



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA
CARRERA DE ELECTRICIDAD

**PROYECCIÓN ENERGÉTICA DE LA CENTRAL EÓLICA HUASCACHACA DE 50 MW
APLICANDO REDES NEURONALES**

Trabajo de titulación previo a la obtención del
título de Ingeniero Eléctrico

AUTORES: CHRISTIAN ALFREDO NARVÁEZ ORTEGA
DANNY ALEXANDER LOJA CAJAMARCA
TUTOR: ING. JOHNNY XAVIER SERRANO GUERRERO, PhD.

Cuenca - Ecuador

2024

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, Christian Alfredo Narváez Ortega con documento de identificación N° 0107650145 y Danny Alexander Loja Cajamarca con documento de identificación N° 0106320062; manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Cuenca, 9 de mayo del 2024

Atentamente,



Christian Alfredo Narváez Ortega

0107650145



Danny Alexander Loja Cajamarca

0106320062

CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA

Nosotros, Christian Alfredo Narváez Ortega con documento de identificación N° 0107650145 y Danny Alexander Loja Cajamarca con documento de identificación N° 0105025050, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Artículo académico: “Proyección energética de la central eólica Huascachaca de 50 MW aplicando redes neuronales”, el cual ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, 9 de mayo del 2024

Atentamente,



Christian Alfredo Narváez Ortega

0107650145



Danny Alexander Loja Cajamarca

0106320062

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Johnny Xavier Serrano Guerrero con documento de identificación N° 0104983382, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: PROYECCIÓN ENERGÉTICA DE LA CENTRAL EÓLICA HUASCACHACA DE 50 MW APLICANDO REDES NEURONALES, realizado por Christian Alfredo Narváz Ortega con documento de identificación N° 0107650145 y por Danny Alexander Loja Cajamarca con documento de identificación N° 0106320062, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Cuenca, 9 de mayo del 2024

Atentamente,



Johnny Xavier Serrano Guerrero
0104983382

Ing. Johnny Xavier Serrano Guerrero, PhD.

0104983382

PROYECCIÓN ENERGÉTICA DE LA CENTRAL EÓLICA HUASCACHACA DE 50 MW APLICANDO REDES NEURONALES

Danny Alexander Loja Cajamarca
Carrera de Electricidad
Universidad Politécnica Salesiana
Cuenca, Ecuador
dloja1@est.ups.edu.ec

Christian Alfredo Narváez Ortega
Carrera de Electricidad
Universidad Politécnica Salesiana
Cuenca, Ecuador
cnarvaezo2@est.ups.edu.ec

Tutor
Xavier Serrano-Guerrero
Carrera de Electricidad
Universidad Politécnica Salesiana
Cuenca, Ecuador
jserranog@ups.edu.ec

Abstract—El presente trabajo aborda la predicción de la generación de electricidad en la central eólica Huascachaca. El objetivo es desarrollar un modelo de proyección energética utilizando redes neuronales para mejorar la planificación del despacho de energía del parque eólico. Se utilizan dos herramientas de predicción, las redes neuronales de memoria a largo plazo con unidades de corto plazo (LSTM) y la redes neuronales convolucionales (CNN). El método identifica y selecciona el modelo más adecuado de pronóstico energético para la central eólica. El Error Porcentual Absoluto Medio es significativamente menor en la red LSTM en comparación con la red CNN. Este estudio se presenta como una herramienta válida para la toma de decisiones en la administración de la generación de electricidad en parques eólicos.

Index Terms—Predicción, viento, energía eólica, redes neuronales, aerogeneradores.

