



UNIVERSIDAD CÉSAR VALLEJO

FACULTAD DE INGENIERÍA Y ARQUITECTURA  
ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL

Pronóstico de la velocidad del viento para la producción de  
energía eólica en horizontes temporales utilizando redes  
neuronales en Tumbes - 2022

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:  
Ingeniero Ambiental

**AUTOR:**

Perez Lucas, Edson Adrian ([orcid.org/0000-0003-1857-8460](https://orcid.org/0000-0003-1857-8460))

**ASESOR:**

Dr. Jave Nakayo, Jorge Leonardo ([orcid.org/0000-0003-3536-881X](https://orcid.org/0000-0003-3536-881X))

**LÍNEA DE INVESTIGACIÓN:**

Calidad y Gestión de los Recursos Naturales

**LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:**

Desarrollo sostenible y adaptación al cambio climático

LIMA — PERÚ

2022

## Dedicatoria

El presente trabajo va dedicado especialmente a mis madres Victoria Marques (Aleli), Sofia Panduro viuda de Vásquez y Sonia Lucas quien a pesar de nuestras diferencias siempre me ha apoyado en todo.

A toda mi familia que a pesar de las adversidades pasadas en pandemia nunca dejaron de sonreír y me dieron la fortaleza para poder terminar esta hermosa etapa.

A mis hermanos por aguantar mi forma de darles cariño y no perder la paciencia, a las grandes amistades que tuve la dicha de conocer y aún conservo su amistad.

## Agradecimiento

Doy gracias a mi familia de parte de mi madre por haberme criado, hacer de mi un hombre de bien y darme la oportunidad de tener una carrera universitaria, a la familia de mi padre que me recibieron con los brazos abiertos y nunca me trataron como un extraño, finalmente agradezco a él joven Edward Elric quien me enseñó que “El hombre no puede obtener nada sin primero dar algo a cambio. Para crear, algo de igual valor debe darse a cambio. Esa es la primera ley de la Alquimia, la ley del Intercambio equivalente”.

## Declaratoria de autenticidad del asesor



**UNIVERSIDAD CÉSAR VALLEJO**

**FACULTAD DE INGENIERÍA Y ARQUITECTURA  
ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL**

### **Declaratoria de Autenticidad del Asesor**

Yo, JAVE NAKAYO JORGE LEONARDO, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA AMBIENTAL de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, asesor de Tesis titulada: "Pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neuronales en Tumbes - 2022", cuyo autor es PEREZ LUCAS EDSON ADRIAN, constato que la investigación tiene un índice de similitud de 9.00%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

LIMA, 24 de Julio del 2022

Apellidos y Nombres del Asesor:	Firma
JAVE NAKAYO JORGE LEONARDO DNI: 01066653 ORCID: 0000-0003-3536-881X	Firmado electrónicamente por: JJAVEN el 24-07- 2022 12:04:38

Código documento Trilce: TRI - 0365259



## Declaratoria de originalidad del autor



**UNIVERSIDAD CÉSAR VALLEJO**

**FACULTAD DE INGENIERÍA Y ARQUITECTURA  
ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL**

### **Declaratoria de Originalidad del Autor**

Yo, PEREZ LUCAS EDSON ADRIAN estudiante de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA AMBIENTAL de la UNIVERSIDAD CÉSAR VALLEJO SAC - LIMA NORTE, declaro bajo juramento que todos los datos e información que acompañan la Tesis titulada: "Pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neuronales en Tumbes - 2022", es de mi autoría, por lo tanto, declaro que la Tesis:

1. No ha sido plagiada ni total, ni parcialmente.
2. He mencionado todas las fuentes empleadas, identificando correctamente toda cita textual o de paráfrasis proveniente de otras fuentes.
3. No ha sido publicada, ni presentada anteriormente para la obtención de otro grado académico o título profesional.
4. Los datos presentados en los resultados no han sido falseados, ni duplicados, ni copiados.

En tal sentido asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de la información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

Nombres y Apellidos	Firma
PEREZ LUCAS EDSON ADRIAN DNI: 75279548 ORCID: 0000-0003-1857-8460	Firmado electrónicamente por: EPEREZL2 el 29-07- 2022 13:38:10

Código documento Trilce: INV - 1355315

Índice de contenidos	
Carátula.....	i
Dedicatoria.....	ii
Agradecimiento.....	iii
Declaratoria de autenticidad del asesor.....	iv
Declaratoria de originalidad del autor.....	v
Índice de tablas.....	viii
Índice de figuras.....	xi
I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO.....	5
III. METODOLOGÍA.....	15
3.1. Tipo y diseño de investigación.....	15
3.2. Variables y operacionalización.....	16
3.3. Población, muestra y muestreo.....	16
3.4. Técnicas e instrumentos de recolección de datos.....	16
3.5. Procedimientos.....	18
3.6. Método de análisis de datos.....	20
3.7. Aspectos éticos.....	21
IV. RESULTADOS.....	21
4.1. Tratamiento de Missing.....	21
4.2. Evaluación de la red neuronal artificial.....	24
4.2.1. Adiestramiento de la red neuronal en los diferentes horizontes temporales con la variable velocidad del viento.....	24
4.3. Pronóstico de valores futuros de la variable velocidad del viento.....	53
4.4. Producción de energía eólica.....	56
IV. DISCUSIÓN.....	58
V. CONCLUSIÓN.....	61

VI. RECOMENDACIONES.....	62
REFERENCIAS.....	63

## Índice de tablas

### Tabla 1.

Lista de Horizonte temporal de predicción según: ZHAO, X, WANG, S y LI, T (2011)..... 11

### Tabla 2

Funciones de activación más usadas..... 13

### Tabla 3

Herramientas estadísticas estándar más usadas..... 14

### Tabla 4.

Dirección del viento del día 21 de octubre del 2014 presenta la siguiente variación porcentual. .... 21

### Tabla 5.

Velocidad del viento del día 21 de octubre del 2014 presenta la siguiente variación porcentual. .... 23

### Tabla 6.

Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 4 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). .... 24

### Tabla 7.

Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 8 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). .... 27

### Tabla 8.

Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 16 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). .... 30

### Tabla 9.

Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 32 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). .... 33

Tabla 10.

Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 64 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). ..... 36

Tabla 11.

Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 4 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). ..... 39

Tabla 12.

Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 8 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). ..... 42

Tabla 13.

Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 16 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal)..... 45

Tabla 14.

Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 32 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal)..... 48

Tabla 15.

Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 64 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal)..... 50

Tabla 16.

Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 4 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal). ..... 53

Tabla 17.

Data de testeo del 1 de enero al 4 de enero del 2022 horizonte temporal a corto plazo..... 53

Tabla 18.

Data de testeo del mes de enero del 2022 a diciembre del 2023 en el horizonte temporal a mediano plazo. .... 56

Tabla 19.

Data de testeo de los años 2022 y 2029 en el horizonte temporal a largo plazo. .

Tabla 20.

Producción de la energía eólica en el horizonte temporal a corto plazo del 1 de enero del 2022..... 56

## Índice de figuras

### Figura 1.

Diagrama de flujo del procedimiento ..... 18

### Figura 2.

Crecimiento en horas de la dirección del viento en la estación Matapalo del día 21 de octubre del 2014. .... 22

### Figura 3.

Crecimiento en horas de la velocidad del viento en la estación Matapalo del día 21 de octubre del 2014. .... 24

### Figura 4.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 4 nodos en horizontes temporales a corto plazo. .... 27

### Figura 5.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 8 nodos en horizontes temporales a corto plazo. .... 30

### Figura 6.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 16 nodos en horizontes temporales a corto plazo. .... 33

### Figura 7.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 32 nodos en horizontes temporales corto plazo. .... 36

### Figura 8.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 64 nodos en horizontes temporales corto plazo. .... 39

### Figura 9.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 4 nodos en horizontes temporales a mediano plazo ..... 42

### Figura 10.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 8 nodos en horizontes temporales a mediano plazo. .... 45

Figura 11.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 16 nodos en horizontes temporales a mediano plazo. .... 47

Figura 12.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 32 nodos en horizontes temporales a mediano plazo ..... 50

Figura 13.

Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 64 nodos en horizontes temporales a mediano plazo. .... 53

## Resumen

Para poder usar la energía eólica es importante conocer los valores a futuros de la velocidad del viento, es por ello que la investigación pronosticó la velocidad del viento, empleando redes neuronales artificiales en los diferentes horizontes temporales, los datos fueron brindados por el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI), de la estación meteorológica Matapalo ubicado en el departamento de Tumbes. Los datos de la estación fueron ordenados con el programa Microsoft Excel, se encontraron datos incompletos, se empleó el método Missing para imputar los datos faltantes. Los datos imputados se dividen en 70% data de entrenamiento y el 30% restante en data de testeo las cuales fueron ingresados a la red neuronal artificial (ANN) en grupos de corto plazo (horas), mediano plazo (meses) y largos plazo (año). Con la red neuronal entrenada, se logró una mayor eficiencia cuando se trabajó con 32 nodos, un error cuadrático medio de 0.13 en la data de entrenamiento y 0.76 para la data de testeo a corto plazo, mientras que a mediano plazo se obtuvo una eficiencia con 32 nodos o capas ocultas 0.06 en la data de entrenamiento y 0.22 para la data de testeo a mediano plazo. Con esta misma red se pronosticó para los años 2022 y 2023 en los diferentes horizontes, arrojando valores de velocidad del viento que oscilan entre 0.09 m/s y 2.84 m/s para el periodo de corto plazo, para los promedios mensuales a mediano plazo la velocidad del viento oscila entre 0.75 m/s y 1.42 m/s y para largo plazo la velocidad del viento oscila entre 0.85 m/s y 0.88 m/s.

**Palabras clave:** Red neuronal artificial, Horizontes temporales, data de entrenamiento, data de testeo

## **Abstract**

In order to use wind energy, it is important to know the future values of wind speed, which is why this research predicts wind speed using artificial neural networks in short-term, medium-term and long-term time horizons, The data were provided by the SENAMHI of the Matapalo weather station located in the department of Tumbes. The station data was ordered with the Microsoft Excel program, finding incomplete data for which the "Missing" method was used to allocate the missing data. The imputed data are divided into 70% training data and the remaining 30% in testing data, which were entered into the artificial neural network (ANN) into short-term (hours), medium-term (months) and long-term (year). Using the trained neural network, greater efficiency was obtained when working with 32 nodes or hidden layers, which yielded a mean square error of 0.13 in the training data, and 0.76 for the short-term test data, while in the medium term an efficiency was obtained with 32 nodes or hidden layers of 0.06 in the training data and 0.22 for the medium-term test data. With the trained neural network, it was forecast for the years 2022 and 2023 in the short-term, medium-term and long-term horizons, yielding wind speed values that range between 0.09 m/s and 2.84 m/s for the short-term period, for the medium-term monthly averages the wind speed ranges between 0.75 m/s and 1.42 m/s and for the long term the wind speed ranges between 0.85 m/s and 0.88 m/s.

**Keywords:** Artificial neural network, Time horizons, training data, testing data

## I. INTRODUCCIÓN

Actualmente, el 80% de combustibles fósiles abarca la demanda de energía primaria a escala mundial, generando casi el 65% de gases de efecto invernadero de forma total. Se estima que el 40% de total de emisiones de CO<sub>2</sub> son producidas por el sector energético (IPCC, 2019)

Los datos revisados en la plataforma del banco Mundial (2019), señala que la generación de energía en el caribe y América latina (ALC) tuvo un aumento del 112% en el consumo eléctrico entre los años 1980 y 2014, además que los niveles de CO<sub>2</sub> durante dicho periodo presento un aumento alrededor del 106%, especulando una posible relación en las emisiones de CO<sub>2</sub> producto del consumo de energía eléctrica. Analizando casos especiales en la región de ALC como Brasil y México, presentan los niveles de emisiones de CO<sub>2</sub> más altos, mientras que el consumo energético es menor con respecto a las demás naciones como Uruguay, Chile y Argentina, estos países mencionados tienen una relación inversamente proporcional con relación al alto consumo eléctrico y bajos índices de emisiones de CO<sub>2</sub>.

En América Latina, especialmente en Chile, cuenta con un elevado beneficio de la energía eólica y solar en la transformación en electricidad, siendo un país fascinante para invertir en energías renovables (Blombergnef,2019). Esto sugiere que las fuentes renovables es una buena opción para minimizar el CO<sub>2</sub> producto de las emisiones generadas en la producción de energía eléctrica.

De acuerdo a la Agencia Internacional de Energías Renovables (IRENA), la energía eléctrica en el Caribe y América Latina, en el caribe el 75% de energía son a partir de fuentes alternativas como la geotérmica, eólica, energía solar, biomasa e hidroeléctrica, ocupando esta última el 80% de la producción de energía renovable. Según los datos del Banco Mundial, el aprovechamiento de energías renovables en la región se redujo en un 30% en los años 1990 al 2012. Las posibles causas se atribuyen a las barreras normativas que en

tropiezan los procesos de cambio hacia una unión energética en los países, así como los progresos en desarrollo e innovación tecnológica que ha transcurrido a un ritmo muy pausado. (CEPAL,2013)

La incorporación de energía de características renovables en el sistema energético y en particularidad la energía eólica ha tenido un mayor protagonismo, provocando una atención mayor en el rendimiento de los parques eólicos. Esta incorporación tiene diferentes motivos como: mitigación de gases de efectos invernaderos, seguridad energética, accesibilidad a la energía en el desarrollo rural y la generación de empleos (Brusca, Chiacchio, D'Urso, Famoso, Galvagno, 2020, p.1).

El Consejo Global de Energía Eólica (GWEC), elaboro un informe en el cual indica que el límite eólico instalado a nivel global abarco un potencial total de 60,4 GW a 651 GW en el año 2019, lo que simboliza un aumento del 19% con relación a las instalaciones del 2018 y un incremento del 10% con relación al total de energía eólica a nivel global en el 2018 (GWEC, 2019, p.10).

El levantamiento de las instalaciones de parques eólicos ha generado una atracción dentro de la comunidad científica para aprender de forma precisa los procedimientos para el pronóstico de la producción de energía de las instalaciones eólicas. Por ellos el Perú, en la actualidad, tiene 5 parques eólicos en la extensa costa peruana las cuales son C.E Parque Eólico Marcona (Ica), C.E. Wayra I (Parque Nazca), C.E. Parque Eólico Cupisnique (la libertad), C.E. Parque Eólico Talara (Piura) y C.E. Parque Eólico Tres Hermanas (Ica), entre ellas suman una potencia instalada de 371 MW (Osinergmin, 2020, p. 150).

