

JOURNAL OF ENERGY, ENGINEERING
OPTIMIZATION AND SUSTAINABILITY

2026

ENERGÍA Y SUSTENTABILIDAD



Vol. 10 Núm. 2 (2026)

Reserva de Derechos al Uso Exclusivo

No. 04-2026-050410175100-102. ISSN: 2448-8186



DIRECTORIO

L.D. GUILLERMO NARVÁEZ OSORIO

Rector

DR. WILFRIDO MIGUEL CONTRERAS SÁNCHEZ

Secretario de Investigación, Posgrado y Vinculación

DR. LUIS MANUEL HERNÁNDEZ GOVEA

Secretario de Servicios Académicos

LIC. ALEJANDRINO BASTAR CORDERO

Encargado del Despacho de la Secretaría de
Servicios Administrativos

Esta revista está citada en:

Sistema Regional de Información en Línea para Revistas Científicas de América Latina y el Caribe, España y Portugal LATINDEX.<http://www.1atindex.unam.mx/> JOURNAL OF ENERGY, ENGINEERING OPTIMIZATION AND SUSTAINABILITY, Vol 10, No. 2, Año 2026, es una publicación continúa editada por la Universidad Juárez Autónoma de Tabasco, Av. Universidad S/N, Zona de la Cultura, Col. Magisterial, C.P. 86040, Villahermosa, Tabasco, México. Tel. (+52) (933) 358 1500 Ext. 5040, <https://revistajeeos.ujat.mx/JEEOS/es/>, Email: jeeos@ujat.mx. Indizada en LATINDEX. Editora responsable: Laura Lorena Díaz Flores. Reserva de derechos al uso exclusivo No. 04-2026-050410175100-102, ISSN: 2448-8186, ambos otorgados por el Instituto Nacional del Derecho de Autor. Responsable de la última actualización de este número: Pauly González Mayo, Universidad Juárez Autónoma de Tabasco, Av. Universidad S/N, Zona de la Cultura, Col. Magisterial, Centro, Tabasco. C.P. 86040. Fecha de última actualización, 31 de agosto 2026.

This work is licensed under a Creative Commons Attribution- NonCommercialShareAlike 4.0 International License.

Dra. Laura Lorena Díaz Flores
EDITORA EN JEFE

M.A. Pauly González Mayo
GESTORÍA Y ASISTENCIA EDITORIAL

MIS Dalia Exaltación Medina Mandujano
MAEE. Mary Cruz Valenzuela Jiménez
ASISTENTE DE DISEÑO Y ESTILO

Dra. Sulma Guadalupe Gómez Jiménez
Dra. Margarita del Carmen Noguera Miceli
ASISTENCIA EN TRADUCCIÓN Y MAQUETADO

EDITORES ASOCIADOS INVITADOS

Dr. Darío Colorado Garrido. **Universidad Veracruzana**
Dra. Linda Viviana García Quiñonez. **Universidad Veracruzana**
Dr. Cristian Gómez. **Universidad Veracruzana**
Dra. Deysi Carmina Peña Ortiz. **Universidad Veracruzana**
Dr. Roberto Agustín Conde Gutiérrez. **Universidad Veracruzana**
Dr. Gerardo Alcalá Perea. **Universidad Veracruzana**
Dra. Zaira Ruth Zuviría López. **Universidad Autónoma de Guadalajara**
Dra. Karen Rodríguez Rosales. **Universidad Autónoma de Querétaro**
Dra. Laura López Díaz. **Universidad Juárez Autónoma de Tabasco**
Dr. Erik Ramírez Morales. **Universidad Juárez Autónoma de Tabasco**

COMITÉ EDITORIAL

Dr. Bassam Ali, **Facultad de Ingeniería, Universidad Autónoma de Yucatán**

Dr. Fabricio Nápoles Rivera, **Universidad Michoacana de San Nicolás de Hidalgo**

Dr. Francisco López Villareal, **Instituto Tecnológico de Villahermosa.**

Dr. Fernando Israel Gómez Castro, **Universidad de Guanajuato**

Dr. Juan Serrano Arellano, **Instituto Tecnológico de Pachuca**

Dra. Isabel María Valdivia Fernández, **Universidad de la Habana- Facultad de Geografía**

Dra. Ivett Zavala Guillén, **Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California**

Dr. Luis Alfonso García Cerda, **Centro de Investigación de Química Aplicada**

Dra. Nancy del Pilar Medina Herrera, **Universidad Autónoma de Nuevo León**

Dra. Ma. Guadalupe Garnica Romo, **Universidad Michoacana de San Nicolás de Hidalgo.**

Dra. María Guadalupe Alpuche Cruz, **Universidad de Sonora**

Dr. Pedro Cruz Alcantar, **Universidad Autónoma de San Luís Potosí**

Dr. Salvador Tututi Ávila, **Universidad Autónoma de Nuevo León**

Dra. Santa del Carmen Herrera Sánchez, **Universidad Autónoma del Carmen**

Índice Vol. 10 Núm. 2 (2026)

Carta editorial

Zuviría-López Z.R.