I. INTRODUCCIÓN

Las energías renovables se distinguen por su capacidad de producción continua y prácticamente inagotable en una escala viable para la humanidad. Estas incluyen fuentes como la energía solar, eólica, hidroeléctrica, de biomasa y geotérmica, todas reconocidas por su bajo impacto ambiental. A pesar de que no están exentas de ciertos efectos negativos en el entorno, estos son considerablemente menores en comparación con las repercusiones asociadas a tecnologías basadas en combustibles fósiles. Prácticamente todos los países del mundo han adoptado el objetivo de satisfacer al menos parte de sus necesidades energéticas mediante fuentes renovables. La energía eólica, en particular, se destaca debido a su amplia expansión y a la tendencia de reducción de costos, lo que la posiciona para competir con las formas convencionales de generación de electricidad. Se espera que esta tendencia conduzca a una mayor presencia de la energía eólica en todos los rincones del planeta en el futuro cercano. [1]

La producción de electricidad mediante la energía eólica fue desarrollada a finales del siglo XIX y principios del siglo XX, coincidiendo con la expansión creciente de la

disponibilidad de electricidad en áreas cada vez más extensas, como ciudades y pueblos [2].

A nivel mundial, la generación eléctrica a partir de fuentes renovables ha experimentado un notable crecimiento, representando el 9.32 % de la generación total en 2018. En el año 2010, la industria de la energía eólica logró instalar una capacidad de 35,8 GW, a pesar de los desafíos económicos y financieros, lo que representó un aumento del 23 % en comparación con el año 2009. Este incremento elevó la capacidad mundial a 194,4 GW en parques eólicos instalados a nivel global. Este valor es más de diez veces superior a la capacidad registrada una década antes [3]. La generación eólica ha destacado en los últimos años, representando el 51.2 % de la generación renovable mundial en el mismo año [4]. En el año 2020, se alcanzaron cifras récord en la generación de energía eólica, con una capacidad instalada de 93 GW y un crecimiento del 53 %. Este crecimiento se debe en gran parte a la necesidad de encontrar fuentes de energía alternativas que sean sostenibles y que contribuyan a mitigar los efectos adversos del cambio climático [5].

El diseño de un aerogenerador requiere el conocimiento del potencial eólico de la zona en la que se instalará. En entornos urbanos, con complejos efectos aerodinámicos, comprender el comportamiento del viento es esencial para encontrar la ubicación óptima. Para abordar este desafío, se recurre a técnicas de dinámica de fluidos computacional, que permiten simular y comprender la complejidad de las corrientes de viento alrededor de edificios y estructuras [5]. Los aerogeneradores se clasifican en ejes horizontal o vertical. Mientras que los de eje horizontal son comunes en áreas extensas, no son ideales para entornos urbanos debido a la variabilidad del viento. En cambio, los de eje vertical son más adecuados para tales entornos. La electricidad es esencial para el progreso y el bienestar, especialmente con el crecimiento poblacional. Esto plantea desafíos en la gestión de sistemas energéticos, como la predicción de la generación y la demanda de electricidad. En este sentido, se han realizado

investigaciones en este ámbito tanto en el corto como el largo plazo [6]. El pronóstico a corto plazo es esencial para una gestión eficiente de la generación, distribución y operación de transmisión. En este sentido, se han desarrollado diversas técnicas, como procedimientos difusos y redes neuronales. Estas técnicas permiten anticipar la demanda eléctrica con horas o días de antelación, mejorando la toma de decisiones [6]. La integración de redes neuronales en la predicción de los datos correspondiente a la generación de energía renovable facilita la gestión y operación de los sistemas eléctricos, especialmente en microrredes aisladas donde la infraestructura de transmisión es limitada [7].

Para mejorar la precisión en la predicción del consumo eléctrico, las Redes Neuronales Artificiales (RNA) se han vuelto esenciales. Modeladas a partir de las redes neuronales biológicas, las RNA son idóneas para capturar relaciones no lineales entre variables, lo que las hace útiles en la modelación de fenómenos complejos. Aunque su uso puede ofrecer pronósticos más precisos con menos errores, enfrentan desafíos como la selección de datos de entrenamiento, altos costos computacionales y la necesidad de ajustes empíricos para optimizar el modelo [8].

