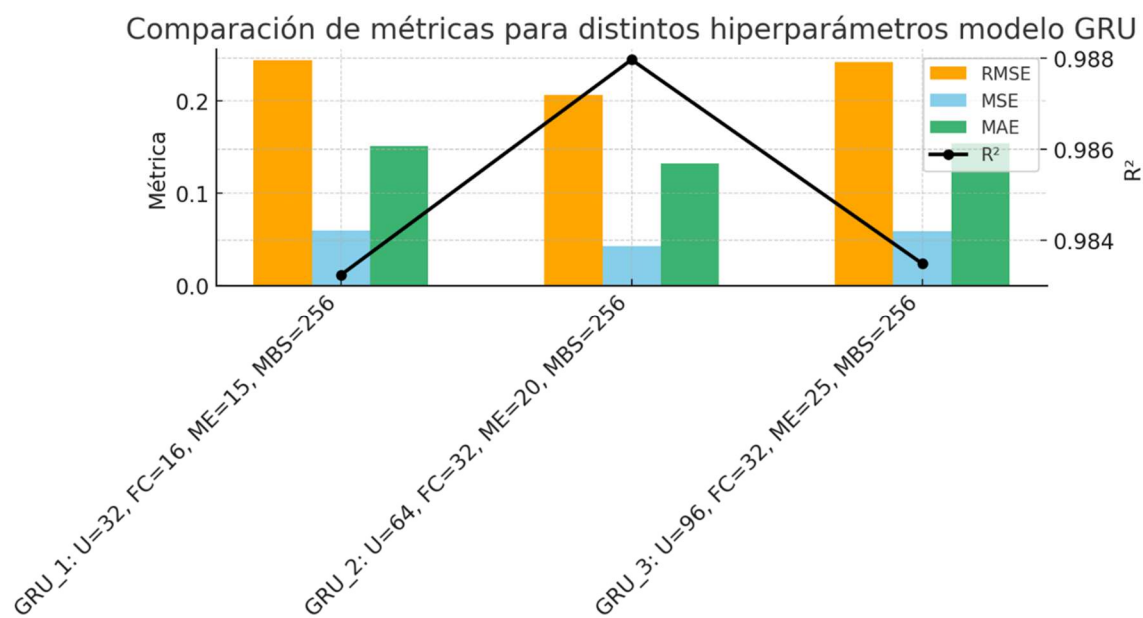
Modelo GRU

Este modelo de red recurrente GRU se caracteriza por tener puertas de actualización y reinicio, lo que le permite mantener dependencias temporales de manera eficiente con una estructura más ligera que la LSTM. A diferencia de esta última, la GRU cuenta con menos parámetros, por lo que su entrenamiento es más rápido sin comprometer significativamente el desempeño. En este caso, se utilizan sesenta muestras minútales consecutivas del pasado equivalentes a una hora de datos para predecir el valor futuro. Este enfoque resulta adecuado cuando se requiere reducir el tiempo de cómputo o realizar iteraciones rápidas, manteniendo buenas prácticas como la validación temporal, la normalización de datos y la prevención de fuga de información.

En la tabla 13 y en la gráfica 19 se observa la variación de los hiperparámetros de acuerdo con lo encontrado en la revisión bibliográfica y los resultados obtenidos de las métricas evaluadas.

Tabla 13. Comparación de hiperparámetros modelo GRU.

Hiperparámetros	RMSE	MSE	MAE	R2
GRU 1: U=32, FC=16, ME=15, MBS=256	0.24426	0.059662	0.15118	0.98323
GRU 2: U=64, FC=32, ME=20, MBS=256	0.20687	0.042797	0.13241	0.98797
GRU 3: U=96, FC=32, ME=25, MBS=256	0.24245	0.05878	0.15418	0.98348



Gráfica 19. Comparación de hiperparámetros modelo GRU.

