

Redes Neuronales para la Estimación del Periodo Fundamental de Aerogeneradores de Eje Horizontal

Neural Networks for the Estimation of the Fundamental Period of Horizontal-Axis Wind Turbines

Inzunza-Aragón, I.¹✉; Amaya-Gallardo, E.², Valdez-Cano, R.³; Valenzuela-Beltrán, F.⁴,
Martínez-Montenegro, H.S.⁵

Datos de Adscripción:

¹✉ Inzunza Aragón, Indira
Universidad Autónoma de Coahuila. Facultad de Ingeniería Civil. Torreón,
Coahuila, México.
iinzunza@uadec.edu.mx
ORCID: <https://orcid.org/0000-0002-1200-0548>

² Amaya Gallardo, Edmundo
Universidad Autónoma de Coahuila. Facultad de Ingeniería Civil. Torreón,
Coahuila, México.
eamaya@uadec.edu.mx
ORCID: <https://orcid.org/0000-0002-2985-0952>

³ Valdez Cano, Ricardo
Universidad Autónoma de Coahuila. Facultad de Ingeniería Civil. Torreón,
Coahuila, México.
ricardovaldezcano@uadec.edu.mx
ORCID: <https://orcid.org/0000-0001-7079-7754>

⁴ Valenzuela Beltrán, Federico
Universidad Autónoma de Sinaloa. Facultad de Ingeniería. Culiacán, Sinaloa,
México.
fvalenzuelab@uas.edu.mx
ORCID: <https://orcid.org/0000-0002-2528-9475>

⁵ Martínez Montenegro, Hugo Santiago
Universidad Autónoma de Coahuila. Facultad de Ingeniería Civil. Torreón,
Coahuila, México.
martinezhugo@uadec.edu.mx
ORCID: <https://orcid.org/0009-0006-2203-1117>

Resumen - El periodo fundamental de vibración de los aerogeneradores de eje horizontal es un parámetro esencial para el diseño y el desempeño de sus componentes principales, como el rotor, la góndola y los sistemas electromecánicos responsables de transformar la energía del viento en electricidad. Este parámetro se determina comúnmente mediante análisis dinámicos modales o a partir de expresiones cerradas aproximadas; sin embargo, cuando se requiere evaluar múltiples configuraciones, como en la etapa de prediseño o al realizar estudios paramétricos, el uso reiterado de estos métodos puede volverse poco práctico. En este trabajo se propone la aplicación de Redes Neuronales Artificiales (RNA) como una alternativa para estimar el periodo fundamental de aerogeneradores de eje horizontal a partir de la masa en la punta y las características geométricas de la torre de soporte. Se implementaron RNA multicapa, de entrenamiento hacia adelante y aprendizaje supervisado, empleando como base de datos modelos con rotores de 70 a 120 m de diámetro, torres de soporte con alturas entre 70 y 100 m y diámetros entre 3 y 6 m. Se observó que, al comparar las predicciones de las redes con los resultados obtenidos mediante ecuaciones cerradas y superficies de respuesta, las RNA se correlacionan mejor

con los resultados de referencia en el intervalo paramétrico analizado. Estos resultados muestran que el uso supervisado de la inteligencia artificial, aplicada al campo de la ingeniería estructural, constituye una herramienta poderosa y confiable, capaz de complementar métodos tradicionales y de abrir posibilidades para el diseño y la optimización de aerogeneradores modernos.

Palabras Clave – Aerogeneradores, Periodo estructural, Redes Neuronales Artificiales, Superficies de respuesta.

Abstract - The fundamental period of Horizontal-Axis Wind Turbines (HAWT) is an essential parameter in the design and performance of their main components, such as the rotor, the nacelle, and the electromechanical system responsible for converting wind energy into electricity. This parameter is commonly determined through modal dynamic analyses or by means of approximate closed-form expressions; however, when multiple configurations must be evaluated, such as in pre-design stage or in parametric studies, the repeated application of these methods can become impractical. In this work, Artificial Neural Networks (ANN) are proposed as an alternative for estimating the fundamental period of HAWT based on the top mass and the geometric characteristics of the supporting tower. Multilayer feedforward ANN with supervised learning were implemented, using a database of turbine models with rotor diameters ranging from 70 to 120 m, support towers with heights between 70 and 100 m, and diameters between 3 and 6 m. It was observed that, when comparing the network predictions with results derived from closed-form equations and response surface methods, ANN are better correlated with the reference results within the analyzed parametric range. These findings suggest that supervised Artificial Intelligence, applied in the Structural Engineering field, is a powerful and reliable tool that complements traditional methods and broadens possibilities for the design and optimization of modern wind turbines.

Keywords - Artificial Neural Networks, Response surfaces, Structural period, Wind Turbines.