El presente trabajo busca probar la eficiencia de las Red Neuronal Artificial (ANN) como un instrumento de pronóstico para la velocidad del viento usando datos con la mayor antigüedad posible, es por ello que se pronosticó la velocidad del viento para los años 2022 al 2023 en forma de corto plazo, mediano plazo y largo plazo. Por lo tanto, se propuso el problema general de la investigación **¿Es posible determinar el pronóstico de la velocidad del**

**viento para la producción de energía eólica en horizontes temporales utilizando redes neurales en Tumbes – 2022?** Asimismo, se plantearon los problemas específicos **¿Se podrá crear un instrumento para pronosticar en diferentes horizontes temporales la velocidad del viento para la producción de energía eólica utilizando redes neuronales en tumbes – 2022?; ¿En qué horizonte temporal determinado, el pronóstico de la velocidad del viento para la producción de energía eólica utilizando Redes Neuronales es aceptable en Tumbes – 2022?**

La Justificación ambiental de la presente investigación, es dar a conocer que la energía eólica es de uso inagotable, ilimitado y contribuye a impedir el calentamiento global al frenar el consumo de combustibles fósiles, al ser producidas por la velocidad del viento no contamina el ambiente, como la generación de energía convencional que produce gases de efectos invernaderos como se mencionó anteriormente. La producción de electricidad sin proceso de combustión ni fase de conversión térmica es un proceso muy favorable desde el punto de vista ecológico, porque es limpio y no hay problemas de contaminación. Se suprime radicalmente la combustión, lo que afecta a la atmósfera, suelo, agua, fauna, vegetación, etc. Por otra parte, la justificación social y económico del proyecto de investigación es poder pronosticar la velocidad del viento en un futuro, donde se podrá implementar parques eólicos en zonas de difícil acceso, pero con buenas condiciones meteorológicas cubriendo la demanda eléctrica y su vez generando puestos de trabajo.

**Objetivo General:** Determinar el pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neurales en Tumbes – 2022 . Por ende, se plantearon los siguientes **objetivos específicos:** Elaborar un instrumento para pronosticar en diferentes horizontes temporales la velocidad del viento para la producción de energía eólica utilizando redes neuronales en tumbes – 2022; Determinar en qué horizonte temporal los pronósticos de la velocidad del viento para la producción de energía eólica utilizando Redes Neuronales es aceptable en Tumbes – 2022.

De la misma manera se plantea la **hipótesis general**: Se podrá determinar el pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neurales en Tumbes - 2022. En esa misma línea, se plantea **las hipótesis específicas** de investigación: Se podrá elaborar un instrumento para pronosticar en diferentes horizontes temporales la velocidad del viento para la producción de energía eólica utilizando Redes neuronales en Tumbes – 2022; Hasta que horizonte el pronóstico de la velocidad del viento para la producción de energía eólica utilizando Redes Neuronales es aceptable en Tumbes – 2022.

## II. MARCO TEÓRICO.

Quiñonez, J; Huanca, E y Holguino A (2019). En su trabajo sobre los recursos eólicos determinan una evaluación cualitativa y cuantitativa tiene como objetivo de calificar el potencial aprovechable del recurso eólico en el departamento de Puno específicamente en la ciudad de Juliaca. Examinaron datos entre los años 2013 al 2014 por el Servicio Nacional de Meteorología e Hidrología del Perú – SENAMHI y lo compararon con los datos de Surface Meteorology and Solar Energy de la NASA. El trabajo cualitativo se hizo con la distribución Weibull para la estimación del potencial eólico para una altura 25 m, el potencial medio anual es de  $15.91 \text{ W/m}^2$  y para el doble de altura el potencial es de  $31.82 \text{ W/m}^2$ . Concluyendo que en su zona de estudio se puede instalar aerogeneradores de potencia media, pues la velocidad del viento no es mucha y su dirección es inestable. Además, los datos del SENAMHI y de la NASA son verídicos para calificar la velocidad del viento. Por otra parte, El trabajo cuantitativo trató en la clasificación de la velocidad del viento a 25 m de altura del suelo para la media mensual y la media horaria, al ser comparadas los datos del SENAMHI y de la NASA las velocidades medias mensuales muestran un promedio diferente de 8.93% dentro de las estaciones de clima cálidos, por lo que la velocidad del viento es superior en 3 m/s con dirección al este y oeste.

Charaja E. (2017) realizó una planificación de inversión con un valor factible para crear un parque eólico con un potencial bajo, la energía renovable sería empleado en el sistema de bomba de riego por goteo. Calculando que la demanda en potencia es de 14KW/h y de 450 KW/año. Los resultados se estimaron para 15 años con una tasa de 15.1% con respecto al CPPK, lo cual indica que el parque eólico es rentable.

Columbus, C, Del Rio Mendoza, M, Esquivel, P y Martínez, R (2018). Su estudio sobre la producción de energía eólica por medio de un plan estratégico está plasmado para un periodo de 10 años concluyendo en el 2028. El presente trabajo busca la expansión y el aumento de la industria de generación de energía eólica en el Perú. Para cumplir con los objetivos a largo plazo, mediano plazo y corto plazo se establecieron medidas, con ayuda del estado

en el 2008 se comenzó a realizar un proyecto que involucra la energía producida por el viento y diferentes tipos de energía renovables. Para el 2016 el 2.2% del total de energía generada en el Perú fue producida por la energía eólica. El Perú cuenta con un gran potencial para poder generar energía eólica y con ello se cubriría el desabastecimiento de energía eléctrica y la demanda nacional, Los lugares potenciales para poner parques eólicos serían Cajamarca, Ica, La Libertad, Lambayeque, Piura, etc, lo que provocaría inversiones nacionales e internacionales generando un crecimiento exponencial en los parques eólicos. Como conclusión de la implementación y desarrollo del plan de análisis y estrategias en el área de producción de energía eólica, busca implementar nuevos métodos específicos cumpliendo los objetivos a corto plazo, mediano plazo y largo plazo dirigidos a maximizar la rentabilidad, incrementar las ventas y producir mayor empleabilidad dentro de dicha área.

Bojórquez, M (2018). En su trabajo indica que el calentamiento global es producido por los gases de efecto invernadero y dichos gases son producidos por el sector energético. Es por ello que buscó dar nuevas opciones para la obtención de energía limpias, proponiendo un parque eólico marino que generara electricidad limpia, lo cual brindara electricidad a viviendas que no cuentan con dicho recurso, se estima que la creación gradual de parques eólicos para energías renovables pueda mitigar las emisiones de CO<sub>2</sub> que se genera en el sector eléctrico.

Cabana, W (2019) en su investigación busca el punto máximo en potencia de un panel a través de redes neuronales artificiales. Su tesis busca desarrollar un algoritmo usando redes neuronales. Desarrollando un modelo especulativo el cual produzca relaciones matemáticas y establezca algunos parámetros. Se empleo un Simulink establecido con las características técnicas del panel. Teniendo la simulación y el modelo teórico se generó 39000 ejemplos que fueron empleados como el entrenaamiento de la red neuronal, producto de ello se tuvo una ecuación matricial que estima el voltaje, intensidad de corriente y la máxima potencia para diferentes irradiancias, la temperatura e incidentes del panel. El resultado de la red neuronal artificial subestima en 1.5% la acumulación de energía, por ende, se pudo lograr un algoritmo de redes neuronales artificiales para el punto de máxima potencia.

Espíritu Y. Flores I. (2021) en su trabajo de investigación pronosticaron la velocidad del viento con promedios mensuales empleando la red neuronal Artificial (ANN). Para lo cual usaron datos de 3 estaciones meteorológicas, las cuales estuvieron incompletas, por medio del tratamiento Missing completaron los datos faltantes, obteniendo como resultados promedios que oscilan entre 2.3 y 3.6 m/s para el año 2021 los cuales fueron plasmados en mapas de velocidad del viento empleando el software ArcGIS.

Azumendi D. (2018) en su estudio desarrolla un instrumento que permite la predicción de la velocidad del viento con relación a 10 m de altura, para luego extrapolar las velocidades en forma vertical hasta el tamaño del aerogenerador. Mostrando una conducta aleatoria de la velocidad del viento, determino que no hay modelo que estime mejores pronósticos en algún horizonte de tiempo. El proyecto toma cuatro puntos y horizontes de tiempos diferentes. El aerogenerador es afectado por la densidad del aire afectando la curva de potencia, para ello se hace una rectificación por densidad de aire, con los datos obtenidos se interpola de tal forma que se pueda estimar la velocidad del viento.

De la Cruz, J (2018) en su artículo realiza un análisis basado en las variables eólicas como dirección y velocidad del viento. Los resultados tienen un gran potencial de certeza infiriendo que podría proveer la demanda de energía eléctrica, de la zona de estudio a través de parques eólicos, contemplando el uso eficaz del recurso.

Ibargüengoytia, P, Reyes, A, Borunda, M y Garcia U (2017) en su artículo científico plasma el avance de una de una Inteligencia Artificial (IA) para la predicción del potencial eólico apoyado de bases de datos meteorológicos de años pasados. El uso de las Redes Bayesianas Dinámicas (RBD) como una propuesta novedosa, se probó con datos meteorológicos del centro regional de tecnología eólica (CERTER) y al compararse se hallaron resultados satisfactorios que aprueban las Redes Bayesianas Dinámicas como un instrumento favorable para el pronóstico del potencial eólico

Carmelo, H et al (2017) en su trabajo tiene como objetivo predecir la progresión velocidad del viento en periodos de 30 días al noroeste de Brasil,

uso modelos como medias móviles autorregresivas formadas por Holt-Winters (HW) y (ARIMA) asimismo redes artificiales (ANN). Combinó modelos Arima y ANN y modelos ANN y HW. El producto estadístico de error de HW y ANN son valores bajos de 3.8%, 4.91% y 2.85%, se concluye que el error estadístico de las variables de los modelos híbridos por separado se compara y puede intervenir en la certeza de las velocidades del viento.

Nogay, H, Akinci T y Eidukeviciute, (2012) en su trabajo de investigación utilizaron prototipos de redes neuronales artificiales para predecir en corto plazo la velocidad del viento en su zona de estudio. Usaron datos del Servicio Meteorológico del estado con una antigüedad de diez años. El estudio empleó diferentes modelos de ANN, concluyendo que 60 neuronas es el prototipo más exitoso para poder pronosticar la velocidad del viento en un plazo corto. El entrenamiento en los modelos ANN se tuvo un error cuadrático medio de 0.378088 y 0.970490.

De Almedia Lucas, E (2019) en su tesis busca mejorar los pronósticos de energía eólica en su país utilizando los siguientes modelos Redes Neuronales Artificiales (RNA) y mesoescala WRF-ARW. En total tomó 8 modelos de predicción de energía producida por el viento, implementó modelos híbridos los cuales fueron WRF-RNA, modelos numéricos WRF-ARW con regresiones lineales (WRF-RL), empleándolo en parques eólicos los cuales fueron treinta y uno (1267,4 Mega watts (MW)), el híbrido constituido por el tipo WRF-RNA tuvo el mejor desempeño. El análisis Clustes sin corrección para los datos de velocidad del viento presentó alrededor de 17% de un error medio absoluto, para tener en cuenta, predicciones individuales para cada parque eólico. Para todos los modelos con relación a WRF-RNA los resultados de sesgo (bias) son más cercanos al cero y un valor medio absoluto en el rango de 10% y 6.5% cotejado con el modelo WRF-RL que está en el rango de 14% y 9%. Con el resultado se puede indicar que la unión de un modelo físico con un modelo RNA podría ser una excelente opción para el pronóstico de la energía eólica.

PEREZ, D (2019) en su trabajo tiene la exigencia de pronosticar la velocidad del viento en parques eólicos. Por ende, usa las Redes neuronales Artificiales (RNA) como herramienta para pronosticar la velocidad del viento en

el periodo de tiempo corto, a una hora en el futuro. Utilizo Feedforward Backpropagation en RNA, con la herramienta de Neural Networkk Toolbox de Matlab, empleando cuatro muestras apoyadas una de la otra, por las diferentes variaciones en sus parámetros internos o arquitectura, pudo determinar la tecnología más eficiente. Los valores de Error Medio Cuadratico (MSE) Y Error Medio Absoluto (MAE) son menores de 0.086 y 0.231 unidades, a comparación de otras publicaciones es muy favorable.

Gupta, A, Salau, A, Chaturvedi, P, Akinola, S y Ikechi N, (2019) en su trabajo hablan sobre la inteligencia artificial y como son empleadas en diferentes aplicaciones, una de ellas son las redes neuronales artificiales (ANN), pues resaltan por aplicabilidad y capacidad en distintos campos. La palabra Neuronal proviene del sistema nervioso Humano (animal) específicamente de las neuronas. Al evaluar las redes neuronales artificiales como un método de predicción. Se pone en juicio los conceptos de redes neuronales artificiales como sus aplicaciones y características, a su vez se compara con otros métodos convencionales, concluyendo que las redes neuronales artificiales es mejor que otros métodos convencionales para resolver problemas.

Nascimento et al. (2019) el artículo en conjunto tuvo como objetivo pronosticar la velocidad del viento en Uruguay en un periodo de corto plazo, aplicando diferentes herramientas para la red neuronal artificial (ANN). A lo largo del trabajo realizaron predicciones entre 1 y 3 horas con una precisión casi exacta, los inconvenientes comenzaron al momento de prolongar el tiempo de pronóstico, teniendo una menor precisión sin embargo al pronosticar a largo plazo los resultados fueron precisos. El trabajo presentado en conjunto da aportes al sector público, privado inclusive a la comunidad científica ya que brinda información de la velocidad del viento para el país de Uruguay que cuenta con índice alto en potencial eólico,

Los parámetros como humedad, temperatura, dirección del viento, velocidad del viento y la presión intervienen en la generación de energía eólica (Borunda, García, Ibergueyta y Reyes, 2018). Por su parte García, Flores, Manjarrez y Rodríguez, (2017) lo que buscaron fue calcular la cantidad de

energía que se generará en un periodo a futuro determinado con las variables que interfieren en la producción de energía eólica

El viento se genera a partir de una diferencia de calentamiento en varias partes del planeta generada por la radiación solar, generando presiones atmosféricas en distintos campos, las zonas con mayor calentamiento acostumbran tener una presión atmosférica menor, esto provoca que los cuerpos de aire se trasladen a la parte superior de la atmosfera producto de su poca densidad, y suelen bajar en zonas frías, y en las zonas frías la densidad del aire es mayor y estas se dirigen a las zonas donde están el aire caliente que se trasladaron a la parte superior de la atmosfera. Estos despliegues sumados a la rotación de la tierra, las fuerzas centrífugas y de Coriolis generan los vientos (Custódio, 2013, p.13).