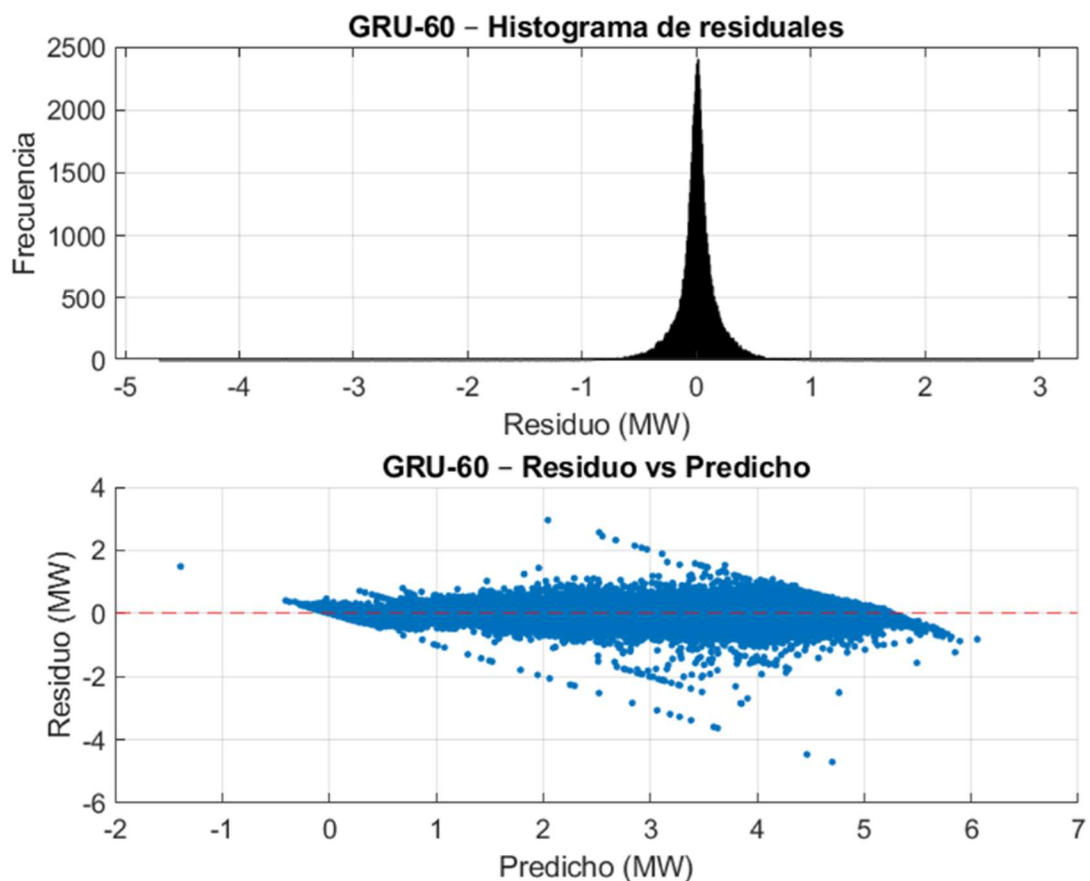
En la Tabla 14 se presenta el ajuste realizado a los hiperparámetros del modelo GRU, de acuerdo con los resultados obtenidos en las métricas de evaluación, donde el modelo GRU_2 mostró el mejor desempeño.

Tabla 14. Ajuste de parámetros modelo GRU.