I. INTRODUCCIÓN

Con el fin de cumplir con el Acuerdo de París, México tiene la meta de generar el 35% de su energía eléctrica mediante energías limpias renovables, entre ellas, la energía eólica (Secretaría de Energía, 2024). De acuerdo con cifras de la Asociación Mexicana de Energía Eólica [AMDEE] (2025), en el país hay 74 parques eólicos distribuidos en 15 estados del país. En todos ellos, la energía del viento es aprovechada por aerogeneradores de eje horizontal, en inglés, *Horizontal-Axis Wind Turbine* (HAWT).

Los aerogeneradores de eje horizontal (HAWT) se componen principalmente de tres partes: la torre de soporte, la góndola y el rotor; este último, a su vez, está compuesto por las palas y el buje. Uno de los parámetros estructurales más relevantes para el diseño y desempeño de los componentes de los HAWT es el periodo fundamental de vibración, ya que desde la etapa de prediseño es necesario evitar que el periodo natural del rotor y la góndola coincidan con el de la estructura, presentándose el fenómeno de resonancia (Det Norske Veritas & Riso National Laboratory, 2002; Saram & Yang, 2025). Incluso se estipula que la frecuencia natural del HAWT debe encontrarse en un intervalo de 1 a 3 veces la frecuencia del rotor (International Electrotechnical Commission, 2019).

Para obtener el periodo estructural se realizan análisis dinámicos modales con programas computacionales empleando análisis de elementos finitos y monitoreo de la respuesta estructural mediante mediciones de vibración ambiental, sin embargo, este tipo de análisis requiere de tiempo y recursos computacionales elevados, así como conocimientos técnicos especializados (Soyoz et al., 2024). Una manera aproximada de calcularlo consiste en conceptualizar estas estructuras como un sistema de un grado de libertad con una masa concentrada, o como una viga en voladizo con una masa al final de su longitud (Kelele et al., 2023). Estas metodologías aproximadas son útiles en etapas tempranas de diseño para un solo modelo; sin embargo, cuando se requiere sistematizar múltiples configuraciones de torres de soporte y diámetros de rotor, es necesario optar por procedimientos prácticos y sencillos.

En las últimas cuatro décadas, la aplicación de Redes Neuronales Artificiales (RNA) ha demostrado ser una alternativa poderosa que permite resolver diferentes problemas de la Ingeniería Civil (Lagaros, 2023), en el área de Ingeniería Estructural son útiles principalmente en problemas donde la naturaleza de los datos no sigue una tendencia lineal o se involucran demasiadas variables como el cálculo de la confiabilidad estructural (Vazirizade et al., 2017), factores de carga y resistencia (Bojorquez et al., 2017, Al-Gburi et al., 2025), cálculo del periodo fundamental en edificios de concreto de varios niveles (Elgohary, 2025), predicción de daño en elementos estructurales (Hakim et al., 2022), entre otros. Pocos estudios han aplicado las RNA o algún otro componente de Inteligencia Artificial, en el comportamiento estructural de HAWT instalados costa adentro (De Anda et al., 2023), la mayoría se decanta por HAWT instalados en mar (costa afuera), en la optimización del diseño y funcionamiento de las palas (Jiang et al., 2025) o en mecanismos y estrategias de control para los sistemas eléctricos y mecánicos (Elkodama, et al., 2023).

Asimismo, se ha demostrado que las RNA predicen resultados con mayor exactitud que las ecuaciones cerradas o las superficies de respuesta, lo que representa una alternativa para el manejo de un gran número de datos y la programación de algoritmos o programas computacionales (Inzunza-Aragón et al., 2022). Por otro lado, las superficies de respuesta ofrecen ecuaciones cerradas, fáciles de implementar, sin necesidad de un algoritmo o programa computacional, siendo más prácticas que la ejecución de una RNA.

En este estudio, el periodo fundamental de 6048 modelos de aerogeneradores con distintas características geométricas se calculó considerando cada uno como una viga en voladizo, posteriormente, el periodo fundamental se obtuvo mediante RNA y superficies de respuesta. Se implementaron redes neuronales artificiales (RNA) multicapa de entrenamiento hacia adelante (feedforward) con aprendizaje supervisado. Para el entrenamiento de las redes se propusieron diferentes porcentajes de entrenamiento, prueba y validación, así como diferentes números de capas. Las superficies de respuesta empleadas en este estudio se obtuvieron mediante regresión lineal utilizando el criterio de terminación AIC y la regresión de Ridge. Para la obtención de estas se consideraron superficies de 4 a 6 variables.

Una vez entrenadas las RNA y obtenidas las superficies de respuesta, se calculó el periodo estructural de 112 modelos diferentes de HAWT que no se incluyeron en el entrenamiento inicial.