El modelado y la caracterización de las turbinas eólicas son aspectos críticos en la generación de energía eólica. Para ello se requiere la estimación precisa de factores críticos como la densidad atmosférica, la superficie de barrido del rotor y la función del coeficiente de rendimiento. Esta información es esencial para comprender y optimizar el rendimiento de una turbina eólica específica. Sin embargo, dado el creciente valor de la energía eólica como una fuente de energía renovable y amigable con el medio ambiente, surge la necesidad de avanzar en la eficiencia y el control de estos sistemas. En este contexto, las redes neuronales han demostrado ser herramientas valiosas para predecir datos relacionados con la generación eólica. La combinación de datos recopilados en tiempo real con redes neuronales permite mejorar la capacidad de pronosticar la generación de energía eólica. Estas proyecciones exactas son esenciales para asegurar la estabilidad y el rendimiento óptimo de los sistemas de suministro eléctrico, dado que posibilitan una integración más efectiva de la energía generada por el viento en la red eléctrica y la planificación de la generación de energía [9].

El análisis de datos de viento es fundamental para la gestión de la generación de electricidad en parques eólicos. En [10], se lleva a cabo el análisis de los datos de velocidad del viento recopilados en la estación meteorológica de Chimborazo. Además, se realiza una evaluación del rendimiento del modelo Auto-regresivo no lineal con entradas exógenas (NARX) como una herramienta predictiva. También se ha propuesto un enfoque para reconstruir series temporales de precipitaciones con ausencia de datos de las estaciones meteorológicas [11].

En [12] se aborda la predicción a corto plazo de la velocidad del viento en series temporales incompletas, vital para el despacho de la generación. El proceso implica el uso de anemómetros en estaciones meteorológicas, que pueden generar datos falsos o faltantes debido a varios problemas. Se propone reconstruir las series temporales usando RNA y predecir la velocidad del viento a corto plazo con el método de *k* Vecinos más Cercanos. Se valida la metodología con datos de diversas ubicaciones en Michoacán, México. Este estudio contribuye a mejorar la precisión en la predicción del viento para la planificación y gestión de la energía renovable.

La velocidad del viento se define como una serie temporal, que tiene cuatro componentes subyacentes: la tendencia, el ciclo, la estacionalidad y el error (o aleatoriedad). Existen técnicas diseñadas para minimizar la aleatoriedad de la serie, un ejemplo de ello son las técnicas que miden el error cuadrático mínimo. Estas técnicas permiten determinar cuál presenta una menor dispersión con respecto a los datos reales, ofreciendo una herramienta valiosa para la evaluación y ajuste de las series temporales [13].

El MAE (Error Absoluto Medio) se refiere a la medida promedio de los errores en un proceso de pronóstico, sin tener en cuenta su dirección. Básicamente, es el promedio de los valores absolutos de los errores calculados. Este parámetro ofrece una métrica fácil de interpretar, dado que la pérdida se representa en las mismas unidades que la variable de salida, tal como se ve en la Ecuación 1 .

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

Por otro lado, el MAPE (Error Porcentual Absoluto Medio) evalúa el grado de error en forma de porcentaje, lo que lo hace independiente de la escala utilizada. Se determina como el promedio de los errores porcentuales, sin tener en cuenta su dirección. Esta medida es particularmente útil en el análisis de series temporales consistentes y equidistantes. Sin embargo, el MAPE (ver Ecuación 2) es sensible a la escala y no se recomienda en situaciones con bajos volúmenes de datos. Dado que se expresa en términos porcentuales, resulta más comprensible que otras métricas, convirtiéndolo en un indicador comúnmente utilizado para comparar diversos modelos de pronóstico con conjuntos de datos distintos [14].

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2)$$

II. METODOLOGÍA

En la Figura 1 se muestra la metodología del sistema de predicción de velocidades del viento propuestas y proyección energética.




Fig. 1. Metodología aplicada al proyecto

A. Etapa 1: Recolección y procesamiento de datos históricos

Se recolectaron registros históricos de la actividad de la Central Eólica Minas de Huascachaca. Se recaba información relevante sobre variables importantes, como la velocidad y dirección del viento, se procede a depurar los datos para eliminar cualquier anomalía o inconsistencia.

B. Etapa 2: Selección de las variables de entrada y salida de los datos históricos

Se dispone de la velocidad y dirección del viento, además del día, mes y año, se escogen como variables de entrada la velocidad, la dirección, el día y como variables de salida únicamente la velocidad de viento.