Parámetro	Ajuste	Comentario
LstmLayer (U)	64	Es la capa recurrente que memoriza dependencias temporales, representa cantidad de neuronas que procesan la secuencia, este valor tiene un equilibrio entre capacidad y uso computacional.
FullyConnectedLayer (FC)	32	Es una capa intermedia que toma la salida del lstmLayer (64) y lo proyecta en un espacio más pequeño ayudando a mejorar lo aprendido antes de predecir la salida final.
FullyConnectedLayer	1	Transforma la salida anterior (32) en único valor escalar de modo que convierte la representación abstracta en el valor numérico final.
ReluLayer	ReLu	Uso de esta función para añadir no linealidad y permite que la red aprenda relaciones complejas lo cual evita saturación de gradientes y acelera el entrenamiento del modelo.
SeqLen	60	La red ve 60 pasos temporales previos antes de predecir, capturando rampas y persistencias sin recursos adicionales computacionales.
Optimizer	Adam	Optimiza la conexión entre neuronas ajustando el gradiente adaptativamente, de forma que converge rápido y es estable.
MaxEpochs (ME)	20	Hace referencia al número de iteraciones para realizar validaciones, sin embargo, si la validación se estabiliza puede detenerse en una menor iteración.
MiniBatchSize (MBS)	256	Tiene que ver con la cantidad de secuencias procesadas por iteración antes de actualizar las conexiones entre neuronas, con este ajuste se equilibra la estabilidad del gradiente y eficiencia de cálculo.

En la gráfica 20 se observa el histograma residual y los residuos versus lo predicho. La distribución presenta un pico central muy concentrado y colas controladas, lo cual refleja

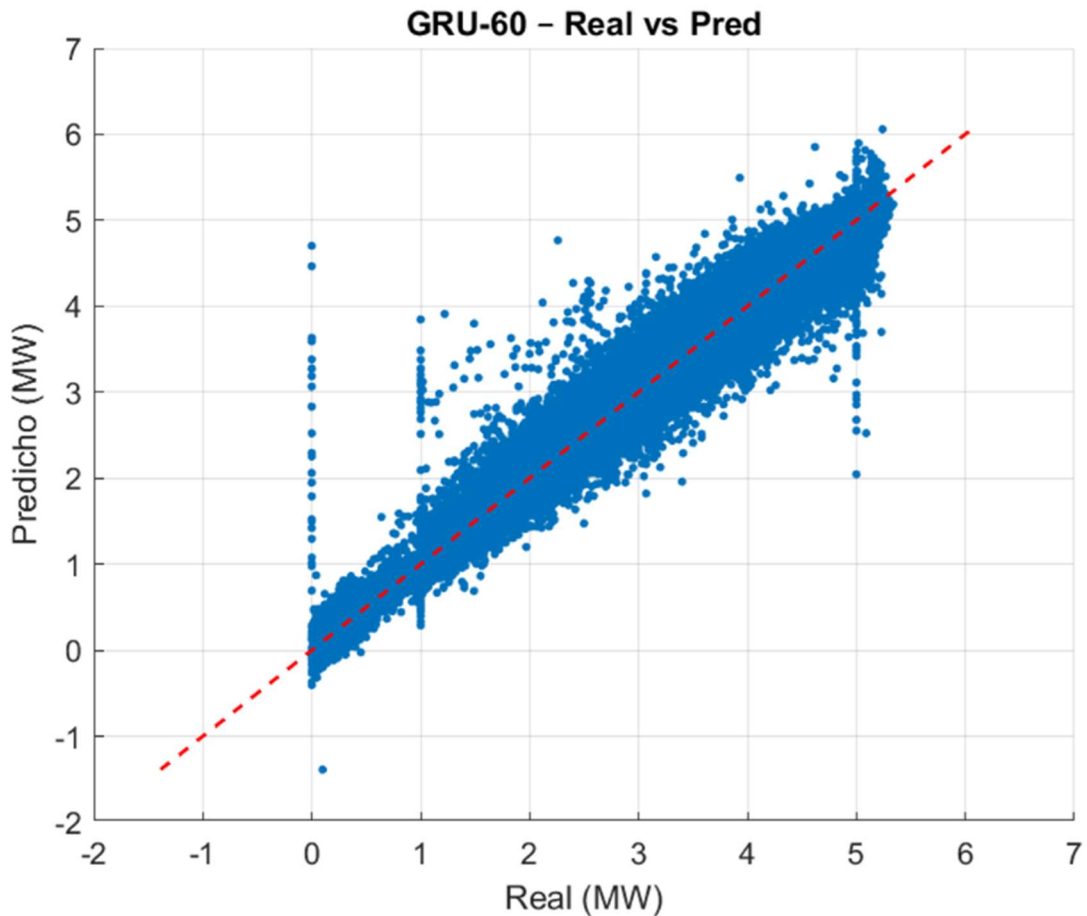
una excelente calibración del modelo. Los residuos negativos en potencias altas son muy pocos, lo que indica que el sesgo en la zona nominal es mínimo. La dispersión total es menor que en los modelos anteriores, mostrando que el GRU posee mayor consistencia y robustez frente a variaciones rápidas. Por este motivo, se considera un comportamiento muy bueno en términos de ajuste y estabilidad.