Los resultados obtenidos de este estudio mostraron que las RNA calculan el periodo fundamental de HAWT con una correlación de 0.99, mientras que las superficies de respuesta tienen una correlación entre 0.85 y 0.96 en función de las variables involucradas.

II. PARTE TÉCNICA DEL ARTÍCULO

El objeto de estudio se centra en obtener el periodo estructural fundamental de HAWT con torres de soporte de acero cilíndricas y cónicas de sección transversal variable con la altura, desde la base hacia la góndola, de mayor a menor diámetro, con rotores de tres palas, empleando métodos aproximados y comparando los resultados obtenidos con RNA y superficies de respuesta. En la Figura 1 se muestran las principales partes de un HAWT.

2.1 Generación de base de datos

Se generó una base de datos con un total de 6048 elementos, la configuraciones de torres de soporte con alturas entre 70 m y 100 m con incrementos de 5 m, con diámetros en la base, D_b , de 3m a 6 m con incrementos de 1.0 m, diámetros en la punta, D_t , con valores de $0.5D_b$ a D_b con incrementos de 0.5m, espesor en la base, t_b , de 0.025 cm a 0.038 cm con incrementos de 0.0125 cm, espesor en la punta, t_t , de $0.5t_b$ a t_b con incrementos de 0.0125 m, y cuatro masas en la punta, que incluye el peso de las palas, góndola y buje, m_r , entre 70.0 t y 314.5 t, con incrementos de 81.5 t, asociadas a diámetros aproximados de 75 m, 90m, 110 m y 120 m, respectivamente. Estas dimensiones son representativas de los aerogeneradores instalados en los distintos parques eólicos del territorio mexicano (AMDEE, s.f.).

Figura 1

Partes principales de un Aerogenerador de eje horizontal




Tabla 1.

Descripción del intervalo de las variables de estudio


Variable	Intervalo	Incremento
Masa del rotor, m_r , t	70.0 a 314.5	81.5
Altura de la torre, H , m	70 a 100	5
Diámetro en la base, D_b , m	3.0 a 6.0	1.0
Diámetro en la punta, D_t , m	$0.5D_b$ a D_b	0.5
Espesor en la base, t_b , m	0.025 a 0.038	0.0125
Espesor en la punta, t_t , m	$0.5t_b$ a t_b	0.0125

2.2 Cálculo del periodo estructural fundamental

El periodo estructural se define como el tiempo que tarda una estructura en completar un ciclo desde su posición original, generalmente medido en segundos. Por lo general, el periodo estructural fundamental se refiere al primer modo de vibrar. Para estructuras regulares y HAWT, este modo de vibrar es de traslación en un sentido. En la figura 2 se muestran los tres primeros modos de vibración de un HAWT.

Figura 2

Primeros tres modos de vibrar de un HAWT



El periodo de cualquier estructura, T_n , puede obtenerse con (1) donde m representa la masa de la estructura y k la rigidez lateral. Para el caso particular de los HAWT, la masa total considera la suma de la masa en la punta, m_r , y el 22.35% de la masa de la torre, m_{torre} , (Kelele et al., 2023). La rigidez lateral se calculó considerando que su comportamiento es similar al de una columna empotrada con un extremo libre con una masa concentrada en el extremo superior, i.e oscilador de 1GL, y se calcula con (3), donde E es el Módulo de Elasticidad del material, I es el momento de inercia promedio de la sección modificada y H es la altura de la torre.

El peso volumétrico del acero estructural se toma como 8500 kg/m³ en vez de la densidad estándar de 7850 kg/m³ con el objetivo de considerar el peso de la soldadura, tornillos, anillos rigidizantes, accesorios, entre otros, para estimar el peso total de la torre. Con base en esto, se incrementó en un 40 % el espesor de la torre para aproximar el peso real utilizando la densidad estándar del acero. Con ese espesor modificado, se calcula el momento de inercia promedio de la sección modificada en la base y en la punta de la torre.

$$T_n = 2\pi \sqrt{\frac{m}{k}} \quad (1)$$

$$m = m_r + 0.2235m_{torre} \quad (2)$$


$$k = \frac{3EI}{H^3} \quad (3)$$

2.3 Entrenamiento de RNA

Las RNA son algoritmos que permiten predecir o calcular valores objetivos a partir de datos de entrada proporcionados por el usuario. Existen diferentes tipos de RNA, dependiendo del tipo de aprendizaje, número de capas y arquitectura de aprendizaje, sin embargo, todas parten de una neurona principal llamada perceptrón. La configuración de las neuronas se esquematiza en la Figura 3, donde se pueden observar las entradas o input, x_n , una función de entrada o activación contenida en una capa oculta, una capa de salida con la función de salida y los resultados o output, out_m . Las funciones de activación y de salida son ecuaciones que se alimentan con pesos, w_{mn} , que se generan aleatoriamente y un número de desfase o bias b_m . Las redes neuronales artificiales (RNA) con aprendizaje supervisado comparan el resultado obtenido de su entrenamiento con un valor objetivo proporcionado por el usuario; la red se entrenará consecutivamente hasta alcanzar los parámetros de finalización establecidos, como el mayor coeficiente de correlación (R), el menor error cuadrático medio (ECM) o un número específico de entrenamientos.