Integración de calor en la purificación de ciclohexano grado textil utilizando etilenglicol como solvente 1-16

Cruz-Valdez J.A.^{1*}, Álvarez-Alor B.², Montalvo-Salinas D.³, Garzón-Pérez A.S.⁴, Alvarado-Méndez P.E.⁵

Fotosíntesis artificial efecto sinérgico de Ti^{3+} , Co^{2+} , Co^{3+} en los mecanismos de activación, acoplamiento c-c hacia la producción de isopropanol 17-30

Pérez- de la Cruz A.Y.¹, Montalvo-Salinas D.^{2*}, Cruz-Valdez J.A.¹, Pérez- Francisco J.M.¹, Jiménez- Castillo U.¹, Álvarez-Alor B.³

Predicción de la potencia en una turbina vestas v52 mediante regresión polinomial y una red neuronal 31-46

Olan-Barroso A.A.^{1*}, Alaffita-Hernández F.A.², Escobedo-Trujillo B.A.¹, Colorado-Garrido D.²

Estrategias de ingeniería de software verde para aplicaciones energéticamente eficientes

Morales-Reyes E.^{1*}, Pacheco-Reyes J.N.¹, Vázquez-Hernández R.¹, Gilbón-Aburto A.¹, Gómez-Manuel E.¹ 47-54

Estudio teórico y experimental de la eficiencia térmica de un colector cilindro parabólico en Coatzacoalcos, México 55-70

Rodríguez-Flores E.¹, González-Martínez M.I.², Fuentes-Orozco S.², Garrido-Meléndez J.³, Márquez-Nolasco A.⁴, Conde-Gutiérrez R.A.^{4*}.

Determinación de la acumulación de metales en *eichhornia crassipes* para valorización de biomasa 71-80

Benítez-Martínez X. S.¹, Domínguez-Villate W. A.¹, Núñez-Correa S.¹, Morales-Salas L.^{2,3*}

Restricciones de sostenibilidad y riesgo de cola en portafolios accionarios de México 81-96

Villada-Medina H.D.^{1*}, Rendón-García J.F.¹, Alcalá-Perea G.²

Análisis en lazo cerrado de un convertidor elevador en cascada con reducción del rizo de corriente de entrada para aplicaciones con celda de combustible de hidrógeno 97-114

Hidalgo-Leal H.D.¹, Cruz-Gutiérrez F.^{1*}, May-Burgos L.D.¹, Sarao-Cruz L.D.J.¹, Pérez-Aguilar A.¹.

Predicción de la potencia en una turbina vestas v52 mediante regresión polinomial y una red neuronal

Power prediction for vestas v52 wind turbine using polynomial regression and neural networks

Olan-Barroso A.A.^{1*}, Alaffita-Hernández F.A.², Escobedo-Trujillo B.A.¹, Colorado-Garrido D.²

¹ Facultad de Ingeniería, Universidad Veracruzana, Av. Universidad Veracruzana Km. 7.5, Col. Santa Isabel I, Coatzacoalcos, 96538, Veracruz, México

² Centro de Investigación en Recursos Energéticos y Sustentables (CIRES), Universidad Veracruzana, Av. Universidad Veracruzana Km. 7.5, Col. Santa Isabel I, Coatzacoalcos, 96538, Veracruz, México

*zS22017148@estudiantes.uv.mx

falaffita@uv.mx

Artículo Científico

Publicado: 31 de agosto 2026

RESUMEN

En el presente trabajo se desarrolló un modelo polinomial y una red neuronal para predecir la potencia eléctrica del aerogenerador Vestas V52 ubicado en el campus del Instituto de Tecnología de Dundalk (DkIT), Irlanda. Se utilizaron datos experimentales del aerogenerador, correspondientes a registros promedio de cada diez minutos adquiridos entre enero de 2006 y marzo de 2020. Las variables de entrada incluyeron principalmente parámetros operativos relevantes de la turbina y factores ambientales disponibles en los datos SCADA (Supervisory Control and Data Acquisition). Los modelos fueron implementados, entrenados y validados en MATLAB empleando los datos registrados. El desempeño de los modelos fue evaluado mediante métricas estadísticas como el coeficiente de determinación (R^2) y el error cuadrático medio (RMSE). Los resultados mostraron que ambos enfoques permiten estimar la potencia generada con un nivel adecuado de precisión. La red neuronal artificial con función de activación ReLU obtuvo un coeficiente de determinación de 0.9845 y un RMSE de 26.78 kW. No obstante, el modelo de regresión polinomial destaca por su practicidad operativa, facilitando el cálculo de la potencia sin un alto costo computacional. Ambos modelos se establecen como herramientas eficaces para el análisis del rendimiento energético de aerogeneradores Vestas V52 sometidos a condiciones normales de funcionamiento.

Palabras clave: Regresión polinomial, Redes neuronales, Energía eólica.