M. Ouanani (2016) resalta que la energía renovable se origina de procesos naturales que se repiten constantemente. La ciencia de la energía renovable “es aquella ciencia que permite utilizar los flujos de energía renovable que se reponen constantemente para generar energía eléctrica de manera útil para el aprovechamiento de la humanidad con un modo sostenible.

Para M. Ouanani (2016) la energía eólica es producto de la energía cinética del viento aprovechada para producir electricidad con ayuda de aerogeneradores, el viento choca con si alises, estas empiezan a girar y remover una turbina, esto genera la producción de energía eléctrica a través de la energía mecánica producida por la energía cinética del viento. Es importante que los aerogeneradores se ubiquen en puntos estratégicos y se pueda aprovechar la velocidad del viento, estos aerogeneradores agrupados se les denomina parques eólicos. Considerados importantes fuentes de energía abundante e inagotable que no contamina el ambiente.

El viento cumple un papel importante en la obtención de energía según P. F. Bolaños Logroño (2018), es producida por el moviendo de las masas de aire gracias a la diferencia de presión y densidad, en distintas partes del planeta producto de la temperatura.

FERNÁNDEZ, L (2007) indica que el Horizonte Temporal de Predicción es un rango en un periodo (registrado en un punto en que se ejecutó el pronóstico) determinado en el instante futuro que realiza el pronóstico. De acuerdo a ZHAO, X, WANG, S y LI, T (2011) toman el horizonte temporal de predicción para la predicción en un parque eólico en 4 categorías. Tabla 1, de acuerdo a los escasos datos solo se trabajó con los horizontes Corto plazo, mediano plazo y largo plazo.

Por su parte FERNÁNDEZ, L (2007) indica que el pronóstico a corto plazo es el más atractivo, ya que las ofertas cierran a las 10 horas en el mercado eléctrico.

Tabla 1. Lista de Horizonte temporal de predicción según: ZHAO, X, WANG, S y LI, T (2011)

<b>Horizonte temporal de predicción</b>	<b>Rango de tiempo</b>
Muy corto plazo	Desde el segundo 0 a 30 min en el futuro
Corto plazo	Desde 30 min a 2 o 3 días en el futuro
Mediano plazo	Desde 2 o 3 días a un mes en el futuro
Largo plazo	Desde 1 mes a 12 meses más en el futuro

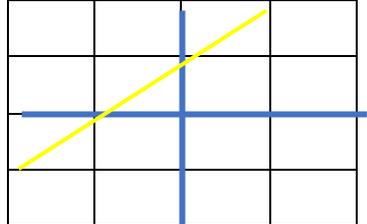
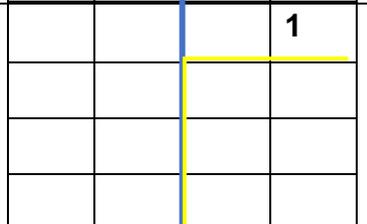
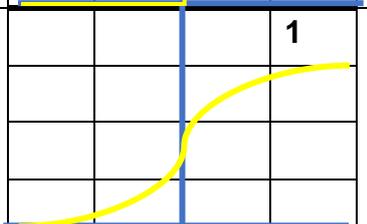
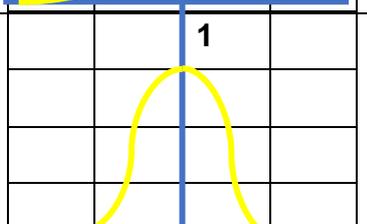
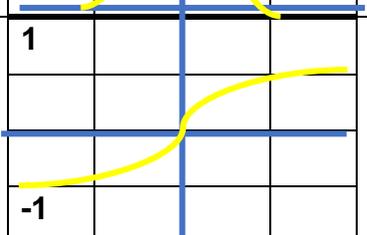
De acuerdo con Pérez, D. (2019). Las redes neuronales artificiales fueron hechas para imitar el procesamiento de un sistema neuronal biológico. La principal causa. Es elaborar un sistema eficaz de realizar actividades complejas en procesamientos, a través de muchas conexiones o interconexiones que trabajen de forma paralela. Una red neuronal aprende a solucionar problemas a través de los datos de entrada y se ajusta los pesos de las capas ocultas, tan bien puede resolver problemas con información probabilística. Para obtener un rendimiento eficaz es necesario conocer a la red neuronal a profundidad como el componente más simple.

La red neuronal no tiene una definición clara por eso varios autores indica lo siguiente:

- Es un dinámico sistema que copia al sistema nervioso. Por su capacidad de autoajustares podemos decir que es adaptable a las nuevas condiciones. (Bolaños, P. p 15)
- Conformada por herramientas computacional la red neuronal es capaz procesar infinidad de datos, elaborando algoritmos para asignar pesos apropiados, desarrollar patrones de operación, relacionar la linealidad del problema de estudio con predicciones confiables y precisas. (Profillidis, V y Botzoris, G, 2019)
- Se encuentra distribuidas por una arquitectura del sistema nervioso humano, conformado por elementos de procesadores múltiples. Cuenta con un algoritmo ajustable a parámetros solicitados. (Salas, R 2004)

Las redes neuronales artificiales al igual que una neurona biológica puede ser activada, mostrando diferentes estados, pero siempre en el rango de -1 a 1 o de 0 a 1 (Matich, 2001, p.14). La activación de la red neuronal determina si de tomaran en cuenta las entradas o no para llevar a cabo. Las funciones más comunes son (Bhaskar M, Jain, A y Srinath, N 2010, p.1-6)

Tabla 2. Funciones de activación más usadas

Función	Formula	Grafica
Función lineal	$f(\epsilon) = a * \epsilon + b$	
Función de paso binario	$f(\epsilon) = 1; \epsilon > 0$ $f(\epsilon) = 0; \epsilon < 0$	
Función sigmoide	$f(\epsilon) = \frac{1}{1 + e^{-\epsilon}}$	
Funciones Gaussian	$f(\epsilon) = e^{-\epsilon^2}$	
Función tangente hiperbólica	$f(\epsilon) = \frac{2}{1 + e^{-2\epsilon}} - 1$	

Con la red neuronal artificial entrenada es inevitable hacer una comprobación de la misma, para ello se analiza la precisión de la red neuronal artificial en las identificaciones de desconocidos patrones. Empleando los datos que no entraron en el entramiento de la red neuronal estos fueron datos de entrada y salida. Sucesivamente en la adaptación de un parámetro que acceda a tildar de forma cuantitativa que tan próximo esta de la respuesta pronosticada de acuerdo a la real o esperada. La evaluación cuenta con paramentos que son utilizados con mayor frecuencia para ver la eficacia de una red neuronal son los establecidos por Li, G y Shi, J (2010)

Tabla 3. Herramientas estadísticas estándar más usadas

Parámetros de evaluación	Formula
Error medio absoluto (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n  y_i - f_i $
Error porcentual medio absoluto (MAPE)	$MAPE = \frac{1}{n} \sum_{i=1}^n \left  \frac{y_i - f_i}{y_i} \right $
Error medio cuadrático (MSE)	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2$
Raíz de error medio cuadrático (RMSE)	$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2}$
<p>Donde:</p> <p><b>n</b> Manifiesta el total de datos utilizados para la comparación y evaluación.</p> <p><b>y<sub>i</sub></b> Manifiesta la salida real o esperada de las observaciones</p> <p><b>f<sub>i</sub></b> Manifiesta las predicciones de la red observada.</p>	

El esquema de la red neuronal artificial está compuesto por la interconexión entre las distintas neuronas. El conjunto de neuronas se le denomina capas, estas capas procesan su comportamiento y un número de variables similares (Bolaños F., 2018)

- Capa de entrada: Encargada de recensionar los datos y distribuirlos a las capas ocultas (neuronas). Los datos que se vaya a ingresar corresponderán al tipo y el número de neuronas
- Capas ocultas: Se encarga de la creación del algoritmo. La cantidad de neuronas depende de los datos ingresados en la capa de entrada.
- Capa de salida: Se encarga de entregar los datos analizados en las capas ocultas que fueron recepcionados en la primera capa

Una alegoría usual en el ámbito del aprendizaje automático que abarca la inteligencia artificial es examinar la resolución de la problemática como un modelo de aprendizaje que trata una vez terminado algún problema en tener la capacidad de determinar la situación problemática y responder empleando las

técnicas aprendidas (Moreno A. p 22, 1994). Mientras tanto Plaza E. (1992) indica que sistema puede aprender de manera automatizada por medio de un conjunto de algoritmos, tomando elecciones de acuerdo a experiencias recolectada con los ejercicios resueltos con anterioridad. Siendo capaces de laborar con un rango extendido de datos de entrada, inclusive con información incompleta.

Sanchez, B. (1993). Precisa al entrenamiento como “aquella acción que busca el ser humano para poder superar su límite físico en el ambiente deportivo, en la tutela del método científico y el olvido sistemático del método empírico”, provocando: Una autocrítica constante y una actitud de interrogante sistemática con la relación de las causas cíclicas en el entrenamiento deportivo. Tipificando las cuestiones pertinentes y su concisa definición. La prueba de formulación de la hipótesis de alguna solución de los mismos. Los antecedentes empíricos, los desarrollos de interpretación deductivos e inductivos y la dependencia a las reglas formales.

El método a través del cual la red neuronal aprende es el entrenamiento y el aprendizaje es la consecuencia de este desarrollo. El aprendizaje se ejecuta a raíz de todo el conjunto a comparación de la influencia individual de cada elemento (López, P. 2007). El desarrollo del entrenamiento siempre es participativo, actualizándose los pasos cada vez que logre la meta deseada. Cuando la red ha sido entrenada comienza la ejecución, que trata de mantener los pasos de la red fijo, pudiendo procesar los datos, es decir, podrá responder la red de una forma óptima a entradas no vistas con anterioridad.

### III. METODOLOGÍA

#### **3.1. Tipo y diseño de investigación**

La presente investigación es de tipo aplicada, la cual indaga y determina las características y propiedades más importantes de los objetivos de la investigación como, personas, viviendas, probetas o diferentes fenómenos que se desea estudiar. Es por ello, que el estudio presenta un diseño no

experimental, puesto que no establecen ni pueden probar similitudes cuales de forma directa entre dos elementos o variables (Borja, 2016, p.13).

### 3.2. Variables y operacionalización

- **Variable Independiente:** Redes neuronales
- **Variable Dependiente:** Pronostico de la velocidad del viento

### 3.3. Población, muestra y muestreo

- **Población:** La investigación tiene como población datos históricos de la velocidad del viento en los últimos 20 años.
- **Muestra:** La investigación tiene como muestra la información de velocidad del viento anotado en los últimos 20 años, tomada de la siguiente estación:
  - **Estación:** MATAPALO, ubicado en el distrito Matapalo, provincia de Zarumilla, departamento de Tumbes.  
Coordenadas: Latitud: 3°40'57.94" S, Longitud: 80°11'54.64" W y Altitud: 62 msnm. Tipo: Automática – meteorológica.  
Código: 472F353C
- **Muestreo:** Es la recopilación de toda la información meteorológica otorgada por el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI).

### 3.4. Técnicas e instrumentos de recolección de datos.

El procedimiento para obtener los datos será el Análisis Documental en el cual se basa en examinar datos contenidos en documentos existentes, tales como informes y base de datos, etc. Este procedimiento demanda de habilidad para seleccionar, ubicar y analizar la información que está libre. Una comprobación de la investigación en alguna área implica el análisis del contenido de los artículos de investigación que se han publicado (Kothari, 2009, p.110). En el siguiente trabajo el análisis documental consentirá la reducción y sistematización de la información compilada (base de datos) para su siguiente procesamiento como datos, valores o respuestas a la variable de investigación.

La herramienta que se empleará será una ficha de registro la cual consiente el almacenar datos e información de fuentes que fueron consultadas. Estas fichas son instrumentos prediseñados que deben ser entendibles, así como sencillas de completar para su posterior comprensión ya que facilitan la observación estructurada.