Figura 3

Composición de una Red Neuronal Artificial



Para este estudio se entrenó una red neuronal multicapa, de entrenamiento hacia adelante (feedforward) con aprendizaje supervisado y una arquitectura de aprendizaje basada en el algoritmo Levenberg-Marquardt (Demuth & Beale, 2000). Estas redes se componen de una función de entrada sigmoidea y una función de salida lineal. Se empleó el complemento Neural Net Fitting del software Matlab (Mathworks, 2019) para el entrenamiento de las RNA.

Los datos de entrada fueron: masa del rotor en kilogramos, altura de la torre, diámetros inferior y superior, espesores inferior y superior, todas las variables en metros. La base de datos no tuvo ningún procesamiento ni normalización de datos. El parámetro de salida fue el periodo estructural en segundos.

Para el entrenamiento de las redes se propusieron diferentes porcentajes de entrenamiento, validación y evaluación (E-V-E), así como diferentes números de capas ocultas. En la Tabla 2 se muestran el número de RNA, la distribución de los datos para el entrenamiento, el número de épocas y el número de iteraciones obtenidas en el entrenamiento de cada red. Para este estudio se consideró el total de los datos de entrada para cada lote de entrenamiento; por lo tanto, la época mostrada es la en la que se obtuvo la menor ECM. Las configuraciones con pocas épocas reflejan un entrenamiento insuficiente en contraste con aquellas con más de 800 épocas, sin embargo, este aumento trae consigo el riesgo de sobreajuste, especialmente cuando las iteraciones superan significativamente las épocas o cuando la partición de datos de validación y evaluación es reducida.

En las Figuras 4 y 5 se muestran el ECM y el R obtenidos para cada RNA en la etapa de E-V-E, respectivamente. Como es de esperarse, redes con pocas capas ocultas muestran errores relativamente altos, aunque mantienen valores de R superiores a 0.99. Al incrementar el número de capas ocultas, el error tiende a reducirse, pero aparecen indicios de sobreajuste, particularmente en la red 9, donde la diferencia entre entrenamiento y validación es evidente. En el caso de la red 10, la inestabilidad se relaciona más con la distribución desigual de los datos (70-5-20) que con el número de capas.

Para seleccionar la red más adecuada, se realizó una validación externa utilizando una base de datos que fue excluida deliberadamente del entrenamiento original. En la Tabla 3 se muestran el Error Cuadrático Medio (ECM) y el coeficiente de correlación (R) obtenidos para la validación externa de cada RNA. Conviene elegir una red con bajo ECM y alto R. Debido a lo anterior, se considera que la RNA número 4 es la indicada para calcular el periodo estructural de HAWT con características geométricas dentro de los intervalos de entrenamiento, aunado a que esta red logró un equilibrio óptimo entre entrenamiento suficiente y capacidad de generalización, evitando tanto el subentrenamiento como el sobreajuste.

Tabla 2.
Resultados del entrenamiento de RNA

No.	E-V-E (%)	Capas ocultas	Épocas	Iteraciones
0	70-15-15	1	62	68
1	70-15-15	5	162	168
2	70-15-15	10	916	922
3	70-15-15	15	791	797
4	70-15-15	20	814	820
5	70-20-10	15	766	772
6	70-10-20	15	746	752
7	70-25-5	15	774	995
8	70-5-25	15	629	635
9	70-20-10	20	1000	1000
10	70-10-20	20	1000	1000
11	70-25-5	20	814	1000
12	70-5-25	20	544	829

Figura 4

Error Cuadrático Medio obtenido en el Entrenamiento, Validación y Evaluación de las RNA.




Figura 5

Coefficiente de correlación, R, obtenido en el Entrenamiento, Validación y Evaluación de las RNA.




Tabla 3.