ABSTRACT

This study presents the development of a polynomial model and an artificial neural network to predict the electrical power output of a Vestas V52 wind turbine located at the Dundalk Institute of Technology (DkIT), Ireland. Experimental data consisting of ten-minute average records

collected between January 2006 and March 2020 were used to develop the models. The input variables included key operational parameters of the wind turbine together with environmental variables available from the SCADA (Supervisory Control and Data Acquisition) system. Both models were implemented, trained, and validated in MATLAB. Their performance was assessed using the coefficient of determination (R^2) and the root mean square error (RMSE). The results demonstrate that both approaches provide accurate estimates of the generated electrical power. The artificial neural network with the ReLU activation function achieved an R^2 of 0.9845 and an RMSE of 26.78 kW. Meanwhile, the polynomial regression model offers a practical alternative by enabling rapid power estimation with low computational cost. Overall, both models constitute effective tools for evaluating the energy performance of Vestas V52 wind turbines operating under normal conditions.

Keywords: Neural networks, Polynomial regression, Wind energy.

INTRODUCCION

La creciente integración de la energía eólica en los sistemas eléctricos modernos ha incrementado la necesidad de contar con métodos confiables para la predicción de la potencia eléctrica de aerogeneradores. Una estimación precisa de la potencia eólica resulta fundamental para la evaluación del rendimiento energético, la optimización de la operación y la planeación de sistemas eléctricos provenientes de fuentes renovables [1].

La potencia generada por una turbina eólica depende de múltiples factores ambientales y operativos que varían continuamente durante su funcionamiento. Las curvas de potencia nominales y los modelos teóricos tradicionales no siempre representan adecuadamente el comportamiento real de los aerogeneradores bajo condiciones operativas, lo que limita su precisión para el análisis del desempeño energético [2].

No obstante, en estudios recientes se han desarrollado distintos modelos con el fin de incrementar la precisión en la predicción de la potencia en el campo de la energía eólica. Por ejemplo, Pelletier-F., Masson-C. y Tahan-A. [3] realizaron múltiples entrenamientos utilizando algoritmos de inteligencia artificial para modelar la curva de potencia de un aerogenerador. Asimismo, Kim- Y. S. [4] analizó diferentes métodos de normalización (normalización de min-max, normalización de Z-score, entre otros) aplicados a distintos tipos de redes neuronales con el propósito de mejorar su desempeño. El enfoque híbrido propuesto por Escobedo-Trujillo- B. A. [5], combina redes neuronales artificiales y un modelo polinomial, metodología similar a la desarrollada en el presente trabajo. Asimismo, Gijón-R., A. [6] presenta una comparación entre tres enfoques de modelado: basado en la física, basado en datos y modelos híbridos. En conjunto, estos trabajos muestran que tanto las técnicas de inteligencia artificial como los modelos híbridos han permitido mejorar la precisión en la predicción de la potencia eólica, aunque presentan distintos niveles de complejidad computacional y metodológica.

No obstante, la literatura revisada se ha enfocado principalmente en modelos de redes neuronales para la predicción de potencia utilizando datos experimentales de aerogeneradores, obteniendo resultados con alta capacidad predictiva. Sin embargo, son escasos los estudios que comparan directamente el desempeño de estos modelos en contra de expresiones matemáticas más simples, como los modelos polinomiales. En este contexto, el presente trabajo propone un modelo polinomial para la predicción de la potencia eléctrica de un aerogenerador y su comparación con una red neuronal artificial. A diferencia de un modelo complejo, el modelo polinomial permite predecir la potencia mediante la sustitución directa de las variables de entrada, sin requerir un proceso de entrenamiento ni un elevado costo computacional.

METODOLOGÍA

Descripción del aerogenerador y sitio de estudio. La turbina tipo Vestas V52 cuenta con una potencia nominal de 850.0 kW y está equipada con 3 álabes de rotor, cuya velocidad máxima es de 31.4 rpm, con conexión a una red asíncrona de 50 Hz. Sus dimensiones incluyen un diámetro de rotor de 52 m, un área de 2,124 m² y una altura de buje de 60 m. Los pesos de sus componentes son 11.0 toneladas para el rotor, 100 toneladas para la torre y 22 toneladas para la góndola, el aerogenerador cuenta con una protección anticorrosiva.

La turbina eólica se encuentra instalada en el campus del Instituto de Tecnología de Dundalk (DkIT), Irlanda, en las coordenadas geográficas 53.983° N y 6.392° O, a una elevación aproximada de 13 m sobre el nivel del mar. La ubicación del emplazamiento resulta favorable debido a las características del terreno circundante. Esta ubicación corresponde a un entorno periurbano con predominancia de tierras agrícolas en un radio de 20 km, lo que implica menor presencia de obstáculos que alteren el flujo del viento. No obstante, existe un edificio de 47 metros de altura que se encuentra aproximadamente a 335 m.