### 3.5. Procedimientos

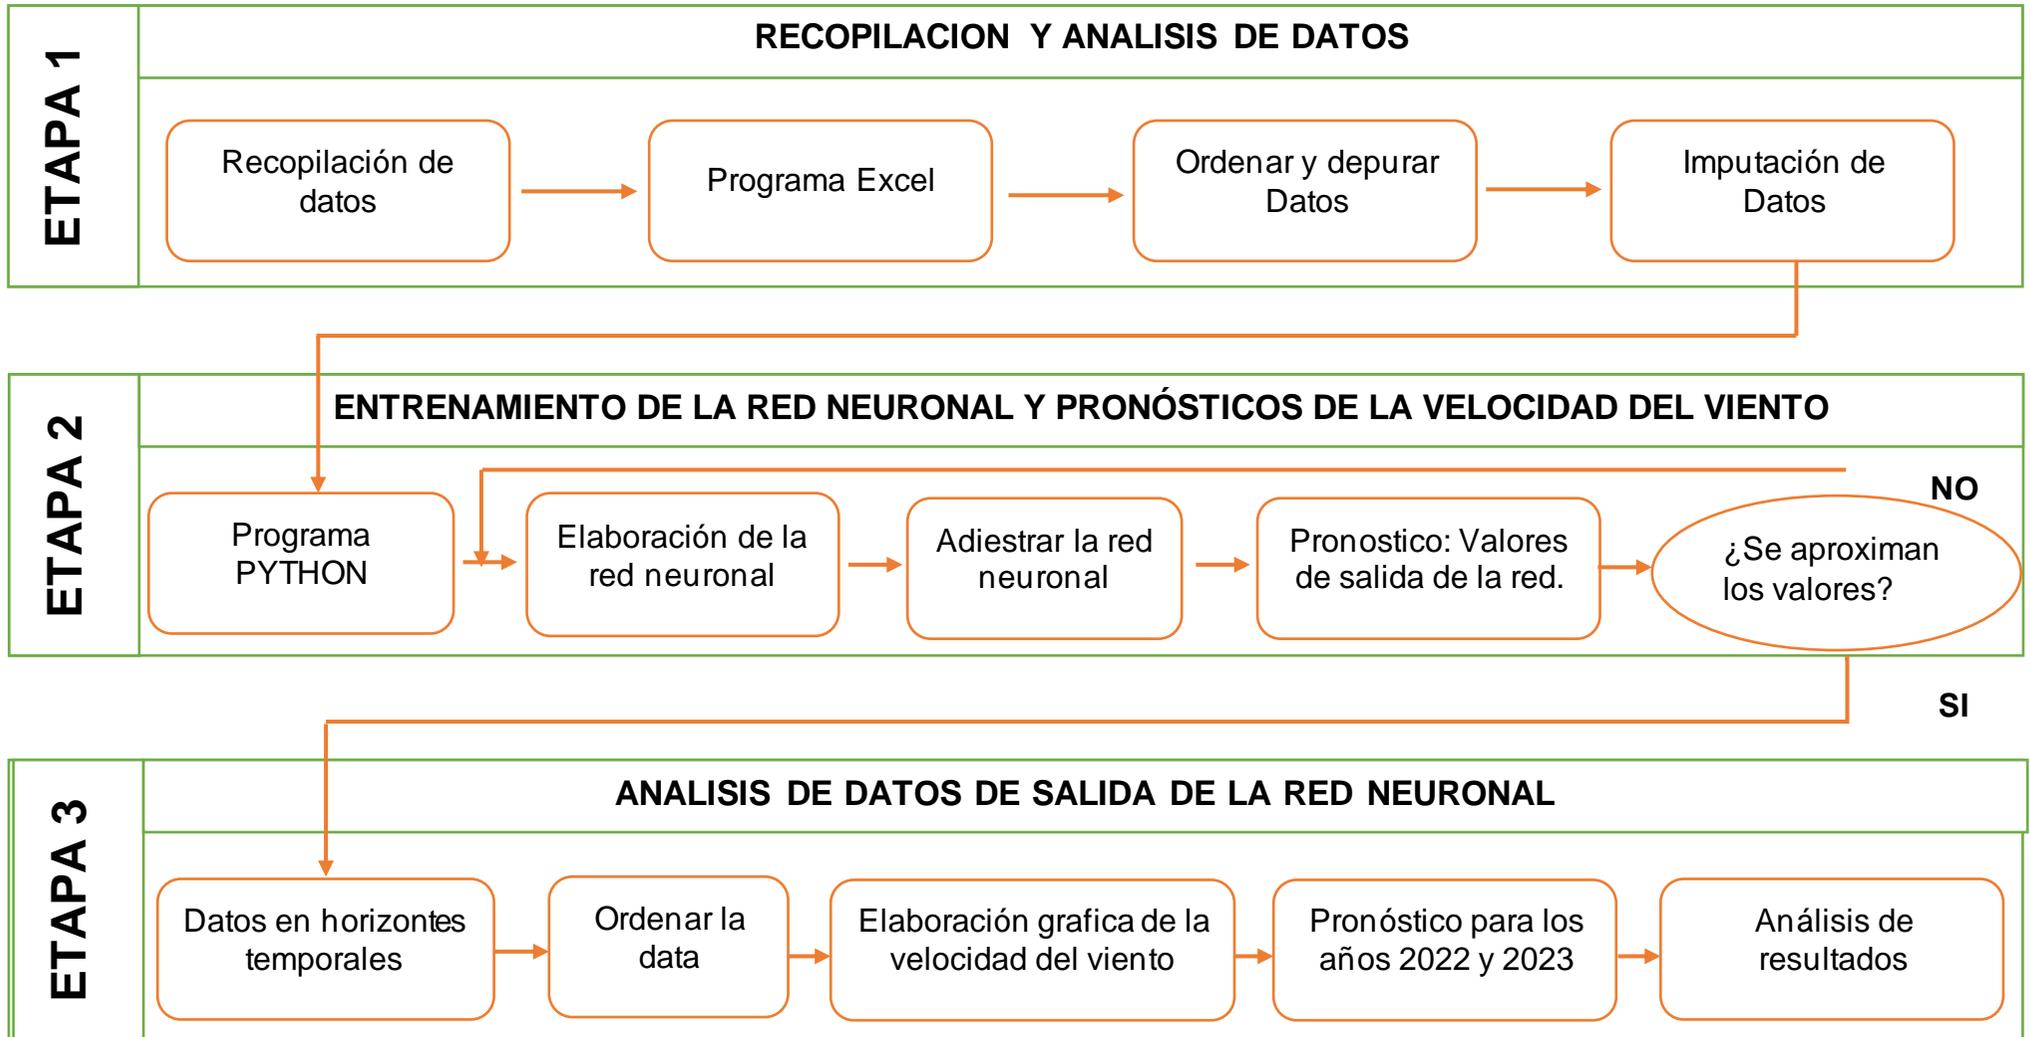


Figura 1. Diagrama de flujo del procedimiento

En el presente trabajo que tiene como nombre Pronostico de la velocidad del viento para la producción de energía eólica en Tumbes se empleó el instrumento de la red neuronal (ANN). Este sistema ANN se aplicó a los datos recopilados de la velocidad del viento, pronosticando valores futuros en los diferentes horizontes temporales horas, meses y años. Los datos que entrego la red neuronal fueron ordenados y analizados por graficas en Excel. Por consiguiente, se detalla las etapas para un mejor entendimiento.

## **ETAPA 1**

De acuerdo a la ley N° 27806, Ley de Transparencia y Acceso a la Información Pública, indica que toda persona tiene derecho a solicitar y recibir información de cualquier entidad de la Administración Pública. En ningún caso se exige expresión de causa para el ejercicio de este derecho. Por ende, se presentó una carta al SENAMHI, solicitando los datos meteorológicos con 20 años de antigüedad de la estación Matapalo ubicada en el departamento de Tumbes, que fue empleado en el presente trabajo de investigación.

Con los datos obtenidos se procedió a ordenar dicha información en el programa Microsoft Excel de acuerdo a sus fechas, evitando errores al momento de la transcripción de valores.

En la data entregada por el SENAMHI se encontró datos incompletos es por ello que se utilizó la metodología llamada Tratamiento de Missing, que emplea el análisis de los datos de la velocidad del viento tomada en horas, los cuales tiene similitud entre las horas restantes.

## **ETAPA 2**

Dentro del ordenador de uso personal se instaló el programa Anaconda Navigator, por medio de ese programa se descargó e instalo la aplicación Jupyter Notebook el cual tiene el uso de trabajar con programación Python , se escogió este medio por su fácil interface de trabajo

Los datos ordenados por el programa de Microsoft Excel, serán ingresados a la aplicación Jupyter Navigator por medio de librerías Pandas, para que pandas pueda correr se ingresó un código de nombre "pip Install

panda”, a su vez para que el programa pueda reconocer las hojas Excel se corrió el siguiente código “df = pd.read\_csv”. Una vez ingresado los datos se creó la red neuronal eligiendo el blackpropagation que se encargó del entrenamiento, para ello la data fue dividida en dos como data de entrenamiento y data de testeo.

La activación sigmoïdal en forma de función, se empleará el método de descenso gradiente como modelo matemático para la red neuronal artificial como entrenamiento. Para evaluar el desempeño de la red se aplicó el error cuadrático, se empleó diferentes números de capas ocultas como 4, 8, 16, 32 y 64, a su vez el número de vueltas se estableció en 300.

En el entrenamiento de la red neuronal artificial para todos los horizontes se utilizó el 70% como entrenamiento y el 30% como data de Testeo, con los primeros 70% de datos sirvió para pronosticar y el resultado de ese pronóstico fue comparado con los 30% restante de la data de testeo. Una vez entrenada la red neuronal se pronosticó la velocidad del viento en los horizontes temporales determinados en la investigación.

### **ETAPA 3**

Los datos de salida obtenidos por la red neuronal artificial fueron ordenados con el programa Excel de acuerdo a los horizontes temporales a corto, mediano y largo plazo. Una vez ordenados de acuerdo a lo establecido se procedió a realizar sus graficas para cada parámetro.

Con la red neuronal ya entrenada se pronosticó la velocidad del viento en los diferentes horizontes temporales para los rangos de inicio del año 2022 y finales del 2023 y por último se hizo el análisis de los resultados obtenidos.

#### **3.6. Método de análisis de datos**

**Microsoft Excel** Se empleó como herramienta secundaria pues se encargó de ordenar los datos importantes (velocidad del viento) el cual fue brindado por el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI).

A continuación, la data de la velocidad del viento fue trasladado a Python el cual trabajó mediante el diagnóstico de la **red neuronal artificial** (ANN) que pronosticó la velocidad del viento en los horizontes temporales.

El rendimiento del modelo de la red neuronal que se elaboró para la siguiente investigación fue medido con los criterios estándar del rendimiento estadístico

### 3.7. Aspectos éticos

El código de ética en investigación de la universidad privada César Vallejo, tiene como propósito que las investigaciones que se realizan en la Universidad, tienen que cumplir los máximos estándares establecidos como el rigor científico, responsabilidad y honestidad, para lograr asegurar exactitud del conocimiento científico y así proteger el derecho y bienestar de los que realizan las investigaciones protegiendo la propiedad intelectual, asimismo busca incentivar las buenas prácticas científicas incluyendo la formación de los investigadores. Por lo tanto, el presente trabajo fue sometido al Turnitin para determinar el porcentaje de autenticidad.

## IV. RESULTADOS

### 4.1. Tratamiento de Missing

Al momento de trabajar con la base de datos, está la posibilidad de la falta de datos o datos que son atípicos. Para completar los datos faltantes hay diferentes métodos, una de ellas es la imputación de datos desde una base de datos existente.

### 4.2. Imputación de datos en la estación Matapalo

#### Dirección del viento

Tabla 4. Dirección del viento del día 21 de octubre del 2014 presenta la siguiente variación porcentual.

Día	hora	Dirección	% de Variación
21/10/2014	0	332	
21/10/2014	1	349	5%
21/10/2014	2	332	-5%
21/10/2014	3	357	8%
21/10/2014	4	347	-3%
21/10/2014	5	331	-5%
21/10/2014	6	303	-8%

21/10/2014	7	304	0%
21/10/2014	8	148	-51%
21/10/2014	9	296	100%
21/10/2014	10	259	-13%
21/10/2014	11	33	-87%
21/10/2014	12	14	-58%
21/10/2014	13	15	7%
21/10/2014	14	328	2087%
21/10/2014	15	328	0%
21/10/2014	16	333	2%
21/10/2014	17	339	2%
21/10/2014	18	310	-9%
21/10/2014	19	283	-9%
21/10/2014	20	300	6%
21/10/2014	21	304	1%
21/10/2014	22	302	-1%
Promedio		272	

En la tabla 4. Se muestra la dirección del viento para la estación Matapalo que cuenta con variaciones altas; estas oscilan de -87% a 2087%



Figura 2. Crecimiento en horas de la dirección del viento en la estación Matapalo del día 21 de octubre del 2014.

En la figura 2 se visualiza el promedio no es semejante entre los lapsos de horas, además se halló datos faltantes los cuales fueron completados por medio de la imputación, usando la mediana 304 y el rango intercuartil 49; para evitar valores constantes se usó el proceso aleatorio con intervalo de 304;49.

## b) Velocidad del viento

Tabla 5. Velocidad del viento del día 21 de octubre del 2014 presenta la siguiente variación porcentual.

<b>Día</b>	<b>horas</b>	<b>velocidad</b>	<b>% de Variación</b>
21/10/2014	00:00:00	1.0	
21/10/2014	01:00:00	0.9	-10%
21/10/2014	02:00:00	0.9	0%
21/10/2014	03:00:00	0.9	0%
21/10/2014	04:00:00	0.9	0%
21/10/2014	05:00:00	0.8	-11%
21/10/2014	06:00:00	1.2	50%
21/10/2014	07:00:00	0.7	-42%
21/10/2014	08:00:00	0.8	14%
21/10/2014	09:00:00	0.7	-13%
21/10/2014	10:00:00	0.7	0%
21/10/2014	11:00:00	1.4	100%
21/10/2014	12:00:00	1.8	29%
21/10/2014	13:00:00	3.2	78%
21/10/2014	14:00:00	3.3	3%
21/10/2014	15:00:00	3.0	-9%
21/10/2014	16:00:00	2.3	-23%
21/10/2014	17:00:00	2.6	13%
21/10/2014	18:00:00	1.5	-42%
21/10/2014	19:00:00	1.4	-7%
21/10/2014	20:00:00	1.5	7%
21/10/2014	21:00:00	1.4	-7%
21/10/2014	22:00:00	1.2	-14%
<b>PROMEDIO</b>		<b>1.5</b>	

En la tabla 5 se visualiza la velocidad del viento en horas en la estación Matapalo, tienen variaciones altas -42% a 100%, además se aprecia, es que en la figura 4 que en las horas 00:00:00 y 22:00:00 la velocidad del viento es semejantes.



Figura 3. Crecimiento en horas de la velocidad del viento en la estación Matapalo del día 21 de octubre del 2014.

En la figura 3 se visualiza el promedio es semejante entre los lapsos de horas, además se halló datos faltantes los cuales fueron completados por medio de la imputación, usando el promedio 1.5 y la desviación estándar 1; para evitar valores constantes se usó el proceso aleatorio con intervalo 1.5;1.

#### 4.2. Evaluación de la red neuronal artificial.

##### 4.2.1. Adiestramiento de la red neuronal en los diferentes horizontes temporales con la variable velocidad del viento.