Resultados de la validación externa de RNA

No.	Validación externa	
	ECM	R
0	5.88×10^{-2}	9.92×10^{-1}
1	3.93×10^{-3}	9.99×10^{-1}
2	1.65×10^{-4}	9.99×10^{-1}
3	2.92×10^{-5}	9.99×10^{-1}
4	2.23×10^{-5}	9.99×10^{-1}
5	2.90×10^{-5}	9.99×10^{-1}
6	2.91×10^{-5}	9.99×10^{-1}
7	3.57×10^{-5}	9.99×10^{-1}
8	3.15×10^{-5}	9.99×10^{-1}
9	2.50×10^{-5}	9.99×10^{-1}
10	2.72×10^{-5}	9.99×10^{-1}
11	2.47×10^{-5}	9.99×10^{-1}
12	3.26×10^{-5}	9.99×10^{-1}

2.4 Obtención de Superficies de Respuesta


Una superficie de respuesta se refiere a un polinomio que relaciona un modelo mecánico con su respuesta numérica. En otras palabras, es una ecuación, Y , que relaciona las variables de un sistema con resultados obtenidos de modelos experimentales, simulaciones numéricas o datos teóricos (Inzunza-Aragón et al., 2022).

Las superficies de respuesta en este estudio, Y , se calcularon mediante regresión lineal múltiple (Witten et al., 2016), como se describe en (4) donde α_0 es la ordenada al origen o un valor constante, α_i son los coeficientes de las variables x_i , y ε es un error residual.

$$Y = \alpha_0 + \sum_{i=1}^n \alpha_i x_i + \varepsilon \quad (4)$$

Se utilizó la misma base de datos de entrada del entrenamiento de las RNA para obtener las superficies de respuesta, analizando diferentes combinaciones de variables con el objetivo de obtener una ecuación cerrada y práctica para el cálculo del periodo fundamental. Por ejemplo, para la superficie de respuesta 1 (Tabla 4) se consideraron la altura de la torre, el diámetro y los espesores en la base y la punta, todas en metros, obteniendo un coeficiente de correlación entre el periodo obtenido y el real de 0.85 y un ECM de 3.26. En la figura 6 se observa que los resultados obtenidos con la superficie de respuesta 1 siguen la tendencia positiva no lineal; sin embargo, para periodos cortos (menores de 2 s) y periodos largos (mayores de 6 s), la ecuación subestima el periodo estructural a pesar de la correlación positiva de los periodos obtenidos; por lo anterior, es necesario realizar un ajuste en las variables y en los coeficientes de la superficie de respuesta.

Figura 6
Resultados de la Superficie de Respuesta 1



Para las superficies de respuesta posteriores, se realizó un procesamiento de las unidades de las variables, como modificar las unidades de la altura a decímetros y los espesores a centímetros; y utilizar variables secundarias como la relación de la masa y la altura, el diámetro promedio considerando el diámetro de la base y en la punta, el espesor promedio considerando el espesor en la base y en la punta, o la relación de esbeltez promedio que relaciona la altura de la torre y el diámetro promedio. Lo anterior con el objetivo de aproximar con mayor precisión los periodos y contemplar la no linealidad del problema.

En la Tabla 4 se muestran las superficies de respuesta con sus variables, así como el R y el ECM obtenidos entre dichas superficies y los valores objetivos. Se observa que las superficies de respuesta 1 y 2, al incluir únicamente parámetros geométricos, tienden a ser menos precisas que las superficies 3 y 4, que incluyen variables secundarias, las cuales mejoran el ajuste y la precisión. En general, la superficie de respuesta 4 tiene un mayor coeficiente de correlación y el ECM menor que las demás superficies al considerar variables secundarias como la relación masa/altura, espesor promedio y relación de esbeltez promedio.

Tabla 4.
Coeficientes de las variables de las superficies de respuesta

Variable	Número de Superficie de respuesta			
	1	2	3	4
Altura de la torre, H , m	0.07		0.88	
Masa de la punta/Altura de la torre, $\frac{m_r}{H}$, t/m			0.65	0.65
Altura de la torre h , dam		0.70		0.30
Diámetro en la base, D_b , m	-1.02	-1.02		
Diámetro en la punta, D_t , m	-0.28	-0.28		
Diámetro promedio, $\bar{D}$, m			-1.27	
Espesor en la base, t_b , m	-37.90			
Espesor en la punta, t_t , m	-10.25			
Espesor en la base, t_b , cm		-0.38		
Espesor en la punta, t_t , cm		-0.10		
Espesor promedio, $\bar{t}$, cm			-0.42	-0.42
Relación de esbeltez promedio, $\frac{h}{\bar{D}}$				2.23
Constante	3.50	5.04	1.22	-4.04
Coefficiente de correlación, R	0.85	0.85	0.92	0.96
Error Cuadrático Medio, ECM	3.26	0.90	0.51	0.27

La ecuación generada por esta superficie de respuesta se representa como (5) donde el periodo fundamental de un HAWT, T_n , puede obtenerse con la masa de la punta, m_r , en toneladas, la altura de la torre, H , en m, y la altura, h , en decímetros, el espesor promedio, $\bar{t}$, en cm y la relación de esbeltez promedio considerando la altura en decímetros y el diámetro promedio en metros.

$$T_n = 0.65 \frac{m_r}{H} + 0.30h - 0.42\bar{t} + 2.23 \frac{h}{\bar{D}} - 4.04 \quad (5)$$

III. RESULTADOS Y DISCUSIÓN

Una vez obtenidos el RNA óptimo y la ecuación generada por la superficie de respuesta, se calculó el periodo estructural de 112 modelos de HAWT que no se emplearon en el entrenamiento original.