Gráfica 20. Histograma y residuos modelo GRU.


En la gráfica 21, donde se muestran los valores reales frente a los predichos, los puntos se agrupan estrechamente alrededor de la línea diagonal. El modelo aprende correctamente la tendencia general y logra reducir el sesgo negativo que persistía en la LSTM. La correlación entre valores reales y predichos es alta, y los errores visibles se concentran en los márgenes, sin desviaciones significativas. Esta gráfica representa un

desempeño excelente, siendo el GRU el modelo al igual que el LSTM con mejor equilibrio entre precisión y generalización.



Gráfica 21. Comparación real vs predicción modelo GRU.

Finalmente, en la gráfica 22 se observa la serie temporal, donde el modelo reproduce con gran exactitud el comportamiento real de la potencia generada. Se aprecia un seguimiento casi idéntico entre la línea real y la predicha, con respuesta rápida ante rampas y sin sobrepasar la potencia nominal. El GRU mantiene la suavidad en la curva sin perder capacidad de respuesta, lo cual demuestra que logra un balance perfecto entre estabilidad y detalle. En conjunto, el modelo GRU presenta un desempeño excelente, consolidándose al igual que el modelo LSTM como la mejor alternativa entre los modelos analizados.



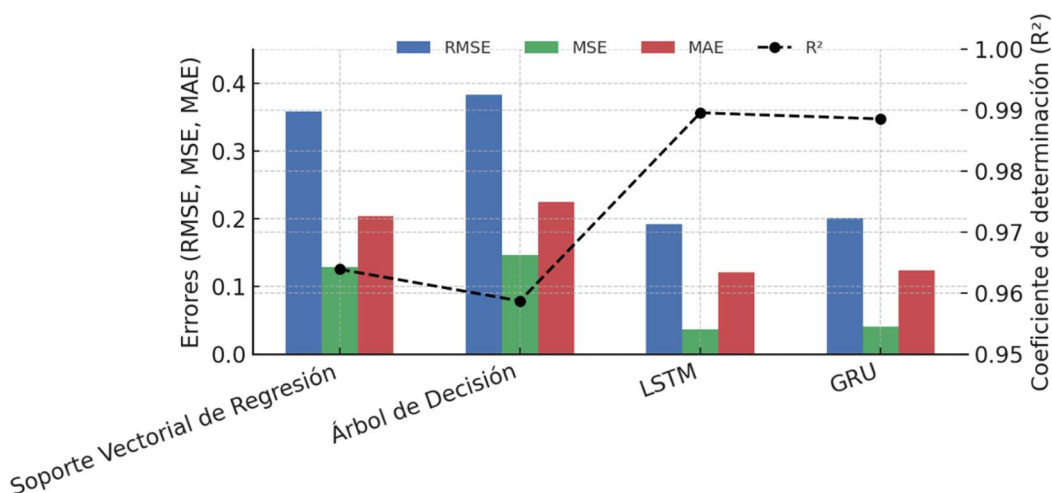
Grafica 22. Predicción Modelo GRU.