Tabla 6. Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 4 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

Fecha	Hora	Data del SENAMHI	Data de testeo
20/11/2021	07:00:00	0.5	0.5
20/11/2021	08:00:00	0.3	1
20/11/2021	09:00:00	0.7	2.3
20/11/2021	10:00:00	0.8	1.5
20/11/2021	11:00:00	1.9	1.6
20/11/2021	12:00:00	4.1	2
20/11/2021	13:00:00	5.6	1.9
20/11/2021	14:00:00	3.9	2.8
20/11/2021	15:00:00	3.3	3.5
20/11/2021	16:00:00	3.9	3.3
20/11/2021	17:00:00	3.5	3.2
20/11/2021	18:00:00	2.9	1.5

20/11/2021	19:00:00	2.4	2
20/11/2021	20:00:00	1.6	0.8
20/11/2021	21:00:00	1.7	1.4
20/11/2021	22:00:00	1.8	1.8
20/11/2021	23:00:00	1.5	1.1
21/11/2021	00:00:00	0.7	0.8
21/11/2021	01:00:00	1.4	0.8
21/11/2021	02:00:00	0.8	1
21/11/2021	03:00:00	1.6	0.9
21/11/2021	04:00:00	0.8	0.7
21/11/2021	05:00:00	0.6	1.4
21/11/2021	06:00:00	1.9	1.1
21/11/2021	07:00:00	2.5	0.7
21/11/2021	08:00:00	2.3	1.2
21/11/2021	09:00:00	1.2	1.6
21/11/2021	10:00:00	2.3	1.4
21/11/2021	11:00:00	2	2.3
21/11/2021	12:00:00	3.1	2.1
21/11/2021	13:00:00	1.9	3.3
21/11/2021	14:00:00	3.2	3.6
21/11/2021	15:00:00	2.5	3.7
21/11/2021	16:00:00	2.3	3.2
21/11/2021	17:00:00	1.9	3.8
21/11/2021	18:00:00	1.7	2.9
21/11/2021	19:00:00	1.6	0.6
21/11/2021	20:00:00	1.5	0.8
21/11/2021	21:00:00	1	2.2
21/11/2021	22:00:00	1.8	2
21/11/2021	23:00:00	1.6	0.1
22/11/2021	00:00:00	1	0.4
22/11/2021	01:00:00	1.1	3.1
22/11/2021	02:00:00	1.3	1.7
22/11/2021	03:00:00	0.9	1.4
22/11/2021	04:00:00	0.6	2
22/11/2021	05:00:00	1.1	2.1
22/11/2021	06:00:00	0.9	2.6
22/11/2021	07:00:00	0.5	2.6
22/11/2021	08:00:00	1	1.9
22/11/2021	09:00:00	2.3	1.3
22/11/2021	10:00:00	1.5	1
22/11/2021	11:00:00	1.6	1.2
22/11/2021	12:00:00	2	1.8
22/11/2021	13:00:00	1.9	3.2
22/11/2021	14:00:00	2.8	3.3
22/11/2021	15:00:00	3.5	4
22/11/2021	16:00:00	3.3	3.3
22/11/2021	17:00:00	3.2	2.4
22/11/2021	18:00:00	1.5	1.9

22/11/2021	19:00:00	2	2.3
22/11/2021	20:00:00	0.8	1.4
22/11/2021	21:00:00	1.4	1.8
22/11/2021	22:00:00	1.8	2
22/11/2021	23:00:00	1.1	1.2
23/11/2021	00:00:00	0.8	1.2
23/11/2021	01:00:00	0.8	1.8
23/11/2021	02:00:00	1	1.3
23/11/2021	03:00:00	0.9	0.8
23/11/2021	04:00:00	0.7	1.1
23/11/2021	05:00:00	1.4	0.4
23/11/2021	06:00:00	1.1	0.2
23/11/2021	07:00:00	0.7	0.4
23/11/2021	08:00:00	1.2	1.1
23/11/2021	09:00:00	1.6	1.6
23/11/2021	10:00:00	1.4	1.4
23/11/2021	11:00:00	2.3	1.1
23/11/2021	12:00:00	2.1	4
23/11/2021	13:00:00	3.3	4.1
23/11/2021	14:00:00	3.6	4.1
23/11/2021	15:00:00	3.7	3.1
23/11/2021	16:00:00	3.2	2.3
23/11/2021	17:00:00	3.8	1.4
23/11/2021	18:00:00	2.9	0.2
23/11/2021	19:00:00	0.6	1.7
23/11/2021	20:00:00	0.8	0.9
23/11/2021	21:00:00	2.2	1.4
23/11/2021	22:00:00	2	1.1
23/11/2021	23:00:00	0.1	0.3
24/11/2021	00:00:00	0.4	0.6
24/11/2021	01:00:00	3.1	1.9
24/11/2021	02:00:00	1.7	0.5
24/11/2021	03:00:00	1.4	0.2
24/11/2021	04:00:00	2	0.6
24/11/2021	05:00:00	2.1	1.2
24/11/2021	06:00:00	2.6	1.6
24/11/2021	07:00:00	2.6	1.4
24/11/2021	08:00:00	1.9	1.4

Red neuronal artificial con 4 nodos
Entrenamiento

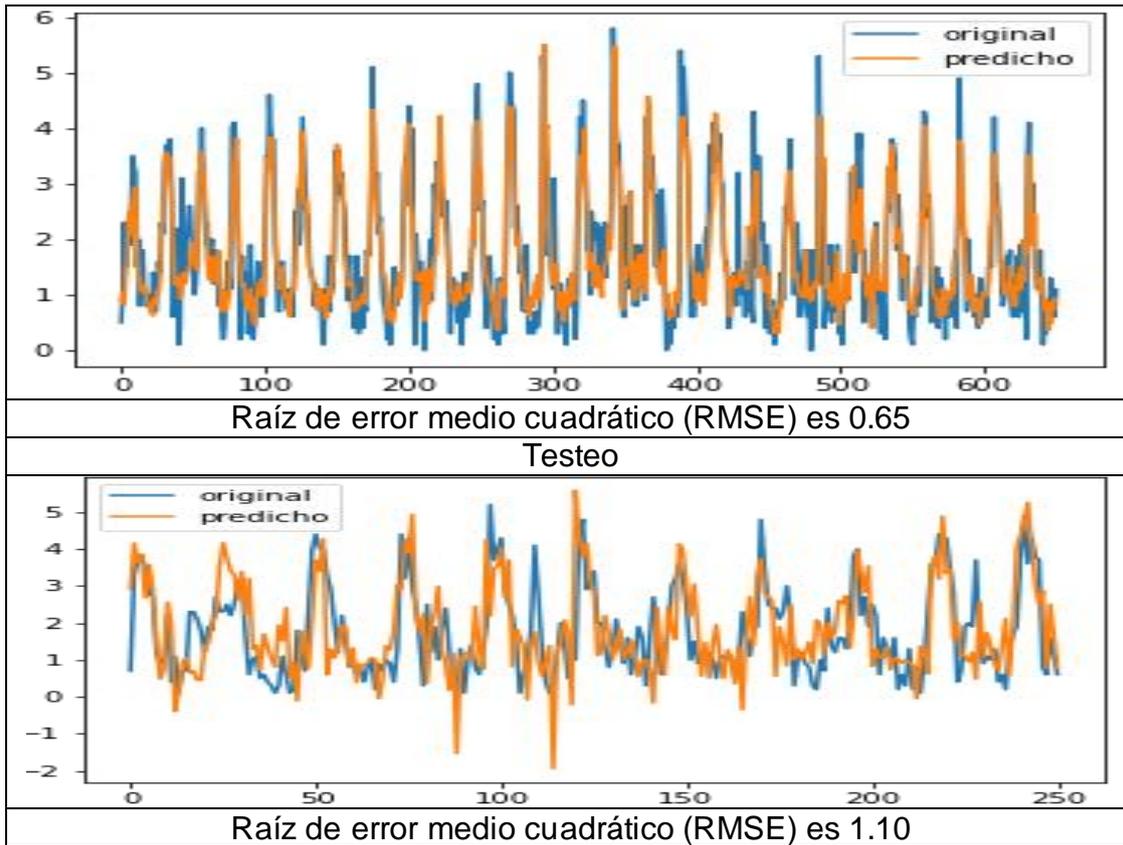


Figura 4. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 4 nodos en horizontes temporales a corto plazo.

En la figura 4 se observó la red neuronal artificial con 4 nodos, la data de entrenamiento presentó el valor de 0.65 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó el valor de 1.10 para la raíz de error medio cuadrático (RMSE).

Tabla 7. Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 8 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

Fecha	Hora	Data del SENAMHI	Data de testeo
20/11/2021	07:00:00	0.5	0.62
20/11/2021	08:00:00	0.3	0.63
20/11/2021	09:00:00	0.7	0.67
20/11/2021	10:00:00	0.8	1.62
20/11/2021	11:00:00	1.9	1.33
20/11/2021	12:00:00	4.1	2.44
20/11/2021	13:00:00	5.6	2.75
20/11/2021	14:00:00	3.9	2.57
20/11/2021	15:00:00	3.3	2.77

20/11/2021	16:00:00	3.9	3.04
20/11/2021	17:00:00	3.5	3.05
20/11/2021	18:00:00	2.9	2.27
20/11/2021	19:00:00	2.4	2.07
20/11/2021	20:00:00	1.6	2.15
20/11/2021	21:00:00	1.7	1.54
20/11/2021	22:00:00	1.8	1.79
20/11/2021	23:00:00	1.5	1.22
21/11/2021	00:00:00	0.7	1.25
21/11/2021	01:00:00	1.4	0.98
21/11/2021	02:00:00	0.8	1.09
21/11/2021	03:00:00	1.6	0.79
21/11/2021	04:00:00	0.8	1.00
21/11/2021	05:00:00	0.6	1.28
21/11/2021	06:00:00	1.9	1.38
21/11/2021	07:00:00	2.5	1.58
21/11/2021	08:00:00	2.3	1.52
21/11/2021	09:00:00	1.2	1.59
21/11/2021	10:00:00	2.3	1.74
21/11/2021	11:00:00	2	1.98
21/11/2021	12:00:00	3.1	2.67
21/11/2021	13:00:00	1.9	2.44
21/11/2021	14:00:00	3.2	3.31
21/11/2021	15:00:00	2.5	3.19
21/11/2021	16:00:00	2.3	2.99
21/11/2021	17:00:00	1.9	2.90
21/11/2021	18:00:00	1.7	2.79
21/11/2021	19:00:00	1.6	2.36
21/11/2021	20:00:00	1.5	1.32
21/11/2021	21:00:00	1	1.38
21/11/2021	22:00:00	1.8	1.94
21/11/2021	23:00:00	1.6	1.60
22/11/2021	00:00:00	1	0.53
22/11/2021	01:00:00	1.1	1.19
22/11/2021	02:00:00	1.3	2.11
22/11/2021	03:00:00	0.9	1.07
22/11/2021	04:00:00	0.6	1.56
22/11/2021	05:00:00	1.1	1.61
22/11/2021	06:00:00	0.9	1.89
22/11/2021	07:00:00	0.5	1.90
22/11/2021	08:00:00	1	2.10
22/11/2021	09:00:00	2.3	2.46
22/11/2021	10:00:00	1.5	2.02
22/11/2021	11:00:00	1.6	2.08
22/11/2021	12:00:00	2	1.76
22/11/2021	13:00:00	1.9	2.66
22/11/2021	14:00:00	2.8	3.08
22/11/2021	15:00:00	3.5	2.81

22/11/2021	16:00:00	3.3	2.98
22/11/2021	17:00:00	3.2	3.24
22/11/2021	18:00:00	1.5	2.70
22/11/2021	19:00:00	2	1.69
22/11/2021	20:00:00	0.8	1.22
22/11/2021	21:00:00	1.4	1.48
22/11/2021	22:00:00	1.8	1.60
22/11/2021	23:00:00	1.1	1.61
23/11/2021	00:00:00	0.8	1.99
23/11/2021	01:00:00	0.8	1.81
23/11/2021	02:00:00	1	1.20
23/11/2021	03:00:00	0.9	1.58
23/11/2021	04:00:00	0.7	1.31
23/11/2021	05:00:00	1.4	1.09
23/11/2021	06:00:00	1.1	0.60
23/11/2021	07:00:00	0.7	0.61
23/11/2021	08:00:00	1.2	0.58
23/11/2021	09:00:00	1.6	1.10
23/11/2021	10:00:00	1.4	1.19
23/11/2021	11:00:00	2.3	0.98
23/11/2021	12:00:00	2.1	2.64
23/11/2021	13:00:00	3.3	3.87
23/11/2021	14:00:00	3.6	3.29
23/11/2021	15:00:00	3.7	3.84
23/11/2021	16:00:00	3.2	2.79
23/11/2021	17:00:00	3.8	1.37
23/11/2021	18:00:00	2.9	-0.01
23/11/2021	19:00:00	0.6	0.97
23/11/2021	20:00:00	0.8	1.30
23/11/2021	21:00:00	2.2	1.30
23/11/2021	22:00:00	2	1.12
23/11/2021	23:00:00	0.1	0.85
24/11/2021	00:00:00	0.4	1.11
24/11/2021	01:00:00	3.1	1.27
24/11/2021	02:00:00	1.7	1.12
24/11/2021	03:00:00	1.4	0.75
24/11/2021	04:00:00	2	0.97
24/11/2021	05:00:00	2.1	0.95
24/11/2021	06:00:00	2.6	1.18
24/11/2021	07:00:00	2.6	1.72
24/11/2021	08:00:00	1.9	1.49

Red neuronal artificial con 8 nodos
Entrenamiento

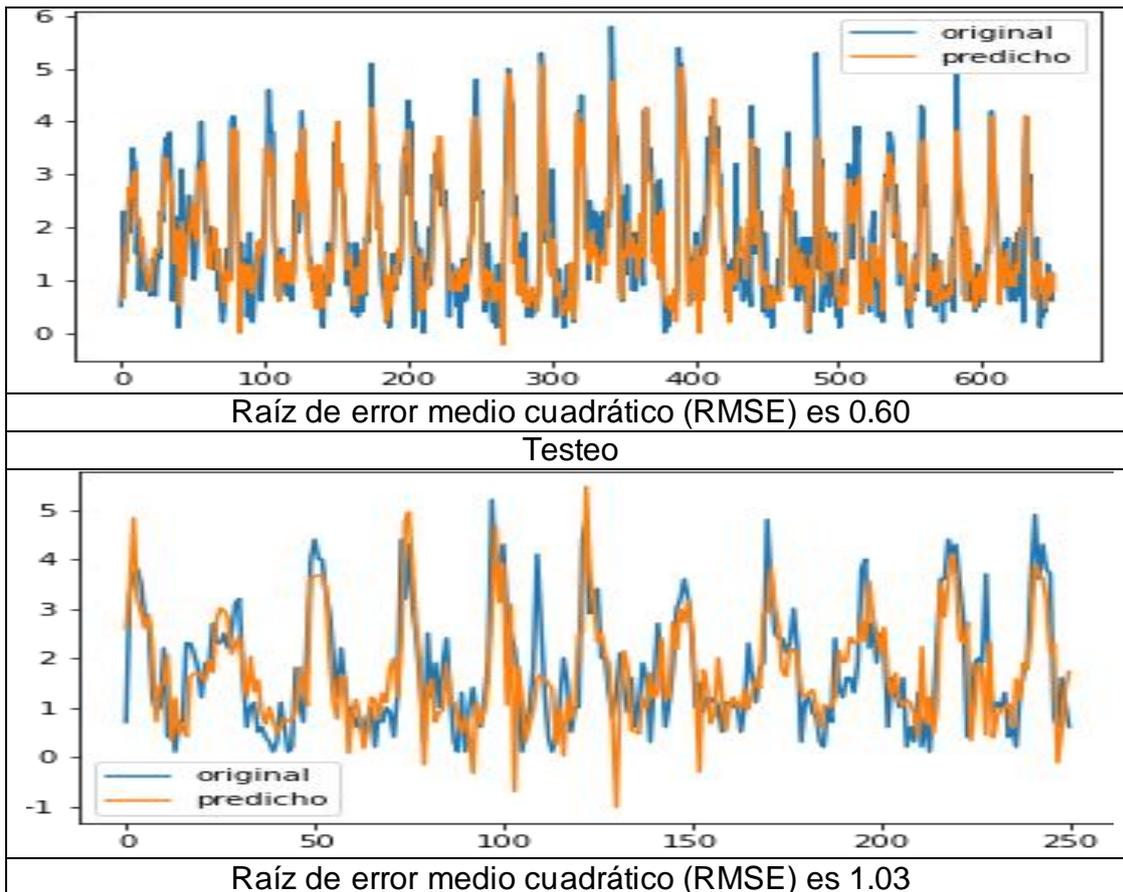


Figura 5. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 8 nodos en horizontes temporales a corto plazo.