En la Figura 7 se muestra la relación entre el periodo obtenido con la RNA 4, descrito en el eje horizontal, y el periodo esperado, en el eje vertical. La RNA logra una correlación casi unitaria, con R de 0.99, y un ECM de 2.23×10^{-5} tal como se muestra en la Tabla 3, lo que refleja un nivel de precisión muy alto y una capacidad de generalización adecuada.

En la Figura 8 se muestra la relación entre el periodo obtenido con (5), generado a partir de la superficie de respuesta 4, descrito en el eje horizontal, y el periodo esperado, en el eje vertical. En contraste con los resultados de la RNA, se observa una mayor dispersión de los puntos respecto a la línea de tendencia. Aunque

la correlación es positiva ($R=0.96$) y el ECM es de 0.321, la precisión es menor y se observa que el modelo no logra reproducir con la misma fidelidad los valores objetivos para periodos mayores a 6 s. Esto sugiere que, si bien las ecuaciones lineales ofrecen simplicidad y facilidad de interpretación, su capacidad para ajustarse a fenómenos con múltiples variables y comportamientos no lineales es limitada.

Figura 7
Resultados de la RNA 4 entrenada





Figura 8
Resultados obtenidos con (5), superficie de respuesta 4.



Como caso de aplicación, una vez obtenido el periodo fundamental, se pueden seleccionar los modelos que cumplan con $1P \leq T_n \leq 3P$, donde P corresponde al periodo de rotación del rotor. Por ejemplo, un rotor similar al N90/2500 (Nordex SE, 2012) con capacidad de generación de 2.5 MW, un diámetro de rotor aproximado de 90 m y una velocidad de operación de 16.2 rpm equivalente a un periodo de 3.73 s, podría instalarse en HAWT con $3.73 \leq T_n \leq 11.9$ s.

Dado que la masa del rotor es constante para cualquier torre de soporte, con los resultados de las RNA y superficies de respuesta se obtienen las posibles configuraciones geométricas de la torre. Para los HAWT calculados con las RNA se obtuvieron 10 modelos de torres de soporte, mientras que con las superficies de respuesta se obtuvieron los mismos 10 modelos y uno adicional (sombreado en gris en la Tabla 5).

Al comparar los periodos obtenidos, se obtuvo una correlación de 0.94 y un ECM de 0.27. El hecho de obtener los mismos modelos de torres de soporte permite concluir que, para casos prácticos y de prediseño, tanto las RNA como las superficies de respuesta son una herramienta útil para el diseño estructural. Sin embargo, en etapas avanzadas de diseño, donde la precisión del periodo fundamental es crítica, las superficies de respuesta no resultan una alternativa viable.

Con estas herramientas es posible seleccionar un diseño preliminar de torre de soporte, a partir del cual se pueden realizar análisis más detallados de capacidad, pandeo, fatiga y aeroservoelasticidad, ya sea mediante modelos simplificados o modelos con elementos finitos, hasta pruebas en túnel de viento y simulaciones de dinámica de fluidos computacional.

Tabla 5.
Configuraciones de torres de soporte adecuadas para el rotor seleccionado.

Altura, <i>m</i>	Diámetro		Espesor		RNA	Periodo (5)
	Inferior, <i>m</i>	Superior, <i>m</i>	Inferior, <i>m</i>	Superior, <i>m</i>		
70	3.0	1.5	0.0374	0.0373	4.32	4.30
75	3.0	2.0	0.0374	0.0311	4.59	4.46
80	3.0	2.0	0.0374	0.0187	5.20	5.08
85	3.0	2.5	0.0250	0.0125	6.40	5.52
90	3.0	2.0	0.0374	0.0373	6.10	5.42
90	4.0	3.5	0.0374	0.0249	3.84	4.09
95	3.0	2.5	0.0374	0.0249	6.36	5.74
95	4.0	2.0	0.0374	0.0311	4.73	5.29
100	3.0	3.0	0.0312	0.0156	7.07	6.14
100	4.0	3.5	0.0374	0.0187	4.68	4.99
85	4.0	4.0	0.0250	0.0187	3.73	3.80

IV. CONCLUSIONES

Las RNA permiten calcular el periodo fundamental de HAWT de manera precisa en comparación con expresiones cerradas obtenidas con superficies de respuesta obtenidas con regresión lineal múltiple. En este estudio, las RNA se entrenaron únicamente para obtener el periodo fundamental asociado al primer modo, excluyendo comportamientos dinámicos particulares, así como modos superiores de vibración.