En la tabla 15 y la gráfica 23 se presentan los resultados de las métricas utilizadas para evaluar el desempeño de los diferentes modelos aplicados. Se observa que los modelos secuenciales LSTM y GRU presentan un comportamiento significativamente superior frente a los modelos de regresión entrenados, reflejándose en valores más bajos de error (RMSE, MSE y MAE) y R^2 muy cercanos a uno, lo que indica una excelente capacidad de ajuste y predicción. De acuerdo con los resultados, el modelo LSTM es el que muestra mejor desempeño global, seguido muy de cerca por el modelo GRU, lo cual coincide con los hallazgos reportados en la literatura y valida la efectividad de las arquitecturas recurrentes para el pronóstico de potencia eólica.

Tabla 15. Resultados de las métricas para cada modelo.

Modelo	RMSE	MSE	MAE	R ²
Soporte Vectorial de Regresión	0.3578	0.1280	0.2040	0.9640
Árbol de Decisión	0.3830	0.1467	0.2251	0.9587
LSTM	0.1899	0.0360	0.1193	0.9898
GRU	0.2068	0.0427	0.1324	0.9879

Desempeño comparativo de modelos de predicción



Gráfica 23. Desempeño comparativo de los modelos seleccionados.

Adicional a los valores obtenidos en las métricas RMSE, MAE y R², los resultados alcanzados permiten analizar la viabilidad operativa de estos modelos para pronosticar la potencia generada y de esta forma tener un valor más acertado al Mercado de Energía Mayorista, particularmente en el contexto de la predicción de potencia eólica para la participación en esquemas de despacho al momento de dar su pronóstico de capacidad diaria.

Por un lado, se tienen los bajos errores de predicción y los altos valores de R² que evidencian que los modelos LSTM y GRU capturan de forma efectiva la dinámica temporal y no lineal del recurso energético. Esto implica que pueden anticipar con buena precisión las rampas de generación o caídas abruptas, lo cual es fundamental en el mercado para minimizar penalizaciones asociadas a desvíos entre la energía comprometida y la realmente entregada.

Desde el punto de vista operativo, estos modelos pueden integrarse a un sistema de gestión de energía (EMS) o a una plataforma de predicción intradiaria, alimentándose de datos SCADA en tiempo real (velocidad y dirección del viento, irradiancia, temperatura, etc.) y actualizando continuamente las predicciones a horizontes de 1–24 h.

En este esquema, el modelo LSTM o GRU se ejecutaría automáticamente en un servidor o nube, generando pronósticos cada pocos minutos. Los resultados podrían luego ser usados por el operador de planta o el agente comercializador para ajustar sus ofertas en el mercado intradiario.

Además, la diferencia en desempeño entre modelos como, por ejemplo, el SVR frente a las redes recurrentes, demuestra que los métodos basados en aprendizaje profundo tienen mayor capacidad para adaptarse a condiciones meteorológicas cambiantes, lo que mejora la confiabilidad del sistema frente a la variabilidad inherente de las fuentes renovables.

CONCLUSIONES

En la revisión de la literatura sobre modelos de predicción de energía eólica, se identificaron distintas técnicas que han evolucionado a lo largo de los años. Se destaca que varios estudios han implementados modelos de predicción basados en métodos físicos, series temporales, redes neuronales, híbridos, entre otros, que han demostrado un desempeño destacado en la estimación de potencia eólica. Con base en estos resultados, se seleccionaron modelos más representativos y se implementaron en la herramienta Matlab para su evaluación comparativa.

Los modelos de regresión (Soporte vectorial y Árbol de Decisión) presentaron un desempeño aceptable superior al 75% en rangos de potencia bajos, pero no lograron representar de forma adecuada las variaciones cercanas a la potencia nominal, limitando su uso para predicciones de corto plazo.

Los resultados obtenidos evidencian que el uso de modelos de aprendizaje profundo, particularmente LSTM y GRU, representa de mejor manera la relación entre las variables de entrada y la potencia generada, en comparación con métodos tradicionales como el Árbol de Decisión o el Soporte Vectorial de Regresión (SVR). Asimismo, los modelos LSTM y GRU presentan un margen de error muy reducido, cercano al 2 %, lo que se traduce en una alta confiabilidad operativa y una posible mayor estabilidad en la red eléctrica con el pronóstico de potencia estimado.