En la figura 5 se observó la red neuronal artificial con 8 nodos, la data de entrenamiento presentó el valor de 0.60 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó el valor de 1.03 para la raíz de error medio cuadrático (RMSE).

Tabla 8. Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 16 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

Fecha	Hora	Data del SENAMHI	Data de testeo
20/11/2021	07:00:00	0.5	0.62
20/11/2021	08:00:00	0.3	0.63
20/11/2021	09:00:00	0.7	0.67
20/11/2021	10:00:00	0.8	1.62
20/11/2021	11:00:00	1.9	1.33

20/11/2021	12:00:00	4.1	2.44
20/11/2021	13:00:00	5.6	2.75
20/11/2021	14:00:00	3.9	2.57
20/11/2021	15:00:00	3.3	2.77
20/11/2021	16:00:00	3.9	3.04
20/11/2021	17:00:00	3.5	3.05
20/11/2021	18:00:00	2.9	2.27
20/11/2021	19:00:00	2.4	2.07
20/11/2021	20:00:00	1.6	2.15
20/11/2021	21:00:00	1.7	1.54
20/11/2021	22:00:00	1.8	1.79
20/11/2021	23:00:00	1.5	1.22
21/11/2021	00:00:00	0.7	1.25
21/11/2021	01:00:00	1.4	0.98
21/11/2021	02:00:00	0.8	1.09
21/11/2021	03:00:00	1.6	0.79
21/11/2021	04:00:00	0.8	1.00
21/11/2021	05:00:00	0.6	1.28
21/11/2021	06:00:00	1.9	1.38
21/11/2021	07:00:00	2.5	1.58
21/11/2021	08:00:00	2.3	1.52
21/11/2021	09:00:00	1.2	1.59
21/11/2021	10:00:00	2.3	1.74
21/11/2021	11:00:00	2	1.98
21/11/2021	12:00:00	3.1	2.67
21/11/2021	13:00:00	1.9	2.44
21/11/2021	14:00:00	3.2	3.31
21/11/2021	15:00:00	2.5	3.19
21/11/2021	16:00:00	2.3	2.99
21/11/2021	17:00:00	1.9	2.90
21/11/2021	18:00:00	1.7	2.79
21/11/2021	19:00:00	1.6	2.36
21/11/2021	20:00:00	1.5	1.32
21/11/2021	21:00:00	1	1.38
21/11/2021	22:00:00	1.8	1.94
21/11/2021	23:00:00	1.6	1.60
22/11/2021	00:00:00	1	0.53
22/11/2021	01:00:00	1.1	1.19
22/11/2021	02:00:00	1.3	2.11
22/11/2021	03:00:00	0.9	1.07
22/11/2021	04:00:00	0.6	1.56
22/11/2021	05:00:00	1.1	1.61
22/11/2021	06:00:00	0.9	1.89
22/11/2021	07:00:00	0.5	1.90
22/11/2021	08:00:00	1	2.10
22/11/2021	09:00:00	2.3	2.46
22/11/2021	10:00:00	1.5	2.02
22/11/2021	11:00:00	1.6	2.08

22/11/2021	12:00:00	2	1.76
22/11/2021	13:00:00	1.9	2.66
22/11/2021	14:00:00	2.8	3.08
22/11/2021	15:00:00	3.5	2.81
22/11/2021	16:00:00	3.3	2.98
22/11/2021	17:00:00	3.2	3.24
22/11/2021	18:00:00	1.5	2.70
22/11/2021	19:00:00	2	1.69
22/11/2021	20:00:00	0.8	1.22
22/11/2021	21:00:00	1.4	1.48
22/11/2021	22:00:00	1.8	1.60
22/11/2021	23:00:00	1.1	1.61
23/11/2021	00:00:00	0.8	1.99
23/11/2021	01:00:00	0.8	1.81
23/11/2021	02:00:00	1	1.20
23/11/2021	03:00:00	0.9	1.58
23/11/2021	04:00:00	0.7	1.31
23/11/2021	05:00:00	1.4	1.09
23/11/2021	06:00:00	1.1	0.60
23/11/2021	07:00:00	0.7	0.61
23/11/2021	08:00:00	1.2	0.58
23/11/2021	09:00:00	1.6	1.10
23/11/2021	10:00:00	1.4	1.19
23/11/2021	11:00:00	2.3	0.98
23/11/2021	12:00:00	2.1	2.64
23/11/2021	13:00:00	3.3	3.87
23/11/2021	14:00:00	3.6	3.29
23/11/2021	15:00:00	3.7	3.84
23/11/2021	16:00:00	3.2	2.79
23/11/2021	17:00:00	3.8	1.37
23/11/2021	18:00:00	2.9	-0.01
23/11/2021	19:00:00	0.6	0.97
23/11/2021	20:00:00	0.8	1.30
23/11/2021	21:00:00	2.2	1.30
23/11/2021	22:00:00	2	1.12
23/11/2021	23:00:00	0.1	0.85
24/11/2021	00:00:00	0.4	1.11
24/11/2021	01:00:00	3.1	1.27
24/11/2021	02:00:00	1.7	1.12
24/11/2021	03:00:00	1.4	0.75
24/11/2021	04:00:00	2	0.97
24/11/2021	05:00:00	2.1	0.95
24/11/2021	06:00:00	2.6	1.18
24/11/2021	07:00:00	2.6	1.72
24/11/2021	08:00:00	1.9	1.49

Red neuronal artificial con 16 nodos
Entrenamiento

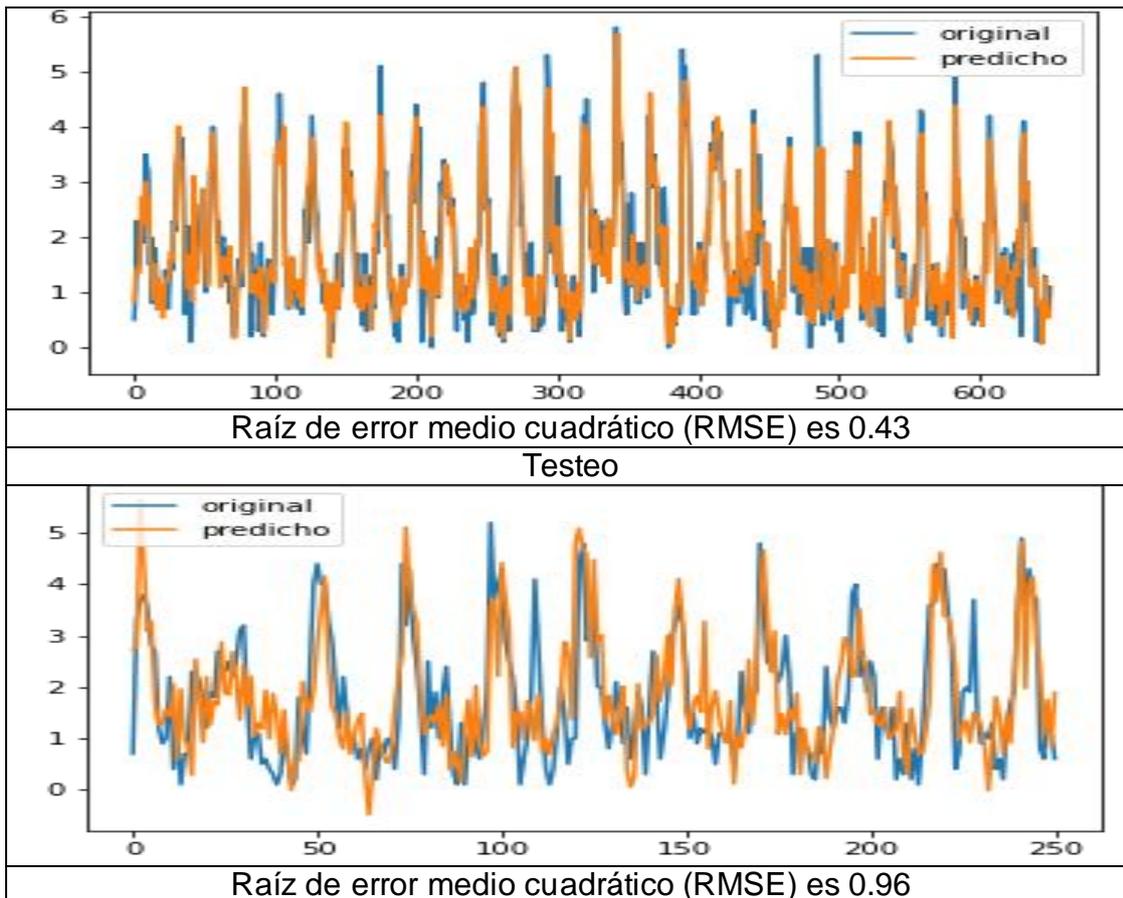


Figura 6. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 16 nodos en horizontes temporales a corto plazo.

En la figura 6 se observó la red neuronal artificial con 16 nodos, la data de entrenamiento presentó el valor de 0.43 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó el valor de 0.96 para la raíz de error medio cuadrático (RMSE).

Tabla 9. Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 32 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

Fecha	Hora	Data del SENAMHI	Data de testeo
20/11/2021	07:00:00	0.5	0.5
20/11/2021	08:00:00	0.3	1
20/11/2021	09:00:00	0.7	2.3
20/11/2021	10:00:00	0.8	1.5
20/11/2021	11:00:00	1.9	1.6
20/11/2021	12:00:00	4.1	2
20/11/2021	13:00:00	5.6	1.9
20/11/2021	14:00:00	3.9	2.8

20/11/2021	15:00:00	3.3	3.5
20/11/2021	16:00:00	3.9	3.3
20/11/2021	17:00:00	3.5	3.2
20/11/2021	18:00:00	2.9	1.5
20/11/2021	19:00:00	2.4	2
20/11/2021	20:00:00	1.6	0.8
20/11/2021	21:00:00	1.7	1.4
20/11/2021	22:00:00	1.8	1.8
20/11/2021	23:00:00	1.5	1.1
21/11/2021	00:00:00	0.7	0.8
21/11/2021	01:00:00	1.4	0.8
21/11/2021	02:00:00	0.8	1
21/11/2021	03:00:00	1.6	0.9
21/11/2021	04:00:00	0.8	0.7
21/11/2021	05:00:00	0.6	1.4
21/11/2021	06:00:00	1.9	1.1
21/11/2021	07:00:00	2.5	0.7
21/11/2021	08:00:00	2.3	1.2
21/11/2021	09:00:00	1.2	1.6
21/11/2021	10:00:00	2.3	1.4
21/11/2021	11:00:00	2	2.3
21/11/2021	12:00:00	3.1	2.1
21/11/2021	13:00:00	1.9	3.3
21/11/2021	14:00:00	3.2	3.6
21/11/2021	15:00:00	2.5	3.7
21/11/2021	16:00:00	2.3	3.2
21/11/2021	17:00:00	1.9	3.8
21/11/2021	18:00:00	1.7	2.9
21/11/2021	19:00:00	1.6	0.6
21/11/2021	20:00:00	1.5	0.8
21/11/2021	21:00:00	1	2.2
21/11/2021	22:00:00	1.8	2
21/11/2021	23:00:00	1.6	0.1
22/11/2021	00:00:00	1	0.4
22/11/2021	01:00:00	1.1	3.1
22/11/2021	02:00:00	1.3	1.7
22/11/2021	03:00:00	0.9	1.4
22/11/2021	04:00:00	0.6	2
22/11/2021	05:00:00	1.1	2.1
22/11/2021	06:00:00	0.9	2.6
22/11/2021	07:00:00	0.5	2.6
22/11/2021	08:00:00	1	1.9
22/11/2021	09:00:00	2.3	1.3
22/11/2021	10:00:00	1.5	1
22/11/2021	11:00:00	1.6	1.2
22/11/2021	12:00:00	2	1.8
22/11/2021	13:00:00	1.9	3.2
22/11/2021	14:00:00	2.8	3.3

22/11/2021	15:00:00	3.5	4
22/11/2021	16:00:00	3.3	3.3
22/11/2021	17:00:00	3.2	2.4
22/11/2021	18:00:00	1.5	1.9
22/11/2021	19:00:00	2	2.3
22/11/2021	20:00:00	0.8	1.4
22/11/2021	21:00:00	1.4	1.8
22/11/2021	22:00:00	1.8	2
22/11/2021	23:00:00	1.1	1.2
23/11/2021	00:00:00	0.8	1.2
23/11/2021	01:00:00	0.8	1.8
23/11/2021	02:00:00	1	1.3
23/11/2021	03:00:00	0.9	0.8
23/11/2021	04:00:00	0.7	1.1
23/11/2021	05:00:00	1.4	0.4
23/11/2021	06:00:00	1.1	0.2
23/11/2021	07:00:00	0.7	0.4
23/11/2021	08:00:00	1.2	1.1
23/11/2021	09:00:00	1.6	1.6
23/11/2021	10:00:00	1.4	1.4
23/11/2021	11:00:00	2.3	1.1
23/11/2021	12:00:00	2.1	4
23/11/2021	13:00:00	3.3	4.1
23/11/2021	14:00:00	3.6	4.1
23/11/2021	15:00:00	3.7	3.1
23/11/2021	16:00:00	3.2	2.3
23/11/2021	17:00:00	3.8	1.4
23/11/2021	18:00:00	2.9	0.2
23/11/2021	19:00:00	0.6	1.7
23/11/2021	20:00:00	0.8	0.9
23/11/2021	21:00:00	2.2	1.4
23/11/2021	22:00:00	2	1.1
23/11/2021	23:00:00	0.1	0.3
24/11/2021	00:00:00	0.4	0.6
24/11/2021	01:00:00	3.1	1.9
24/11/2021	02:00:00	1.7	0.5
24/11/2021	03:00:00	1.4	0.2
24/11/2021	04:00:00	2	0.6
24/11/2021	05:00:00	2.1	1.2
24/11/2021	06:00:00	2.6	1.6
24/11/2021	07:00:00	2.6	1.4
24/11/2021	08:00:00	1.9	1.4