Sistema de adquisición de datos SCADA. Los parámetros de operación se obtuvieron por medio de un sistema SCADA (Supervisory Control and Data Acquisition). Este sistema registra y almacena información en intervalos de diez minutos a través de un controlador conectado a un anemómetro ultrasónico 2-D Thies Clima instalado en la góndola, el cual mide la velocidad y dirección del viento para corregir la posición de la turbina.

Los datos del sistema de posición se registraron por medio de encoders y medidores de posición integrados en el control de la turbina VMP (Vestas Multiprocesador), que transmiten señales eléctricas al sistema SCADA para su almacenamiento e interpretación en secuencias temporales. Asimismo, el sistema registra datos asociados con la potencia eléctrica y temperatura, incluyendo: potencia promedio, potencia mínima, potencia máxima, potencia reactiva, temperatura ambiente, temperatura de la góndola, temperatura del aceite de la caja de engranajes, entre otros.

Descripción de la base de datos. Los datos experimentales fueron obtenidos por [7] y consisten en 653,103 datos registrados correspondientes al período que abarca del 30 de enero del 2006 al

12 de marzo de 2020, los datos se registraron mediante el cálculo de la media aritmética de las muestras para cada intervalo de 10 minutos.

Con el fin de facilitar el análisis, se descartó la variable de temperatura del generador al registrar un valor constante de 999 °C, lo que indicó una falla en el sensor. Asimismo, las variables de potencia máxima, potencia mínima y potencia reactiva no fueron consideradas para el desarrollo de los modelos, ya que el objetivo fue predecir la potencia eléctrica a partir de variables independientes. Debido a que estas variables están directamente relacionadas con la potencia generada, su inclusión como variables de entrada haría que el modelo utilizara información asociada al valor que se pretende estimar. No obstante, estas modificaciones se limitaron a la selección de las variables empleadas en el modelado. **Tabla 1.**

Tabla 1. Variables operativas utilizadas como entradas de los modelos.

Variable	Intervalos	Descripción
V1	[0, 368.4]	Velocidad del viento (m/s)
V2	[0, 183.2]	Desviación estándar de la velocidad del viento (m/s)
V3	[-3224.7, 3175]	Dirección absoluta del viento (°)
V4	[-2969.2, 2406.4]	Dirección relativa del viento (°)
V5	[-5.2, 86.6]	Paso de las palas (Pitch) (°)
V6	[0, 1622]	Velocidad angular del generador (rpm)
V7	[0, 26.2]	Velocidad angular del rotor (rpm)
V8	[-3, 27]	Temperatura ambiente (°C)
V9	[0, 34]	Temperatura de la góndola (°C)
V10	[0, 205]	Temperatura del aceite de la caja de engranajes (°C)
V11	[0, 205]	Temperatura del rodamiento de la caja de engranajes (°C)
V12	[0, 130]	Temperatura de la fase 1 del generador (°C)
V13	[0, 204]	Temperatura de la fase 2 del generador (°C)
V14	[0, 131]	Temperatura de la fase 3 del generador (°C)
V15	[-50, 205]	Temperatura del rodamiento del generador (°C)
V16	[-3274.9, 3149.1]	Potencia eléctrica promedio (kW)

Por otra parte, los datos experimentales presentan dos fuentes principales de valores atípicos. Por un lado, se llevó a cabo el reemplazo de la caja de engranes entre el 4 de octubre de 2018 y el 27 de julio de 2019, periodo en el que no se registraron valores positivos de potencia eléctrica. Por

otro lado, se identificaron errores de medición provenientes de los sensores del sistema SCADA, los cuales registraron magnitudes físicamente imposibles. Como consecuencia, los intervalos crudos presentados en la **Tabla 1** incluyen valores mínimos y máximos que no representan las condiciones reales de operación del aerogenerador, sino lecturas anómalas derivadas de fallas de medición. Cabe destacar que, para el análisis desarrollado en este artículo, no se eliminó ningún dato de la muestra original.

MODELOS DE PREDICCIÓN

Modelo de red neuronal artificial. Se desarrolló un modelo de red neuronal artificial empleando las variables independientes $V1, V2, \dots, V15$ y la potencia eléctrica promedio generada ($V16$) como variable dependiente (ver **Tabla 1**). La salida del modelo se expresa mediante la ecuación (1).

$$\hat{y} = W_2 f(W_1 X + b_1) + b_2 \quad (1)$$

En esta expresión, $\hat{y}$ representa la potencia eléctrica estimada, X corresponde al conjunto de variables independientes, W_1 y W_2 representan las matrices de pesos de la capa oculta y de salida, b_1 y b_2 corresponden a los términos de sesgo asociados a dichas capas mientras que $f(\cdot)$ denota la función de activación, la cual corresponde a la Unidad Lineal Rectificada (ReLU) debido a que reproduce de forma más adecuada el comportamiento físico del aerogenerador. En particular, la turbina no genera potencia eléctrica cuando la velocidad del viento es inferior a aproximadamente 3 m/s, condición conocida como velocidad de arranque. En consecuencia, el interés de este trabajo se centra en modelar el comportamiento del sistema únicamente bajo condiciones de generación. A diferencia de otras funciones de activación, que también aprenden el comportamiento del sistema fuera de esta región, ReLU anula los valores negativos y conserva únicamente la región positiva. Su expresión matemática se muestra en la ecuación (2).