Se disponen de 3 variables (velocidad, dirección y día) para alimentar a la capa de entrada de cada una de las RNA, las variables velocidad de viento anterior y dirección correspondiente a esa velocidad son variables con alto índice de correlación, mientras que las otras variables corresponden a valores de la fecha, que serán utilizadas en el modelo como apoyo para reducir los errores en la predicciones.

1) *Velocidad de viento anterior*: Velocidad del viento promedio [m/s] en periodos de 10 minutos durante toda la muestra.

2) *Dirección*: Dirección del viento se recibe con respecto a las palas en un ángulo entre los -180° a 180° grados, pues la góndola se fija en una posición que se considera se recibe la mayor cantidad de viento.

3) *Día*: Como el día se trata de un valor de fecha se realizó la transformación usando senos y cosenos para representar el día en el rango de -1 a 1 se usaron las Ecuaciones 3 y 4 para la transformación.

$$Dx = \text{Sin}(t_s * N * \frac{2 * \pi}{86400}) \quad (3)$$

$$Dy = \text{Cos}(t_s * N * \frac{2 * \pi}{86400}) \quad (4)$$

Donde:

t_s es el tiempo en segundos entre muestras.

N es la posición de la muestra.

C. Etapa 3: División de los datos en conjuntos de entrenamiento y prueba

Se realiza la división del 80% de los datos de entrada destinados al conjunto de entrenamiento y el 20% restante al conjunto de pruebas.

Asimismo, se lleva a cabo la normalización y transformación de los datos para su posterior utilización en el diseño de la RNA.

D. Etapa 4: Configuración de la topología de la RN

Se establece la estructura que se emplea para predecir las velocidades del viento. Esto implica la selección de la programación en Python, así como la elección de las funciones de activación y la determinación del número adecuado de capas y neuronas. El objetivo principal es desarrollar una RNA capaz de discernir patrones complejos en los datos y realizar pronósticos precisos.

E. Etapa 5: Ajuste de parámetros de la RNA

En este proceso esencial, se procede a calibrar los parámetros y las capas de la RNA con el fin de mejorar su rendimiento y precisión en las predicciones.

F. Etapa 6 : Entrenamiento y validación

Se inicia el proceso de entrenamiento utilizando el 80% de los datos recopilados perteneciente al conjunto de entrenamiento y el 20% restante para pruebas.

La representación gráfica de la función de pérdida durante las etapas de entrenamiento y validación permite evaluar el desempeño del modelo e identificar el sobreajuste o el subajuste. Esta visualización proporciona información sobre cómo evoluciona la pérdida a lo largo del proceso de entrenamiento y permite tomar decisiones sobre ajustes adicionales en el modelo para mejorar su rendimiento y generalización. Lo que permite ajustar los pesos y parámetros para maximizar su eficacia predictiva.

G. Etapa 7: Comprobación del error

Se calcula el error del modelo utilizando diferentes métricas, como el MAE, el Error Cuadrático Medio (MSE) y el MAPE. Estas métricas proporcionan una evaluación objetiva de la precisión del modelo.

Se compara el viento predecido con el real y se analiza su dispersión para verificar el error que existe entre los dos perfiles de viento, los errores evaluados fueron MSE, MAE, MAPE.

H. Etapa 8: Predicción de la velocidad de viento

El modelo de RNA implementado realiza los pronósticos en base a los parámetros óptimos encontrados que resulten en un error mínimo.

I. Etapa 9: Proyección de energía

Mediante el modelado de la curva Potencia-viento de los aerogeneradores que se utilizan se obtiene la energía generada. En este proceso se relaciona la velocidad del viento predicho con la curva del aerogenerador y así obtener energía en intervalos de 10 minutos. Luego, se promedian cada 6 valores para obtener la energía horaria.

III. CASO DE ESTUDIO

Se utilizó como caso de estudio la predicción de valores de la velocidad del viento en la central eólica Huascachaca de 50MW ubicado en la Sierra Sur del Ecuador. Posteriormente se realiza la proyección de energía basada en dicha predicción de velocidades del viento aplicando la metodología presentada en la Fig. 1.

Los vientos locales en la zona de Huascachaca, son influenciados por la geografía local y tienen relevancia en la generación de energía eólica. Comprender la dinámica del viento a nivel local es crucial para optimizar la eficiencia en parques eólicos energéticos [15].