Red neuronal artificial con 32 nodos
Entrenamiento

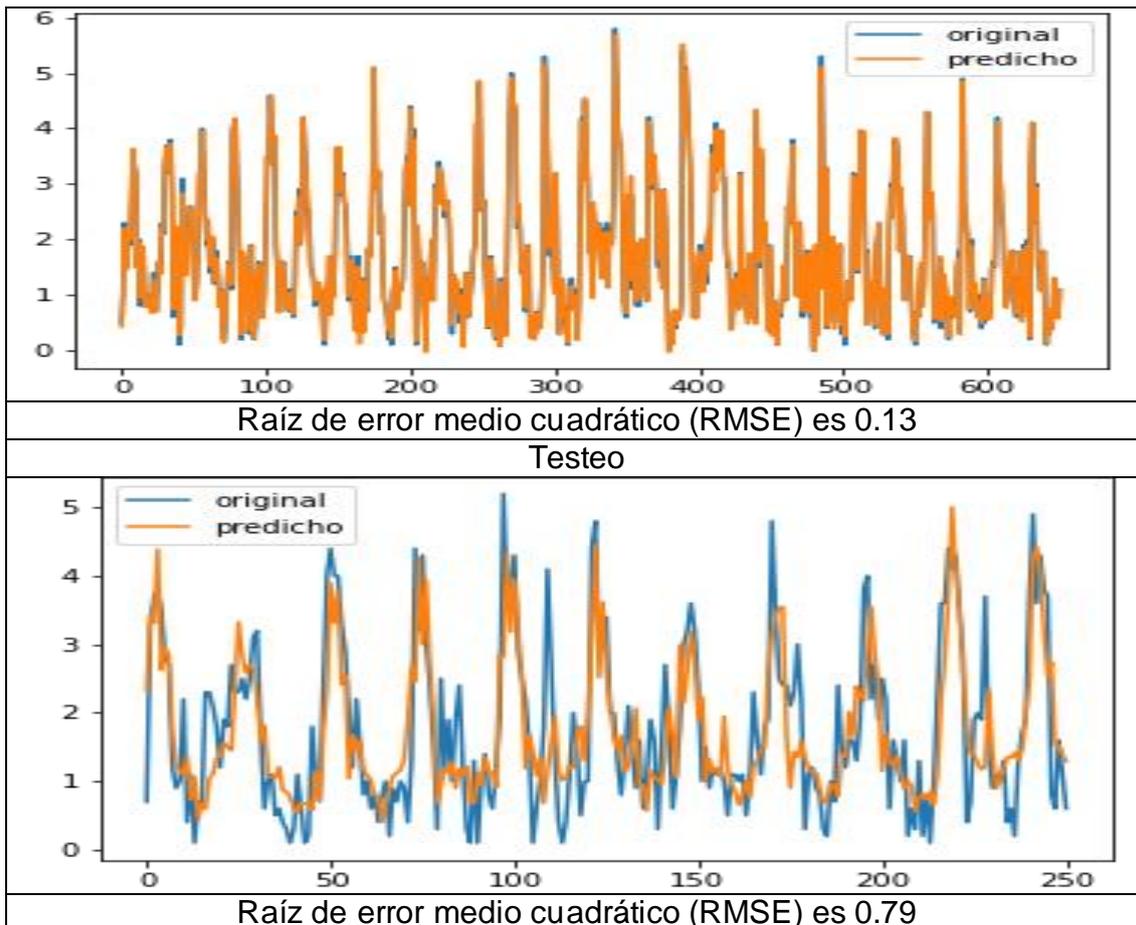


Figura 7. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 32 nodos en horizontes temporales corto plazo.

En la figura 7 se observó la red neuronal artificial con 32 nodos, la data de entrenamiento presentó el valor de 0.13 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó un valor de 0.79 para la raíz de error medio cuadrático (RMSE).

Tabla 10. Cotejo de la velocidad del viento en el horizonte temporal a corto plazo en la estación Matapalo usando 64 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

FECHA	HORA	Data del SENAMHI	DATA DE TESTEO
20/11/2021	07:00:00	0.5	0.79
20/11/2021	08:00:00	0.3	0.92
20/11/2021	09:00:00	0.7	1.10
20/11/2021	10:00:00	0.8	1.80
20/11/2021	11:00:00	1.9	1.71
20/11/2021	12:00:00	4.1	2.23
20/11/2021	13:00:00	5.6	2.77

20/11/2021	14:00:00	3.9	2.48
20/11/2021	15:00:00	3.3	2.53
20/11/2021	16:00:00	3.9	2.83
20/11/2021	17:00:00	3.5	3.60
20/11/2021	18:00:00	2.9	1.93
20/11/2021	19:00:00	2.4	1.43
20/11/2021	20:00:00	1.6	1.30
20/11/2021	21:00:00	1.7	1.09
20/11/2021	22:00:00	1.8	1.29
20/11/2021	23:00:00	1.5	0.76
21/11/2021	00:00:00	0.7	0.92
21/11/2021	01:00:00	1.4	0.85
21/11/2021	02:00:00	0.8	0.98
21/11/2021	03:00:00	1.6	0.68
21/11/2021	04:00:00	0.8	0.64
21/11/2021	05:00:00	0.6	0.96
21/11/2021	06:00:00	1.9	1.21
21/11/2021	07:00:00	2.5	1.15
21/11/2021	08:00:00	2.3	1.24
21/11/2021	09:00:00	1.2	1.51
21/11/2021	10:00:00	2.3	1.70
21/11/2021	11:00:00	2	1.89
21/11/2021	12:00:00	3.1	2.44
21/11/2021	13:00:00	1.9	2.44
21/11/2021	14:00:00	3.2	3.22
21/11/2021	15:00:00	2.5	2.93
21/11/2021	16:00:00	2.3	3.24
21/11/2021	17:00:00	1.9	2.47
21/11/2021	18:00:00	1.7	3.17
21/11/2021	19:00:00	1.6	1.76
21/11/2021	20:00:00	1.5	0.55
21/11/2021	21:00:00	1	1.29
21/11/2021	22:00:00	1.8	1.48
21/11/2021	23:00:00	1.6	1.11
22/11/2021	00:00:00	1	0.67
22/11/2021	01:00:00	1.1	1.11
22/11/2021	02:00:00	1.3	1.86
22/11/2021	03:00:00	0.9	1.50
22/11/2021	04:00:00	0.6	1.66
22/11/2021	05:00:00	1.1	1.84
22/11/2021	06:00:00	0.9	1.62
22/11/2021	07:00:00	0.5	2.87
22/11/2021	08:00:00	1	1.77
22/11/2021	09:00:00	2.3	2.10
22/11/2021	10:00:00	1.5	1.54
22/11/2021	11:00:00	1.6	1.28
22/11/2021	12:00:00	2	1.59
22/11/2021	13:00:00	1.9	2.67

22/11/2021	14:00:00	2.8	3.63
22/11/2021	15:00:00	3.5	3.04
22/11/2021	16:00:00	3.3	3.60
22/11/2021	17:00:00	3.2	2.86
22/11/2021	18:00:00	1.5	2.50
22/11/2021	19:00:00	2	1.41
22/11/2021	20:00:00	0.8	1.19
22/11/2021	21:00:00	1.4	1.24
22/11/2021	22:00:00	1.8	1.34
22/11/2021	23:00:00	1.1	1.18
23/11/2021	00:00:00	0.8	1.32
23/11/2021	01:00:00	0.8	1.38
23/11/2021	02:00:00	1	1.19
23/11/2021	03:00:00	0.9	1.29
23/11/2021	04:00:00	0.7	1.27
23/11/2021	05:00:00	1.4	1.04
23/11/2021	06:00:00	1.1	0.78
23/11/2021	07:00:00	0.7	0.75
23/11/2021	08:00:00	1.2	0.88
23/11/2021	09:00:00	1.6	0.81
23/11/2021	10:00:00	1.4	1.35
23/11/2021	11:00:00	2.3	1.71
23/11/2021	12:00:00	2.1	1.94
23/11/2021	13:00:00	3.3	3.56
23/11/2021	14:00:00	3.6	3.70
23/11/2021	15:00:00	3.7	4.20
23/11/2021	16:00:00	3.2	2.98
23/11/2021	17:00:00	3.8	1.67
23/11/2021	18:00:00	2.9	0.91
23/11/2021	19:00:00	0.6	0.96
23/11/2021	20:00:00	0.8	1.43
23/11/2021	21:00:00	2.2	1.48
23/11/2021	22:00:00	2	1.25
23/11/2021	23:00:00	0.1	0.77
24/11/2021	00:00:00	0.4	1.09
24/11/2021	01:00:00	3.1	1.25
24/11/2021	02:00:00	1.7	0.94
24/11/2021	03:00:00	1.4	0.60
24/11/2021	04:00:00	2	0.59
24/11/2021	05:00:00	2.1	0.96
24/11/2021	06:00:00	2.6	1.58
24/11/2021	07:00:00	2.6	1.06
24/11/2021	08:00:00	1.9	1.23

Función lineal 64 capas
Entrenamiento

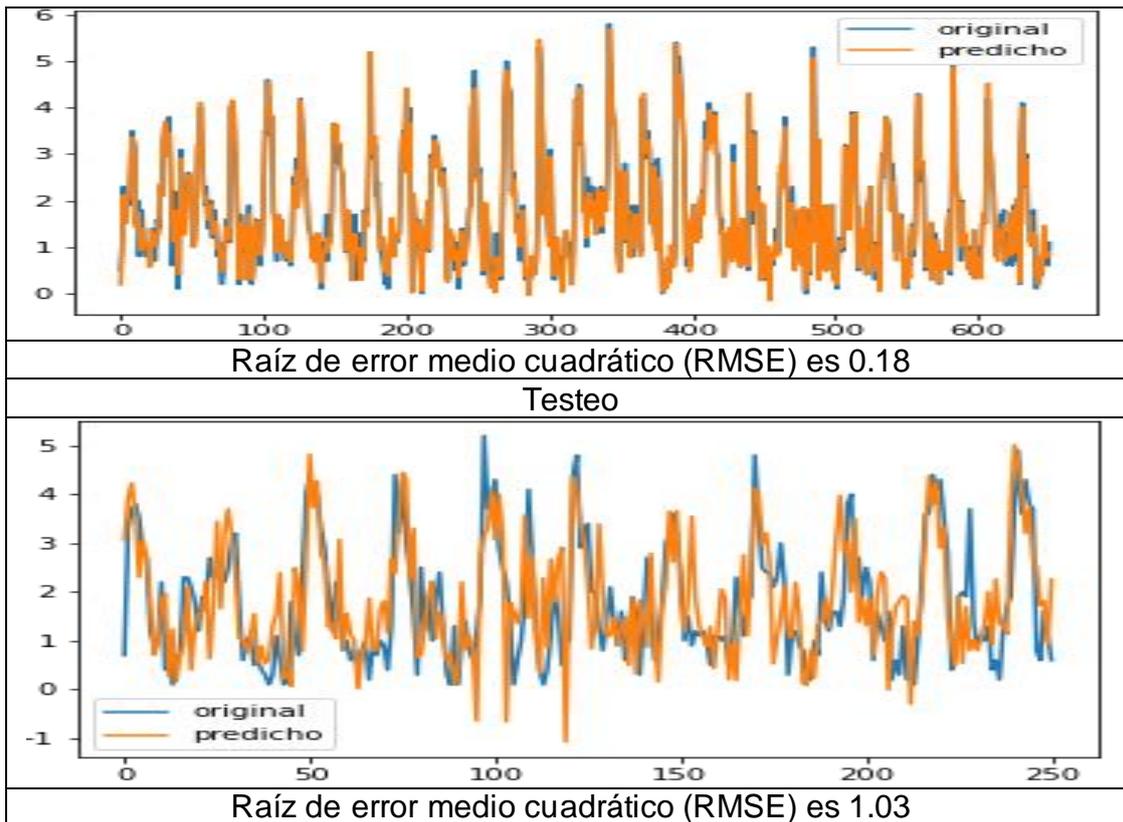


Figura 8. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 64 nodos en horizontes temporales corto plazo.

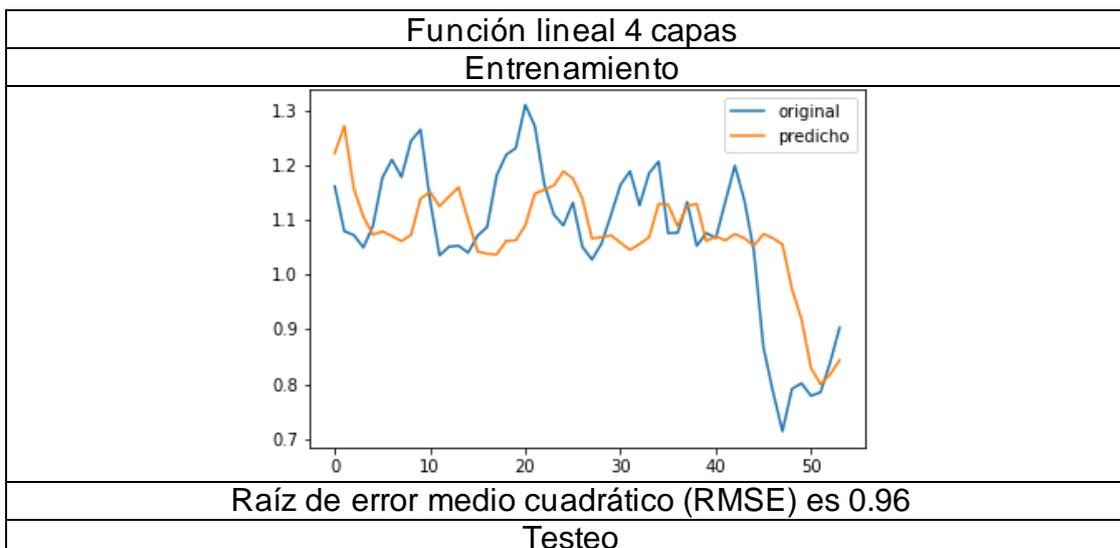
En la figura 8 se observó la red neuronal artificial con 64 nodos, la data de entrenamiento presentó el valor de 0.18 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó un valor de 1.03 para la raíz de error medio cuadrático (RMSE).