$$\text{ReLU}(x) = \max(0, x) = \begin{cases} x & \text{if } x > 0, \\ 0 & x \leq 0 \end{cases} \quad (2)$$

Esto resulta consistente con la curva de potencia del aerogenerador. Aunque otras funciones de activación presentaron valores ligeramente superiores de R^2 y menores valores de RMSE (ver **Tabla 2**), la selección de ReLU prioriza la coherencia física del modelo sobre una mejora marginal en las métricas de desempeño. El modelo cuenta con un esquema basado en una división temporal de los datos, compuesto por un 80% de los registros destinados a la fase de aprendizaje y un 20% para validación, debido a que el tamaño del registro de datos proporciona un conjunto de validación suficientemente representativo, permitiendo destinar una mayor cantidad de información al entrenamiento del modelo sin comprometer la evaluación de su capacidad de generalización [8].

Tabla 2. Valores de R^2 y RMSE obtenidos para las funciones de activación evaluadas.

Función de activación	R^2	RMSE
ReLU	0.9845	26.78 KW
Tanh	0.9897	21.795 KW
Sigmoid	0.9880	23.595 KW
LeakyRelu	0.9845	26.712 KW
Gelu	0.9848	26.511 KW

Como parte del entrenamiento se aplicó la normalización Z-score [4]. Esta ajusta cada variable para tener de media 0 y desviación estándar 1, con el objetivo de evitar una distorsión del conjunto de datos, esto asociado a los valores atípicos [9]. La fórmula característica se muestra en (3), donde z_i es el valor normalizado, x_i es la observación i -ésima, n es la cantidad de muestras, μ y σ son el promedio y la desviación estándar de las muestras.

$$z_i = \frac{x_i - \mu}{\sigma} \text{ con } i = 1, \dots, n \quad (3)$$

A diferencia de la técnica de Levenberg-Marquardt [5], el entrenamiento se realizó mediante el optimizador ADAM fundamentado en su capacidad de gestionar tasas de aprendizaje adaptativas además de su robustez ante el ruido de los valores atípicos [10]. Para este proceso se estableció una tasa de aprendizaje (*learning rate*) inicial de 1×10^{-3} . Asimismo, se utilizó un lote de entrenamiento (*minibatch*) de 1024 muestras para actualizar los parámetros del modelo en cada iteración. El entrenamiento se realizó durante 150 épocas (*epochs*), donde cada época representa un recorrido completo por el conjunto de datos de entrenamiento, con el fin de asegurar la convergencia del modelo [11]. Dichos parámetros de configuración fueron seleccionados a partir de pruebas preliminares y basados en estudios anteriores [3].

Polinomio. La metodología adoptada se inspira en el enfoque de regresión polinomial usado por [12] para la predicción de eficiencia térmica, el cual se adapta en este estudio al análisis de la potencia eléctrica. En este contexto, se relaciona la variable dependiente P (potencia eléctrica) con un conjunto de variables operativas independientes $V1, V2, \dots, V15$, mostradas en la **Tabla 1**. El modelo general (4) se expresa como:

$$P = W(V1, V2, \dots, V15) + \varepsilon \quad (4)$$

donde W representa la función polinomial que describe el comportamiento de la potencia eléctrica en función de las variables independientes y ε corresponde a un error aleatorio. Se asume que ε es una variable aleatoria con distribución normal.

Para la construcción del modelo mostrado en la ecuación (4), se realizaron combinaciones empíricas entre las variables independientes, considerando términos lineales productos cruzados, términos cuadráticos y cúbicos con el objetivo de capturar interacciones no lineales presentes en el comportamiento del sistema, a partir de dichas combinaciones, se calculó el R^2 entre cada combinación de variables y la potencia predicha, seleccionando la combinación más simple que presentó mayor ajuste, para una explicación más detallada de la metodología, véase [13].