Para evaluar el potencial energético del Parque Eólico Huascachaca, se examina un aerogenerador específico, el DONGFANG-4000-145 con un diámetro de 132 metros y una potencia nominal de 3.57 MW. La selección de este aerogenerador se fundamenta en su capacidad para aprovechar las condiciones óptimas del sitio del proyecto. En particular, en este sitio se encuentra a 2700 msnm. La curva de potencia ajustada, adaptada a esta altitud específica, se presenta detalladamente en la Fig. 2.




Fig. 2. Curva de Potencia dada por el fabricante del aerogenerador DONGFANG-4000-145

IV. RESULTADOS

A. Recolección y procesamiento de datos históricos

En la Fig. 3 se muestra el set de datos pertenecientes a la variable velocidad de viento, los mismos que fueron recolectados desde el 24/02/2023 00:00h hasta 31/10/2023 23:50h.




Fig. 3. Serie temporal original del aerogenerador 1

B. Selección de las variables de entrada y salida de los datos históricos

En la Tabla I se presentan las variables de entrada y salida que el modelo tendrá a su alcance para reconocer patrones a los largo del conjunto de entrenamiento.

TABLE I
VARIABLES DE ENTRADA Y SALIDA DEL MODELO

Variables de entrada	Velocidad anterior	Dirección	Dx	Dy
Variables de salida	Velocidad			

C. División de los datos en conjuntos de entrenamiento y prueba

En la Fig. 4 se observa la división de los datos en conjuntos de entrenamiento y prueba. Por otro lado en la Tabla II se muestra información detallada de la división de los datos en los conjuntos correspondientes.




Fig. 4. Serie temporal con la división en conjuntos de entrenamiento y prueba del aerogenerador 1

Si bien el análisis y aplicación del modelo se realizó para toda la central eólica, en este documento se muestran las gráficas correspondientes al aerogenerador 1, en la central existe un total de 14 unidades de aerogeneradores.

TABLE II
DETALLE DE DISTRIBUCIÓN DE LA MUESTRA

Inicio de Muestras	00:00h 25 Febrero 2023
Fin de Muestras	23:50h 31 Octubre 2023
Conjunto de entrenamiento	80%
Conjunto de prueba	20%

D. Configuración de la topología de la RN

En esta etapa se configuro dos topologías de RNA, con el fin de comparar el desempeño de las dos RNA, las mismas que son presentadas como red neuronal de Memoria a largo plazo y corto plazo (LSTM) y la Red Neuronal Convolutiva (CNN).

E. Ajuste de parámetros de la RNA

1) *Parámetros de la red LSTM*: La Tabla III muestra los parámetros óptimos de la arquitectura de la LSTM que mejor se ajustó al valor real.

TABLE III
PARÁMETROS DE LSTM

Tipo de modelo	Sequential Model
Capa LSTM	70 unidades
Capa dropout	0.3
Capa Dense	1 unidad
Epochs	15
batch size	32

2) *Parámetros de la red CNN*: La Tabla IV muestra los parámetros óptimos de la arquitectura de la CNN que mejor se ajustó al valor real.

TABLE IV
PARÁMETROS DE CNN

Tipo de modelo	Sequential Model
Capa Conv1D	Unidimensional
filters	15
Capa MaxPooling1D	Unidimensional
Capa Flatten	Unidimensional
Capa Dense	50 unidades
Epochs	15
batch size	32

F. Comprobación del error

1) *Evaluación de errores para el conjunto de prueba con LSTM*: La Tabla V presenta los errores obtenidos en el conjunto de datos de prueba para las LSTM.

TABLE V
EVALUACIÓN DE ERRORES DIARIOS DEL AEROGENERADOR 1

Error	MSE	MAE	MAPE
Día 1	0.0090	0.0660	1.0950%
Día 2	0.0049	0.0458	1.2141%
Día 3	0.0042	0.0466	0.9736%
Día 4	0.0027	0.0453	0.8612%
Día 5	0.0006	0.0203	1.2851%
Día 6	0.0039	0.0423	1.0735%
Día 7	0.0144	0.0685	1.3831%
Promedio	0.0057	0.0478	1.1265%

2) *Evaluación de errores para el conjunto de prueba con CNN*: La Tabla VI presenta el error obtenido en el conjunto de datos de prueba para las CNN.