En la práctica, la incorporación de estos modelos en los sistemas de gestión de energía de las plantas eólicas permitiría a los operadores actualizar sus ofertas de generación cada hora, ajustando la potencia comprometida con base en la predicción del recurso. Esto es especialmente relevante en el contexto de la futura implementación del mercado intradiario colombiano (CREG 174/2021 y 1862/2024), donde la precisión de los pronósticos será un factor determinante para la competitividad de los generadores no convencionales. De este modo, los modelos propuestos no solo optimizan la programación energética, sino que aumentarían la rentabilidad y reducen la exposición al riesgo financiero por desviaciones entre energía programada y real.

Los resultados obtenidos concuerdan con la literatura encontrada, donde las redes recurrentes se destacan por su habilidad para modelar dependencias temporales en series de tiempo que en este caso tienen aplicación en el campo de la energía eólica.

Con este trabajo académico se evidencia que los modelos de aprendizaje automático y profundo, adecuadamente seleccionados y entrenados, pueden ser herramientas valiosas para apoyar la planeación operativa y la gestión de riesgo en la oferta de energía eólica dentro del mercado de energía colombiano. Aunque el estudio se realizó con datos del parque Alpha Ventus ubicado en Alemania, los principios del modelo son plenamente transferibles al contexto colombiano, siempre que los modelos se reentrenen con datos locales y reales de un parque eólico local que se encuentre en funcionamiento. No obstante, el desempeño puede variar debido a diferencias en patrones de viento, lo cual puede materializarse y analizarse en trabajos futuros.

En el contexto colombiano, particularmente en la región de La Guajira, se registran velocidades del viento promedio entre 8 y 10 m/s a una altura de 100 m, alcanzando valores máximos superiores a 12 m/s en zonas de costa afuera. Estas condiciones son similares a las observadas en el mar del Norte, lo cual se ha evidenciado a través de la plataforma Global Wind Atlas [32] confirmando el alto potencial eólico de esta región. Sin embargo, aunque el parque eólico Alpha Ventus entró en operación en 2010, este continúa en funcionamiento, por lo que las turbinas empleadas de referencia AREVA M5000-116 de 5 MW aún representan una referencia válida para análisis comparativos. Si bien es cierto que la tecnología ha evolucionado hacia turbinas más eficientes y con mayores capacidades, los datos operativos utilizados en este estudio, correspondientes al año 2014, siguen siendo adecuados para representar el comportamiento de una turbina de clase similar, aplicable a escenarios reales de generación eólica en el contexto colombiano. Este hecho refuerza la viabilidad del enfoque propuesto, aunque también exige que los modelos ajustados consideren los patrones locales de velocidad, dirección, variabilidad y frecuencia del viento, aspectos que pueden diferir de los registros europeos utilizados inicialmente.

TRABAJOS FUTUROS

De acuerdo con el desarrollo del documento y los resultados obtenidos, este trabajo funciona como base para fortalecer la investigación en los siguientes campos:

- Extender el estudio a horizontes de predicción mayores para evaluar la estabilidad temporal del modelo.
- Integrar variables meteorológicas adicionales (temperatura, presión atmosférica, humedad) para mejorar la capacidad predictiva.
- Evaluar modelos híbridos o de ensamblaje que combinen redes recurrentes con métodos estadísticos.
- Aplicar los modelos a datos de parques eólicos reales en Colombia para validar su desempeño en entornos operativos y su potencial uso en un mercado intradiario.