RESULTADOS

Polinomio. El modelo polinomial construido se muestra en la ecuación (5), ajustado con un coeficiente de determinación R^2 de 0.9688, esto indica que aproximadamente el 96.88% de la variabilidad de la potencia eléctrica del sistema es explicada por las variables operativas sin normalizar consideradas en la metodología.

$$\begin{aligned}
 P = & 13.65(V1) - 24.17(V1 \cdot V11) \quad (5) \\
 & - 0.3283(V2) \\
 & + 3.328(V3) \\
 & - 0.02014(V4) \\
 & - 0.008451(V5) \\
 & - 0.2409(V6) \\
 & - 0.2472(V7) \\
 & + 7.491(V8) \\
 & + 1.224(V9) \\
 & - 2.376(V10) \\
 & + 2.059(V11) \\
 & - 1.325(V12) \\
 & + 1.687(V13) \\
 & + 0.7690(V14) \\
 & - 0.4423(V15) \\
 & - 0.9983(V12) \\
 & + 0.1567(V13) \\
 & - 0.0003882(V1 \cdot V5) \\
 & + 0.3008(V1 \cdot V6) \\
 & + 0.06519(V1 \cdot V2) \\
 & - 0.06991
 \end{aligned}$$

La alta correspondencia entre los valores de potencia real y los estimados por el modelo (5), mostrada en la **Figura 1**, evidencia que la mayoría de las predicciones se agrupa sobre la función identidad. Las principales dispersiones respecto a dicha función se atribuyen a la presencia de valores atípicos en la base de datos, originados principalmente durante el reemplazo de la caja de

engranajes del aerogenerador. Este proceso tuvo una duración aproximada de diez meses, periodo en el cual no se registraron condiciones normales de operación, por lo que las mediciones de potencia no representan el comportamiento habitual de la turbina. Asimismo, se observa una acumulación de datos alrededor de la potencia nominal de 850 kW, comportamiento asociado a la estrategia de control del aerogenerador, mediante la cual la potencia generada se limita al alcanzarse dicho valor nominal.




Figura 1. Potencia real contra la potencia predicha por regresión polinomial.

Análisis de residuos. Este permite determinar la variabilidad de ε , con la finalidad de evaluar la calidad del modelo (5), se crea el supuesto de que ε cuenta con una distribución normal con media cero y varianza constante, de modo que se puede aplicar el valor esperado (E) a ambos lados de la ecuación (4), siguiendo la metodología de [13].

$$E(P) = E(W(V1, V2, \dots, V15) + \varepsilon)$$

$$E(P) = E(W(V1, V2, \dots, V15)) + E(\varepsilon)$$

$$E(\varepsilon) = 0$$

$$E(P) = E(W(V1, V2, \dots, V15))$$

Se comprueba el supuesto de normalidad propuesto en el análisis de los residuos, se muestra en la **Figura 2** el histograma de los residuos estandarizados, el cual presenta una forma acampanada con media de aproximadamente cero.




Figura 2. Histograma de los residuos estandarizados.

Debido a la distribución normal de los residuos, se aplicó la regla de las tres sigmas, al cual para una distribución normal cerca del 99.7 % de los valores de una muestra se encuentran dentro del intervalo $\mu \pm 3\sigma$ [14]. Puesto que los residuos presentan una media (μ) de aproximadamente cero, se simplifica a $\pm 3\sigma$, en la **Figura 3** se graficaron dos líneas horizontales en este intervalo, de modo que las observaciones fuera de este intervalo se consideraron valores atípicos, obteniéndose un total de 5434 valores atípicos.




Figura 3. Residuos estandarizados contra valores predichos.

Adicionalmente, se confirma que los residuos son independientes al cumplir con los tres supuestos, donde la gráfica de la **Figura 4** muestra que los residuos cuentan con varianza constante (en forma de banda gris) y un promedio de aproximadamente cero. Los intervalos de confianza y los residuos están representados por las líneas grises y los puntos, respectivamente. Asimismo, los puntos rojos situados fuera de los intervalos de confianza corresponden a los valores atípicos previamente identificados.




Figura 4. Dispersión de residuos con bandas de confianza.

Finalmente, con el propósito de evaluar la influencia de los valores atípicos sobre el ajuste del modelo (5), estos fueron depurados de la base de datos y la regresión fue recalculada. Se obtuvo un coeficiente de determinación de R^2 de 0.9830, lo que representa un incremento de 0.0142 respecto al obtenido con la base de datos original. Este resultado confirma que una parte importante de la disminución en el ajuste del modelo se encuentra asociada a la presencia de valores atípicos representado en la **Figura 5** donde se muestra la potencia real vs. la predicha apreciándose una menor dispersión de los datos y una mayor adherencia de las predicciones a la función identidad.




Figura 5. Potencia predicha vs potencia real sin valores atípicos.

Asimismo, para verificar si los errores se distribuyeron normalmente tras la depuración de la base de datos, se obtuvo el histograma de los residuos estandarizados mostrado en la **Figura 6**. Este presenta una forma acampanada más definida, con una media próxima a cero y una mayor concentración de los datos en torno a este valor, lo que indica que, aun después de la depuración de los valores atípicos, los residuos continúan aproximándose a una distribución normal con media aproximadamente igual a cero.




Figura 6. Histograma sin valores atípicos.

Red neuronal. Se obtuvo un valor de $R^2 = 0.9845$, lo que indica que el 98.45% de la variabilidad de la potencia eléctrica registrada es explicada por el modelo de red neuronal. Asimismo, se calculó un RMSE de 24 kW, evidenciando un menor error global de estimación en comparación con el modelo (5).