TABLE VI
EVALUACIÓN DE ERRORES DIARIOS DEL AEROGENERADOR 1

Error	MSE	MAE	MAPE
Día 1	0.9758	0.8079	40.0316%
Día 2	1.0238	0.8124	55.3343%
Día 3	0.8527	0.7341	35.7046%
Día 4	0.6375	0.6432	15.3471%
Día 5	1.1555	0.7658	64.5875%
Día 6	0.8078	0.7148	46.9891%
Día 7	0.8655	0.7342	55.9084%
Promedio	0.9027	0.7646	44.8432%

G. Predicción de la velocidad de viento

1) *Curvas diarias de viento para el conjunto de prueba*: En la Fig. 5 se observan las curvas de viento con los modelos de RNA propuestos, para un día del conjunto de prueba.

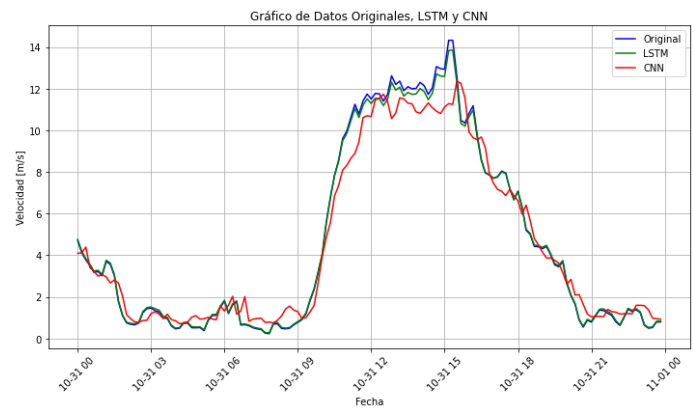


Fig. 5. Predicción vs valores reales de velocidad aerogenerador 1

2) *Curvas semanales de viento para el conjunto de prueba*: En la Fig. 6 se observan las curvas de viento predecidas con las RNA propuestas, para una semana del conjunto de prueba.

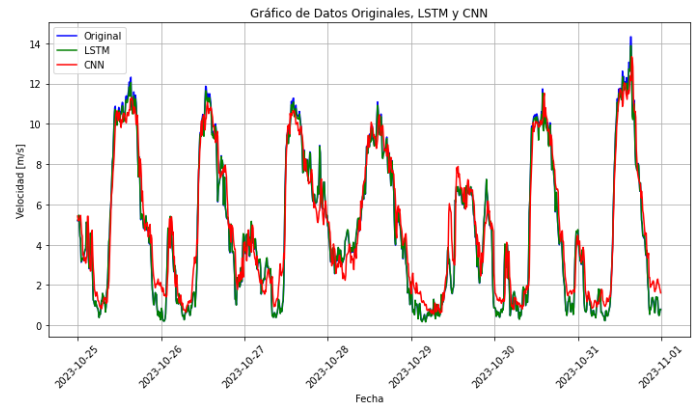


Fig. 6. Predicción vs valores reales de velocidad aerogenerador 1

H. Proyección de energética para el conjunto de prueba

Mediante el conjunto de pruebas se logró calcular la energía proyectada a lo largo de una semana, para ello se utilizó los valores correspondientes a las predicciones de viento, tomando en cuenta la curva del fabricante del aerogenerador DONGFANG-4000-145 presentada en la Fig. 2. Note que si la velocidad de viento es menor a los 2.5 m/s y si supera los 20 m/s la potencia generada es igual a cero. Para obtener la energía horaria se promedian los datos en una hora cada 10 minutos.




Fig. 7. Comparación de energía real vs proyectada del aerogenerador 1




Fig. 8. Comparación de energía promedio diaria real vs proyectada del aerogenerador 1

V. ANÁLISIS DE RESULTADOS Y DISCUSIÓN

Los resultados de las Tablas V, VI y en la Fig. 7, 8 se evidencia el desempeño de las RNA LSTM en comparación con las CNN, especialmente en la precisión de la predicción de valores, como en las métricas MSE, MAE y MAPE. Las LSTM destacan por su capacidad para capturar patrones temporales complejos, lo que las convierte en la opción preferida para la modelización de series temporales y su pronóstico.