El análisis de datos de entrada es fundamental en el entrenamiento de las RNA y Superficies de respuesta. Para este trabajo, las RNA lograron ajustar el periodo estructural sin necesidad de un preprocesamiento de datos de entrada ni cambiar el orden de la magnitud de éstos, sin embargo, para las Superficies de respuesta fue necesario realizar un cambio de unidades, incluso determinar variables secundarias como la relación entre la masa, en toneladas, y la altura en decámetros, el espesor promedio en centímetros o la relación de esbeltez promedio de la torre. Esto se debe a la no linealidad de los datos; probablemente, con superficies de respuesta de segundo orden se podría obtener el periodo estructural con mayor precisión, aunque esta afirmación está sujeta a comprobación.

Es necesario entrenar las RNA con diferentes porcentajes y números de capas ocultas hasta lograr un nivel de precisión adecuado a la naturaleza del problema. Para este caso de estudio, el porcentaje de $E - V - E$ adecuado fue de 75-15-15 y 20 capas ocultas.

Una vez entrenadas, las RNA pueden obtener el periodo estructural fundamental de cualquier HAWT cuyas características geométricas y el diámetro del rotor estén dentro del intervalo establecido.

Es importante mencionar que el periodo fundamental obtenido a partir de las RNA es una aproximación que permite tomar decisiones en las primeras etapas del diseño estructural, como la elección de una configuración de torre de soporte y un diámetro

de rotor adecuado a cierto modelo de góndola o equipo eléctrico. Para obtener el periodo estructural y los modos de vibración de un HAWT es necesario realizar análisis dinámicos con modelos simplificados e incluso modelos con elementos finitos. Trabajos posteriores pudieran abordar la calibración de los resultados obtenidos de las RNA con modelos computacionales avanzados o información obtenida a partir monitoreo estructural de estructuras existentes; así como la aplicación de RNA y superficies de respuesta no lineales para la obtención de periodos y modos de vibrar superiores.

V. AGRADECIMIENTOS

Los autores agradecen a las instituciones involucradas, a los integrantes de los Cuerpos Académicos “Innovación Sustentable de Materiales y Estructuras” CA-UADEC-184 y “Diseño, Evaluación y Rehabilitación de Estructuras” UAS-CA-366, así como a los estudiantes que apoyaron en el desarrollo de la base de datos.