Los pesos y los valores de sesgo (*bias*) obtenidos tras el proceso de entrenamiento definen la configuración interna del modelo. La **Tabla 3** presenta los pesos que conectan las variables de entrada $V_1, V_2, \dots, V_{15}$ con las neuronas de la capa oculta $N_1, N_2, \dots, N_4$, junto con el valor de sesgo asociado a cada neurona. La **Tabla 4** muestra los pesos que conectan las neuronas de la capa oculta con la neurona de salida, además del correspondiente valor de sesgo de la capa de salida.

Como resultado de esta configuración, la **Figura 7** muestra la comparación de la potencia real vs. predicha mediante modelo de red neuronal, los puntos de datos muestran menor dispersión respecto a la función identidad representada en la línea roja, debido a un mayor ajuste del modelo de ANN.




Figura 7. Potencia real vs. potencia predicha por ANN.

Tabla 3. Pesos y sesgos (bias) de la capa oculta.

	N_1	N_2	N_3	N_4
V1	0.072	0.136	-0.767	0.257
V2	0.008	-0.01	0.002	-0.132
V3	0.024	0.006	0.028	-0.018
V4	0.015	0.052	-0.009	0.007
V5	-1.051	0.793	-1.052	-0.04
V6	0.372	0.962	0.293	-0.473
V7	0.372	0.862	0.299	-0.597
V8	0.026	0.102	0.061	-0.086
V9	-0.077	-0.152	-0.081	0.126
V10	-0.04	0.026	-0.134	0.053
V11	-0.058	0.125	0.14	-0.038
V12	0.04	0.054	0.14	-0.208
V13	0.029	0.101	0.027	-0.064
V14	0.016	0.057	-0.039	0.027
V15	0.0001	-0.056	-0.056	0.081
Sesgo	-0.162	-1.58	0.26	1.274

Tabla 4. Pesos y sesgo de la capa de salida.

N_1	N_2	N_3	N_4	Sesgo
0.826	1.020	-1.068	-0.385	0.671

Ajuste de los modelos. Se presentan los resultados comparativos del ajuste de los modelos evaluados mediante el coeficiente de determinación (R^2) y la raíz del error cuadrático medio (RMSE). Ambas métricas fueron utilizadas como criterios de evaluación para cuantificar la capacidad de ajuste y el error asociado a las predicciones generadas por cada modelo (ver **Tabla 5**). No obstante, el modelo de red neuronal es más complejo de replicar, pero presenta mayor robustez, mientras que el modelo polinomial destaca por su facilidad de implementación práctica.

Tabla 5. Métricas de validación.

Modelo	R^2	RMSE
Polinomio	0.9688	37.94 kW
Red neuronal	0.9845	26.78 kW

DISCUSIÓN

Se logró una capacidad predictiva para la turbina Vestas V52, validada mediante métricas de correlación a partir de datos experimentales en condiciones de operación. La incorporación de parámetros de funcionamiento, tales como la velocidad del viento y la temperatura ambiente, permitió mejorar la capacidad predictiva del modelo, lo que contribuye al desarrollo de la investigación en sistemas de generación eólica.

Si bien diversos modelos de redes neuronales artificiales (ANN) reportados en la literatura alcanzan coeficientes de determinación cercanos a 0.99 (**Tabla 6**), ambos modelos desarrollados en este estudio pueden mejorar significativamente su capacidad predictiva mediante la aplicación de filtros matemáticos que reduzcan la influencia de errores de medición y valores atípicos. No obstante, aun sin la aplicación de dichos filtros, el modelo (5) desarrollado en este estudio destaca por su practicidad y facilidad de implementación en entornos de ingeniería, manteniendo una capacidad predictiva competitiva.

Por otra parte, la red neuronal presentó un RMSE altamente competitivo al compararse con algoritmos de alto desempeño, como Random Forest y Multilayer Perceptron [3]. En conjunto, ambos modelos constituyen herramientas precisas y fiables para la predicción de la potencia eléctrica en la turbina Vestas V52.

Tabla 6. Métricas de desempeño reportadas en estudios relacionados.

Algoritmo	RMSE	R^2
Random Forest [3]	75.52	0.989
Decision Tree [3]	94.94	0.975
XGB [3]	102.91	0.970
Light GBM [3]	113.97	0.951
MLPerceptron [3]	175.57	0.991
Stacking [3]	85.31	0.983
Voting [3]	93.04	0.977
Physics-based [2]	30.58	0.995
Data-based [2]	25.04	0.996
Hybrid [2]	24.48	0.997

CONCLUSIÓN

Se desarrollaron dos modelos de predicción de potencia eléctrica en una turbina Vestas V52. El modelo de red neuronal alcanzó un coeficiente de determinación de $R^2 = 0.9845$ y un RMSE de 26.78 kW debido a su metodología enfocada en aumentar la precisión mediante la normalización z-score, el uso de la función de activación ReLU y el algoritmo de optimización Adam, mientras

que el modelo polinomial obtuvo un $R^2 = 0.9688$ y un RMSE de 37.94 kW, el cual permite una estimación inmediata de la potencia mediante la sustitución directa de las variables de entrada.