REFERENCIAS

- [1] Shan Gao, Ningyu Zhang “A review of different methodologies for solving the problem of wind power's fluctuation”. 2009 International Conference on Sustainable Power Generation and Supply.
- [2] Devashish, Amarnath T., Swetapadma P., “A Review on Wind Energy Conversion System and Enabling Technology”. 2016 International Conference on Electrical Power and Energy Systems, 527-532.
- [3] Yue Chen, Zhizhong Guo, Hongbo Li, Guizhong Wang, Yingwei Hou, Abebe Tilahun Tadie. “Review of Research on Power Accommodation of Power Systems with High Proportion Renewable Power Sources”. 2019 22nd International Conference on Electrical Machines and Systems (ICEMS).
- [4] Mark Hutchinson, Feng Zhao. “Global Wind Report 2023” Global Wind Energy Council (GWEC), Bruselas, 2023. Disponible en: GWEC's Global Wind Report 2023. Consultado:18 de agosto 2025.
- [5] Małgorzata Wiatros-Motyka. “Global Electricity Review 2023” Ember, 2023. Disponible en: Global Electricity Review 2023 | Ember. Consultado:18 de agosto 2025.
- [6] Erlong Zhao, Shaolong Sun, Shouyang Wang. “New developments in wind energy forecasting with artificial intelligence and big data: a scientometric insight”. Data Science and Management, Volume 5, Issue 2, June 2022, Pages 84-95.
- [7] Saurabh S. Soman, Hamidreza Zareipour, Om Malik, Paras Mandal. “A review of wind power and wind speed forecasting methods with different time horizons”. North American Power Symposium 2010.
- [8] Tsai, W.-C.; Hong, C.-M.; Tu, C.-S.; Lin, W.-M.; Chen, C.-H. “A Review of Modern Wind Power Generation Forecasting Technologies”. Sustainability 2023.
- [9] Mararakanye, N., Dalton, A., Bekker, B. “Incorporating Spatial and Temporal Correlations to Improve Aggregation of Decentralized Day-Ahead Wind Power Forecasts”. IEEE Access 2022.

- [10] Krannichfeldt, L.V., Wang, Y., Zufferey, T., Hug, G. “Online Ensemble Approach for Probabilistic Wind Power Forecasting”. *IEEE Trans. Sustain. Energy* 2022, 13, 1221–1233.
- [11] Yu, Y.; Han, X.; Yang, M.; Yang, J. “Probabilistic Prediction of Regional Wind Power Based on Spatiotemporal Quantile Regression”. *IEEE Trans. Ind. Appl.* 2020, 56, 6117–6127.
- [12] Yu, Y.X.; Yang, M.; Han, X.S.; Zhang, Y.M.; Ye, P.F. “A Regional Wind Power Probabilistic Forecast Method Based on Deep Quantile Regression”. *IEEE Trans. Ind. Appl.* 2021, 57, 4420–4427.
- [13] G. Grassi and P. Vecchio. “Wind energy prediction using a two-hidden layer neural network,” *Commun Nonlinear Sci Numer Simul*, vol. 15, no. 9, pp. 2262–2266, Sep. 2010.
- [14] Comisión de Regulación de Energía y Gas (CREG), “Cómo funciona el mercado eléctrico de Colombia”, Publicación 8206. [En línea]. Disponible: <https://creg.gov.co/publicaciones/8206/como-funciona-el-mercado-electrico-de-colombia/>. Consultado: 30 de octubre 2025.
- [15] Velázquez Medina, Sergio Leandro. Tesis doctoral “Estimación de la potencia eólica en una zona mediante el apoyo de estaciones meteorológicas de referencia y el empleo de técnicas estadísticas no paramétricas, funcionales y de machine learning: aplicación a las islas Canarias” Departamento de Ingeniería Mecánica. 2011.
- [16] F. Guerrero-Villar, R. Dorado-Vicente, M. Fike, and E. Torres-Jiménez, “Influence of ambient conditions on wind speed measurement: Impact on the annual energy production assessment,” *Energy Convers Manag*, vol. 195, pp. 1111–1123, Sep. 2019.
- [17] Miguel García Lobo. Tesis doctoral “Métodos de predicción de la generación agregada de energía eólica”. Departamento de Ingeniería Eléctrica. 2010.
- [18] M. Sharifzadeh, A. Sikinioti-Lock, and N. Shah, “Machine-learning methods for integrated renewable power generation: A comparative study of artificial neural networks, support vector regression, and Gaussian Process Regression”. *Renewable and Sustainable Energy Reviews*, vol. 108, pp. 513–538, Jul. 2019.