Se observó que cuando se realizan predicciones diarias el MAPE más alto registrado fue de 1.3831% para las redes LSTM y 64.58% para las redes CNN.

En cuanto a la proyección de energía derivada de la predicción del viento, se observa disparidad entre ambas redes neuronales. Las RNA LSTM tienen errores significativamente más bajos. Estos hallazgos subrayan la capacidad superior de las LSTM para modelar dependencias temporales a corto plazo, lo que resulta fundamental para la precisión en la predicción de valores en contextos de series temporales la velocidad del viento.

Por otro lado, estudios similares como [16], en dónde se realiza un pronóstico de velocidades del viento con una RNA

para 1, 3, 6, 9 y 12 horas a diferentes alturas, se observaron que la métrica de error MAPE más bajo fue de 15.84% y se presentó a una altura del anemómetro de 101.8m y 1h como horizonte de predicción. En [17] se compara el modelo ARIMA con el modelo NARX en la predicción de los valores de velocidad del viento, se realizan predicciones para aproximadamente 2 días (50h), donde se obtiene las siguientes métricas de error. Para el modelo ARIMA el MAE fue de 0.91 y para el modelo NARX fue de 0.86, de la misma forma el MSE fue 1.51 y 1.35 para el modelo ARIMA y NARX respectivamente. Adicionalmente, en [18], se realiza la predicción de la velocidad del viento basado en 30, 60 y 90 días, con tres modelos Holt–Winters, RNA y modelo híbrido, la evaluación de las métricas de error consideradas fueron el MSE y el RMSE obteniendo como resultado en el modelo Holt–Winters basado en 90 días un RMSE de 2.14 m/s y un MAE de 1.62 m/s.

Del análisis de los resultados realizado es notorio que el presente estudio obtiene un MAPE considerablemente menor (1.1265% en promedio en la semana de análisis) que el estudio [16], en el que el MAPE mas bajo fue de 15.84%.

Con respecto a [17], el MAE reportado fue de 0.91m/s, mientras que, en contraste, el método presentado en este artículo exhibió un promedio notablemente inferior, alcanzando un valor de 0.0478m/s en términos de MAE. Este marcado contraste en los resultados resalta la eficacia y precisión del enfoque propuesto en el artículo actual.

Las redes CNN presentadas en este análisis presentaron un valor de MAPE elevado siendo este de 44.8432% en promedio semanal, en comparación con los resultados presentados en el análisis [16], donde se obtienen valores menores.

VI. CONCLUSIONES

El presente trabajo demuestra el cumplimiento del objetivo inicial ya que la proyección energética se logra por medio de predicciones diarias. Estas predicciones son más precisas que las predicciones semanales, en donde los errores se incrementan considerablemente. Estos resultados respaldan la elección de las RNA LSTM sobre las CNN.

Se obtuvo un MAPE promedio diario de 1.1265% para las redes LSTM mientras que para las redes CNN se obtuvo un MAPE promedio diario de 44.8432%, para las predicciones semanales el MAPE en las LSTM fue de 2.0311% y 56.4581% para las CNN.

Se identifican áreas para futuras investigaciones, como la optimización de la arquitectura de la RN y la exploración de enfoques adicionales para mejorar la precisión de las predicciones. Estas consideraciones sugieren un camino continuo de desarrollo en el empleo de RAN para prever la producción de energía generada por el viento.