REFERENCIAS

- [1] Agoundedemba, M., Nyenge, R., Musila, N., N’Zi Toure, K. J.-Y., Kim, C. K., & Kim, H.-G. (2026). Improving accuracy of wind speed forecasted with power law and multiple layer perceptron: a case study of Aneho, a coastal area of Togo. *Energy Conversion and Management*: X, 30, 101674. Fecha de consulta: 5 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S2590174526001571>
- [2] Allal, Z., Noura, H. N., Salman, O., & Chahine, K. (2025). Machine learning-based prediction model of wind turbine power generation. *Cleaner Energy Systems*, 12, 100218. Fecha de consulta: 30 de enero de 2026. <https://www.sciencedirect.com/science/article/pii/S2772783125000494>
- [3] Astolfi, D., Celesti, L., Vedovelli, M., Lombardi, A., & Terzi, L. (2022). Data-Driven Assessment of Wind Turbine Performance Decline with Age and Interpretation Based on Comparative Test Case Analysis. *Sensors*, 22, 3180. Fecha de consulta: 20 de enero de 2026. https://www.researchgate.net/publication/360112207_Data-Driven_Assessment_of_Wind_Turbine_Performance_Decline_with_Age_and_Interpretation_Based_on_Comparative_Test_Case_Analysis
- [4] Byrne, R., & MacArtain, P. (2023). Multi-annual time series operational data for a Vestas V52 wind turbine located in a coastal peri-urban environment in Ireland. *Data in Brief*, 48, 109227. Fecha de consulta: 4 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S2352340923003463>
- [5] Camacho-Catemaxca, E., Escobedo-Trujillo, B., Alaffita, F., & Herrera-Romero, J. (2025). Polynomial regression model for the prediction of thermal efficiency in spark ignition engines operating with ethanol-water mixtures. *Revista de Ingeniería Mecánica*. Fecha de consulta: 12 de febrero de 2026. https://www.ecorfan.org/spain/researchjournals/Ingenieria_Mecanica/vol9num22/Journal_of_Mechanical_Engineering_V9_N22_4.pdf
- [6] Escobedo-Trujillo, B. A., Alaffita-Hernández, F. A., Colorado, D., & Siqueiros, J. (2014). Coefficient of performance prediction by a polynomial model of absorption heat transformer. Fecha de consulta: 4 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S1359431116324334>
- [7] Escobedo-Trujillo, B. A., Colorado, D., Rivera, W., & Alaffita-Hernández, F. A. (2016). Neural network and polynomial model to improve the coefficient of performance prediction for solar intermittent refrigeration system. *Solar Energy*, 129, 28-37. Fecha de consulta: 2 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S0038092X16000657>

- [8] Gijón, A., Eiraudó, S., Manjavacas, A., Salvatore-Schiera, D., Molina-Solana, M., & Gómez-Romero, J. (2025). Integrating physics and data-driven approaches: An explainable and uncertainty-aware hybrid model for wind turbine power prediction. *Computer Physics Communications*, 316, 109761. Fecha de consulta: 4 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S0010465525002632>
- [9] Guelleh, H. O., Patel, R., & Mujtaba, I. M. (2026). Renewable energy transition in sub-Saharan Africa: Opportunity for wind energy in Djibouti. *Journal of Cleaner Production*, 545, 147732. Fecha de consulta: 10 de enero de 2026. <https://www.sciencedirect.com/science/article/pii/S0959652626002714>
- [10] Haque, A., & Rahman, S. (2022). Short-term electrical load forecasting through heuristic configuration of regularized deep neural network. *Applied Soft Computing*, 122, 108877. Fecha de consulta: 10 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S1568494622002575>
- [11] Kim, Y. S., Kim, M. K., Fu, N., Liu, J., Wang, J., & Srebric, J. (2025). Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models. *Sustainable Cities and Society*, 118, 105570. Fecha de consulta: 7 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S2210670724003962>
- [12] Montgomery, D. C. (2009). The Histogram y The Normal Distribution. En: *Introduction to Statistical Quality Control* (pp. 66-86). John Wiley & Sons. Hoboken, New Jersey.
- [13] Pei, F., Zhang, B., Long, S., & Yuan, M. (2026). BiLSTM-PINN-based wind turbine power prediction architecture and anomaly data identification. *Renewable Energy*, 261, 125182. Fecha de consulta: 8 de febrero de 2026. <https://www.sciencedirect.com/science/article/pii/S0960148126000078>
- [14] Pelletier, F., Masson, C., & Tahan, A. (2016). Wind turbine power curve modelling using artificial neural network. *Renewable Energy*, 89, 203-214. Fecha de consulta: 29 de enero de 2026. https://www.researchgate.net/publication/291012629_Wind_turbine_power_curve_modelling_using_artificial_neural_network