- [19] M. Ouanani, A. Tutor, I. María, G. Leon, and R. A. Mur, “Trabajo de fin de grado predicción de energía eólica utilizando técnicas de aprendizaje automático.” Departamento de Informática. 2015.
- [20] M. Lei, L. Shiyang, J. Chuanwen, L. Hongling, and Z. Yan, “A review on the forecasting of wind speed and generated power,” *Renewable and Sustainable Energy Reviews*, vol. 13, no. 4, pp. 915–920, May 2009.
- [21] C. Batlle López, P. Rodilla, y P. Mastropietro, Definición de las características de funcionamiento del despacho vinculante, los mercados intradiarios y el mecanismo de balance. Versión final. Entregable del proyecto “Estudio para la modernización del despacho y el mercado spot de energía eléctrica – despacho vinculante y mercados intradiarios”, Instituto de Investigación Tecnológica, Univ. Pontificia Comillas, para la CREG, Contrato 2018-041, oct. 2018.
- [22] The MathWorks Inc., “Definición de modelos de regresión: Árbol de decisión, Regresión gaussiana y Redes neuronales,” Centro de ayuda MATLAB, 2022. [En línea]. Disponible en: <https://www.mathworks.com/help/stats/regression-models.html>. Consultado: 30 de septiembre 2025.
- [23] J.M. Torres, R.M. Aguilar, J.A. Méndez, K.V. Zuñiga-Meneses. “Deep learning en la predicción de generación de un parque eólico” *Actas de las XXXVII Jornadas de Automática 2016*.
- [24] Singh, M., & Kim, S. “Short-term wind power forecasting using LSTM recurrent neural network”. *Energies*, 2019.
- [25] Peng Lu, Lin Ye, Ming Pei, Yongning Zhao, Binhua Dai, Zhuo Li. “Short-term wind power forecasting based on meteorological feature extraction and optimization strategy”. *Renewable Energy*, Volume 184, January 2022, Pages 642-661.
- [26] J. Qin, J. Yang, Y. Chen, Q. Ye, and H. Li, “Two-stage short-term wind power forecasting algorithm using different feature-learning models,” *Fundamental Research*, vol. 1, no. 4, pp. 472–481, Jul. 2021.

[27] Wei Gu, Rui Wang, Rong Sun, Qun Li. “Wind Power Penetration Limit Calculation Based on Stochastic Optimal Power Flow” International Review of Electrical Engineering (IREE). July 2011.

[28] Han Xiaoqing, Yan Yong. “Wind power penetration limit calculation based on power system reliability”. 2009 International Conference on Sustainable Power Generation and Supply.

[29] Zahraa, T., Mahmoud, Y., Ahmed, M. E-Sayed M., Abdelhamed, I., Abdelaziz, A., Mohamed, A. “Wind Power Prediction Based on Machine Learning and Deep Learning Models”. CMC, 2023, Vol. 74, no.1,715-732.

[30] The MathWorks Inc., “Regression model performance metrics (RMSE, R^2 , MSE, MAE)”, MATLAB Help Center, 2022. [En línea]. Disponible en: <https://www.mathworks.com/help/stats/regression-model-performance-metrics.html>.

Consultado: 15 de octubre 2025.

[31] “Areva M5000-116 – Manufacturers and Turbines” The Wind Power. [En línea]. Disponible: https://www.thewindpower.net/turbine_en_326_areva_m5000-116.php.

Consultado: 30 de octubre 2025.

[32] Global Wind Atlas. (2025, Version 4.0). Technical University of Denmark (DTU) & World Bank Group. Disponible: <https://globalwindatlas.info/en/>. Consultado: 30 de octubre 2025.