REFERENCES

- [1] C. Espejo Marín and R. García Marín, "La energía eólica en la producción de electricidad en España," *Revista de Geografía Norte Grande*, no. 51, pp. 115–136, 2012.
- [2] W. Ortiz Alarcón *et al.*, "Análisis y modelamiento de la calidad de la potencia de un sistema de generación eólica en un sistema eléctrico industrial," 2008.
- [3] X. V. Solaun, "La energía eólica una tecnología eficiente de generación eléctrica," *Hermes: pentsamendu eta historia aldizkaria= revista de pensamiento e historia*, no. 38, pp. 30–39, 2011.
- [4] A. Á. B. Santos, O. Camargo, A. Back, F. Silva, F. Catani, F. Estante, G. Lima, G. Violato, J. Araújo, P. Andrade *et al.*, "Atlas eólico bahía," 2013.
- [5] A. F. Galindo, J. A. Rosero, and C. V. Labriola, "Estudio de potencial de generación eólica y diseño de perfil asimétrico para un aerogenerador darrieus tipo h," in *2022 IEEE Biennial Congress of Argentina (ARGENCON)*, Sep. 2022, pp. 1–8.
- [6] X. Serrano-Guerrero, L.-F. Siavichay, J.-M. Clairand, and G. Escrivá-Escrivá, "Forecasting building electric consumption patterns through statistical methods," in *Advances in Emerging Trends and Technologies*, M. Botto-Tobar, J. León-Acurio, A. Díaz Cadena, and P. Montiel Díaz, Eds. Cham: Springer International Publishing, 2020, pp. 164–175.
- [7] X. Serrano-Guerrero, M. Briceño-León, J.-M. Clairand, and G. Escrivá-Escrivá, "A new interval prediction methodology for short-term electric load forecasting based on pattern recognition," *Applied Energy*, vol. 297, p. 117173, 2021.
- [8] X. Serrano-Guerrero, R. Prieto-Galarza, E. Huilcatanda, J. Cabrera-Zeas, and G. Escrivá-Escrivá, "Election of variables and short-term forecasting of electricity demand based on backpropagation artificial neural networks," in *2017 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, Nov 2017, pp. 1–5.
- [9] C. A. Ramírez and A. J. Saavedra-Montes, "Parameter calculation of a small wind turbine model cálculo de parámetros del modelo de una turbina eólica (160 w)," in *2012 IEEE 4th Colombian Workshop on Circuits and Systems (CWCAS)*, Nov 2012, pp. 1–6.
- [10] P. F. Bolaños Logroño, "Predicción de la velocidad del viento mediante redes neuronales, para la estación meteorológica chimborazo." Master's thesis, Escuela Superior Politécnica de Chimborazo, 2018.
- [11] S. Infante, J. Ortega, and F. Cedeño, "Estimación de datos faltantes en estaciones meteorológicas de Venezuela vía un modelo de redes neuronales," *Revista de climatología*, vol. 8, pp. 51–70, 2008.
- [12] H. R. Rangel, N. A. G. Carrillo, J. J. Flores, L. A. Morales-Rosales, and G. M. Montelongo, "Pronóstico a corto plazo de velocidad del viento a partir de datos incompletos." *Res. Comput. Sci.*, vol. 139, pp. 81–95, 2017.
- [13] M. J. Alarcón, "Revisión del método de pronóstico del texto. elementos de producción," *Poliantea*, vol. 4, no. 7, 2008.
- [14] E. Guamán, V. Gavilanes, and I. Escudero, "Detección de datos anómalos e imputación de datos faltantes previo a la modelación temporal de velocidades de viento," *COMITÉ EDITORIAL*, p. 45.
- [15] F. X. A. Rojas, "Modelo multiestado para estudios de confiabilidad del parque eólico minas de huasachaca," Ph.D. dissertation, UNIVERSIDAD DE CUENCA, 2015.
- [16] P. J. Zucatelli, E. G. S. Nascimento, G. Aylas, N. Souza, Y. K. L. Kitagawa, A. Santos, A. Arce, and a. M. Moreira, "Short-term wind speed forecasting in Uruguay using computational intelligence," *Heliyon*, vol. 5, no. 5, 2019.
- [17] E. Cadenas, W. Rivera, R. Campos-Amezcuca, and C. Heard, "Wind speed prediction using a univariate arima model and a multivariate narx model," *Energies*, vol. 9, no. 2, p. 109, 2016.
- [18] M. Ferreira, A. Santos, and P. Lucio, "Short-term forecast of wind speed through mathematical models," *Energy Reports*, vol. 5, pp. 1172–1184, 2019.