VI. REFERENCIAS

- Al-Gburi, M., Alhayani, A. A., & Almssad, A. (2025). Artificial Neural Network Model for Evaluating Load Capacity of RC Deep Beams. *Buildings*, 15(8), 1371. <https://doi.org/10.3390/buildings15081371>
- Asociación Mexicana de Energía Eólica (2025). *Informe anual 2025*. Recuperado de: https://amdee.org/es_es/project/informe-anual-amdee-2025/
- Asociación Mexicana de Energía Eólica (s.f.). *Estudio de capacidades de la industria eólica en México*. Recuperado de: <https://amdee.org/wp-content/uploads/Estudio-de-Capacidades-de-la-Industria-Eolica-en-Mexico.pdf>
- Bojórquez, J., Ruiz, S. E., Ellingwood, B., Reyes-Salazar, A., y Bojórquez, E. (2017). Reliability-based optimal load factors for seismic design of buildings. *Engineering Structures*, 151, 527–539. <https://doi.org/10.1016/j.engstruct.2017.08.046>
- De Anda, J., Ruiz, S. E., Bojorquez, E. & Inzunza-Aragón, I. (2023). Towards optimal reliability-based design of wind turbine towers using artificial intelligence. *Engineering Structures*, 294, 116778. <https://doi.org/10.1016/j.engstruct.2023.116778>
- Demuth, H. & Beale, M. (2000). *Neural network toolbox User's Guide*. The MathWorks, Inc.
- Det Norske Veritas & Riso National Laboratory. (2002). *Guidelines for design of wind turbines*. Denmark.
- Elgohary, H.A. (2025) A comprehensive review and ANN analysis of empirical formulae for determining the fundamental period of Multi-Story RC moment resisting frames. *Journal of Umm Al-Qura University for Engineering and Architecture*, 16, 1519–1526. <https://doi.org/10.1007/s43995-025-00192-3>
- Elkodama, A., Ismaiel, A., Abdellatif, A., Shaaban, S., Yoshida, S. & Rushdi, M.A. (2023) Control Methods for Horizontal Axis Wind Turbines (HAWT): State-of-the-Art Review. *Energies*, 16, 6394. <https://doi.org/10.3390/en16176394>
- Hakim, S. J. S., Irwan, J. M., Ibrahim, M.H.W., & Ayop, S. S. (2022). Structural damage identification employing hybrid intelligence using artificial neural networks and vibration-based methods. *Journal of applied research and technology*, 20(2), 221-236. Epub 27 de enero de 2023. <https://doi.org/10.22201/icat.24486736e.2022.20.2.1233>
- International Electrotechnical Commission. (2019). *Wind energy generation systems – Part 1: Design requirements IEC 61400-1:2019*. IEC Webstore
- Inzunza-Aragón, I.; Ruiz, S.E. & Cruz-Reyes, L. (2022). Use of Artificial Neural Networks and Response Surface Methodology for Evaluating the Reliability Index of Steel Wind Towers. *Advances in Civil Engineering*, 2022, 4219524. <https://doi.org/10.1155/2022/4219524>
- Jiang, Z., Li, H., Yang, H., Wu, H., Liu, W., Chen, Z. (2025). Review of Artificial Intelligence-Based Design Optimization of Wind Power Systems. *Wind*, 5, 18. <https://doi.org/10.3390/wind5030018>
- Jonkman, J., Butterfield, S., Musial, W. & Scott, G. (2009). Definition of a 5-MW Reference Wind Turbine for Offshore System Development (Technical report NREL/TP-500-38060). National Renewable Energy Laboratory.
- Kelele, H.K.; Kahsay, M.B. & Nielsen, T.K. (2023). Dynamic Response Analysis of Wind Turbine Structure to Turbulent Wind Load: Comparative Assessment in time and Frequency Domains. *Applied Mechanics*, 4, 841-855. <https://doi.org/10.3390/applmech4030043>
- Lagaros, N.D. (2023). Artificial Neural Networks Applied in Civil Engineering. *Applied Sciences*, 13, 1131. <https://doi.org/10.3390/app13021131>
- MathWorks (2019). MATLAB (Versión R2019b) [Software de computadora]. The MathWorks, Inc. <https://www.mathworks.com>
- Nordex SE. (2012). *N90/2500, N100/2500, N117/2400: Technical brochure*. Hamburg, Germany: Nordex SE.
- Jonkman, J., Butterfield, S., Musial, W. & Scott G. (2009). *Technical report: Definition of a 5-MW reference wind turbine for offshore system development NREL/TP-500-38060*. National Renewable Energy Laboratory.
- Saram, M. U., & Yang, J. (2025). A review of aeroelastic instabilities and resonance effects in wind turbine blade dynamics. *Wind Engineering*. <https://doi.org/10.1177/0309524x251405726>
- Secretaría de Energía (2024). *Reporte de avance de energías limpias*. Recuperado de: <https://www.gob.mx/cms/uploads/attachment/file/927403/RAEL.pdf>
- Soyoz, S., Hanbay, S. & Bagirgan, B. (2024). Structural monitoring, FEM updating and performance assessment of a wind turbine. *Procedia Structural Integrity*, 64, 484-491. <https://doi.org/10.1016/j.prostr.2024.09.289>
- Vazirizade, S. M., Nozhati, S., & Zadeh, M. A. (2017). Seismic reliability assessment of structures using artificial neural network. *Journal of Building Engineering*, 11, 230-235. <https://doi.org/10.1016/j.jobbe.2017.04.001>
- Witten, I.H., Frank, E., Hall, M.A. & Pal, C.J. (2016). *Data mining: Practical Machine Learning Tools and Techniques*. USA.

No.	Rol	Descripción
1	Conceptualización [Conceptualization]	Indira Inzunza Aragón
2	Curación de datos [Data curation]	Hugo Santiago Martínez Montenegro
3	Análisis formal [Formal analysis]	Indira Inzunza Aragón
4	Obtención de fondos [Funding acquisition]	Federico Valenzuela Beltrán
5	Investigación [Investigation]	Edmundo Amaya Gallardo
6	Metodología [Methodology]	Hugo Santiago Martínez Montenegro
7	Administración del proyecto [Project administration]	Edmundo Amaya Gallardo
8	Recursos [Resources]	Federico Valenzuela Beltrán
9	Software [Software]	Ricardo Valdez Cano
10	Supervisión [Supervision]	Indira Inzunza Aragón
11	Validación [Validation]	Ricardo Valdez Cano
12	Visualización [Visualization]	Hugo Santiago Martínez Montenegro.
13	Redacción - borrador original [Writing – original draft]	Indira Inzunza Aragón
14	Redacción - revisión y edición [Writing – review & editing]	Edmundo Amaya Gallardo