Tabla 11. Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 4 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

<b>Año</b>	<b>MES</b>	<b>Data del SENAMHI</b>	<b>Data de testeo</b>
2014	Octubre	1.33	1.03
2014	Noviembre	1.35	1.15
2014	Diciembre	1.41	1.16
2015	Enero	1.26	1.00
2015	Febrero	1.08	1.09
2015	Marzo	1.16	1.08
2015	Abril	1.08	1.15
2015	Mayo	1.07	1.21
2015	Junio	1.05	1.18
2015	Julio	1.09	1.20

2015	Agosto	1.18	1.27
2015	Setiembre	1.21	1.13
2015	Octubre	1.18	1.02
2015	Noviembre	1.25	1.08
2015	Diciembre	1.27	1.09
2016	Enero	1.14	1.04
2016	Febrero	1.04	1.08
2016	Marzo	1.05	1.11
2016	Abril	1.05	1.15
2016	Mayo	1.04	1.21
2016	Junio	1.07	1.22
2016	Julio	1.09	1.25
2016	Agosto	1.18	1.30
2016	Setiembre	1.22	1.14
2016	Octubre	1.23	1.12
2016	Noviembre	1.31	1.12
2016	Diciembre	1.27	1.14
2017	Enero	1.17	1.08
2017	Febrero	1.11	1.00
2017	Marzo	1.09	1.08
2017	Abril	1.13	1.12
2017	Mayo	1.05	1.16
2017	Junio	1.03	1.18
2017	Julio	1.06	1.14
2017	Agosto	1.11	1.16
2017	Setiembre	1.16	1.22
2017	Octubre	1.19	1.07
2017	Noviembre	1.13	1.05
2017	Diciembre	1.19	1.14
2018	Enero	1.21	1.07
2018	Febrero	1.08	1.05
2018	Marzo	1.08	1.11
2018	Abril	1.13	1.12
2018	Mayo	1.05	1.18
2018	Junio	1.08	1.15
2018	Julio	1.07	1.03
2018	Agosto	1.13	0.90
2018	Setiembre	1.20	0.79
2018	Octubre	1.14	0.77
2018	Noviembre	1.04	0.80
2018	Diciembre	0.87	0.87
2019	Enero	0.79	0.78
2019	Febrero	0.71	0.81
2019	Marzo	0.79	0.85
2019	Abril	0.80	0.80
2019	Mayo	0.78	0.87
2019	Junio	0.79	0.78
2019	Julio	0.84	0.81

2019	Agosto	0.90	0.85
2019	Setiembre	0.96	0.90
2019	Octubre	0.93	0.96
2019	Noviembre	0.85	0.93
2019	Diciembre	0.93	0.85
2020	Enero	0.96	0.90
2020	Febrero	0.90	0.85
2020	Marzo	0.83	0.75
2020	Abril	0.70	0.75
2020	Mayo	0.74	0.86
2020	Junio	0.83	0.84
2020	Julio	0.81	0.87
2020	Agosto	0.93	0.96
2020	Setiembre	0.97	0.96
2020	Octubre	0.97	0.98
2020	Noviembre	1.00	0.96
2020	Diciembre	0.91	0.87
2021	Enero	0.88	0.90
2021	Febrero	0.84	0.84
2021	Marzo	0.82	0.84
2021	Abril	0.80	0.76
2021	Mayo	0.72	0.77
2021	Junio	0.75	0.86
2021	Julio	0.86	0.88
2021	Agosto	0.84	0.89
2021	Setiembre	0.93	0.93
2021	Octubre	0.87	0.88
2021	Noviembre	0.90	0.89
2021	Diciembre	0.90	0.93



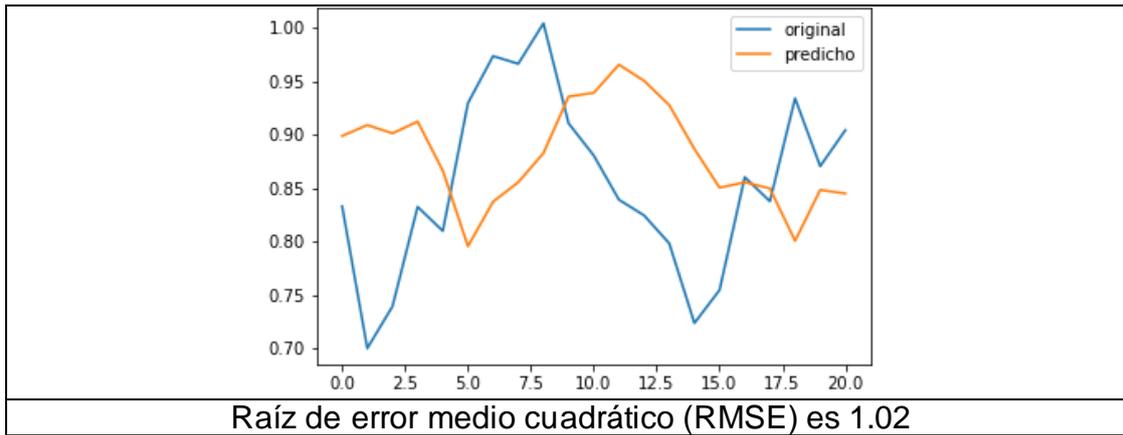


Figura 9. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 4 nodos en horizontes temporales a mediano plazo

En la figura 9 se observó la red neuronal artificial con 4 nodos, la data de entrenamiento presentó el valor de 0.96 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó un valor de 1.02 para la raíz de error medio cuadrático (RMSE).

Tabla 12 Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 8 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

<b>Año</b>	<b>Mes</b>	<b>Data del SENAMHI</b>	<b>Data de testeo</b>
2014	Octubre	1.33	1.13
2014	Noviembre	1.35	1.13
2014	Diciembre	1.41	1.27
2015	Enero	1.26	0.98
2015	Febrero	1.08	1.11
2015	Marzo	1.16	1.04
2015	Abril	1.08	1.10
2015	Mayo	1.07	1.14
2015	Junio	1.05	1.12
2015	Julio	1.09	1.12
2015	Agosto	1.18	1.24
2015	Setiembre	1.21	1.17
2015	Octubre	1.18	1.06
2015	Noviembre	1.25	1.09
2015	Diciembre	1.27	1.11
2016	Enero	1.14	1.03
2016	Febrero	1.04	1.03
2016	Marzo	1.05	1.08
2016	Abril	1.05	1.06
2016	Mayo	1.04	1.16

2016	Junio	1.07	1.12
2016	Julio	1.09	1.17
2016	Agosto	1.18	1.26
2016	Setiembre	1.22	1.15
2016	Octubre	1.23	1.13
2016	Noviembre	1.31	1.15
2016	Diciembre	1.27	1.11
2017	Enero	1.17	1.13
2017	Febrero	1.11	0.99
2017	Marzo	1.09	1.07
2017	Abril	1.13	1.07
2017	Mayo	1.05	1.08
2017	Junio	1.03	1.11
2017	Julio	1.06	1.12
2017	Agosto	1.11	1.07
2017	Setiembre	1.16	1.21
2017	Octubre	1.19	1.13
2017	Noviembre	1.13	1.02
2017	Diciembre	1.19	1.15
2018	Enero	1.21	1.12
2018	Febrero	1.08	0.99
2018	Marzo	1.08	1.12
2018	Abril	1.13	1.04
2018	Mayo	1.05	1.13
2018	Junio	1.08	1.13
2018	Julio	1.07	1.05
2018	Agosto	1.13	1.05
2018	Setiembre	1.20	0.91
2018	Octubre	1.14	0.93
2018	Noviembre	1.04	0.81
2018	Diciembre	0.87	0.90
2019	Enero	0.79	0.79
2019	Febrero	0.71	0.81
2019	Marzo	0.79	0.85
2019	Abril	0.80	0.79
2019	Mayo	0.78	0.84
2019	Junio	0.79	0.90
2019	Julio	0.84	0.96
2019	Agosto	0.90	0.93
2019	Setiembre	0.96	0.85
2019	Octubre	0.93	0.93
2019	Noviembre	0.85	0.96
2019	Diciembre	0.93	0.90
2020	Enero	0.96	0.93
2020	Febrero	0.90	0.96
2020	Marzo	0.83	0.85
2020	Abril	0.70	0.92
2020	Mayo	0.74	0.88

2020	Junio	0.83	0.89
2020	Julio	0.81	0.78
2020	Agosto	0.93	0.89
2020	Setiembre	0.97	0.86
2020	Octubre	0.97	0.79
2020	Noviembre	1.00	0.93
2020	Diciembre	0.91	0.91
2021	Enero	0.88	0.94
2021	Febrero	0.84	1.02
2021	Marzo	0.82	0.88
2021	Abril	0.80	0.96
2021	Mayo	0.72	0.88
2021	Junio	0.75	0.88
2021	Julio	0.86	0.84
2021	Agosto	0.84	0.78
2021	Setiembre	0.93	0.87
2021	Octubre	0.87	0.89
2021	Noviembre	0.90	0.80
2021	Diciembre	0.90	0.94

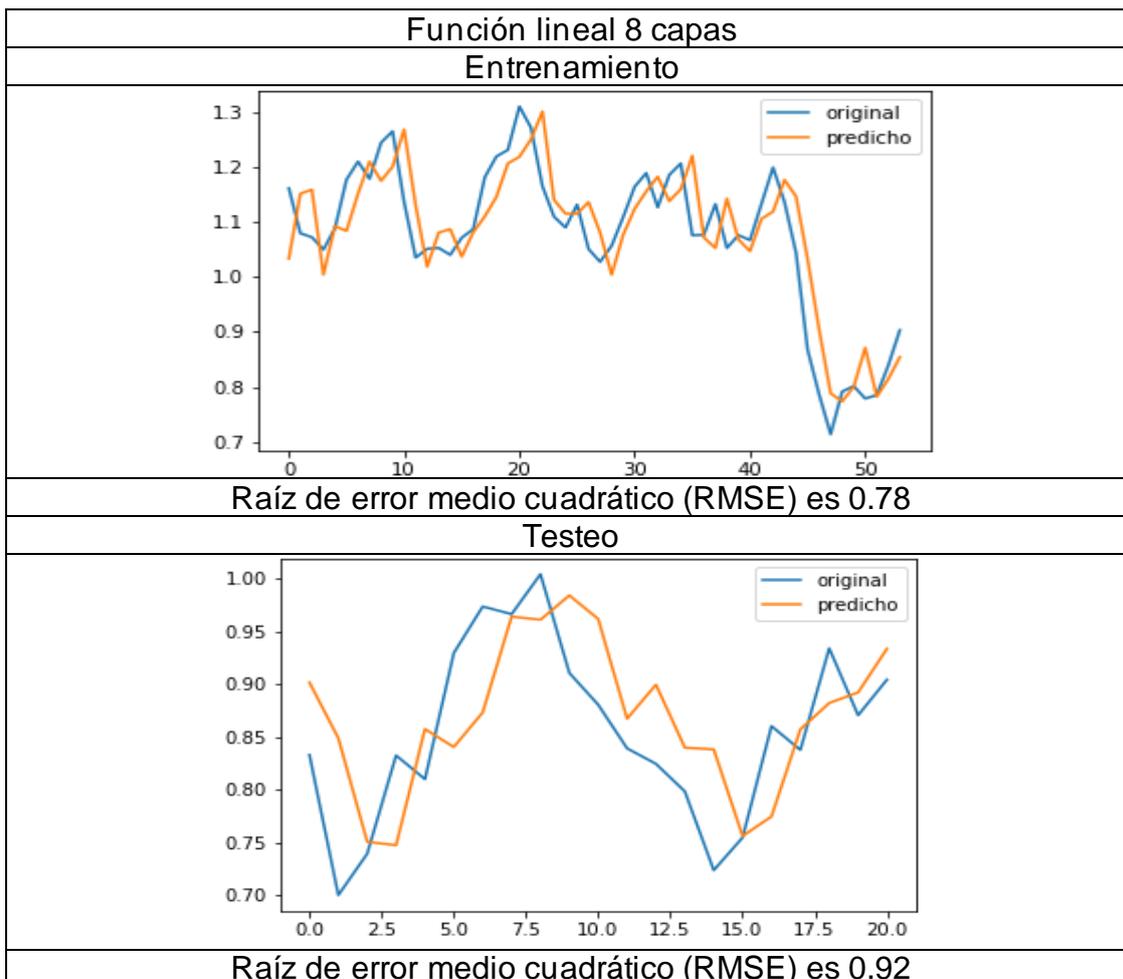


Figura 10. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 8 nodos en horizontes temporales a mediano plazo.

En la figura 10 se observó la red neuronal artificial con 8 nodos, la data de entrenamiento presentó el valor de 0.78 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó un valor de 0.92 para la raíz de error medio cuadrático (RMSE).

Tabla 13. Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 16 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

<b>Año</b>	<b>Meses</b>	<b>Data del SENAMHI</b>	<b>Data de testeo</b>
2014	Octubre	1.33	1.21
2014	Noviembre	1.35	1.06
2014	Diciembre	1.41	1.10
2015	Enero	1.26	1.06
2015	Febrero	1.08	1.07
2015	Marzo	1.16	1.04
2015	Abril	1.08	1.08
2015	Mayo	1.07	1.14
2015	Junio	1.05	1.18
2015	Julio	1.09	1.16
2015	Agosto	1.18	1.19
2015	Setiembre	1.21	1.21
2015	Octubre	1.18	1.13
2015	Noviembre	1.25	1.04
2015	Diciembre	1.27	1.03
2016	Enero	1.14	1.04
2016	Febrero	1.04	1.05
2016	Marzo	1.05	1.06
2016	Abril	1.05	1.08
2016	Mayo	1.04	1.15
2016	Junio	1.07	1.18
2016	Julio	1.09	1.20
2016	Agosto	1.18	1.24
2016	Setiembre	1.22	1.22
2016	Octubre	1.23	1.15
2016	Noviembre	1.31	1.08
2016	Diciembre	1.27	1.06
2017	Enero	1.17	1.10
2017	Febrero	1.11	1.05
2017	Marzo	1.09	1.04
2017	Abril	1.13	1.04

2017	Mayo	1.05	1.09
2017	Junio	1.03	1.14
2017	Julio	1.06	1.16
2017	Agosto	1.11	1.12
2017	Setiembre	1.16	1.15
2017	Octubre	1.19	1.16
2017	Noviembre	1.13	1.08
2017	Diciembre	1.19	1.06
2018	Enero	1.21	1.09
2018	Febrero	1.08	1.06
2018	Marzo	1.08	1.07
2018	Abril	1.13	1.05
2018	Mayo	1.05	1.11
2018	Junio	1.08	1.16
2018	Julio	1.07	1.13
2018	Agosto	1.13	1.05
2018	Setiembre	1.20	0.91
2018	Octubre	1.14	0.84
2018	Noviembre	1.04	0.78
2018	Diciembre	0.87	0.85
2019	Enero	0.79	0.87
2019	Febrero	0.71	0.86
2019	Marzo	0.79	0.86
2019	Abril	0.80	0.79
2019	Mayo	0.78	0.84
2019	Junio	0.79	0.90
2019	Julio	0.84	0.96
2019	Agosto	0.90	0.93
2019	Setiembre	0.96	0.85
2019	Octubre	0.93	0.93
2019	Noviembre	0.85	0.96
2019	Diciembre	0.93	0.90
2020	Enero	0.96	0.83
2020	Febrero	0.90	0.93
2020	Marzo	0.83	0.96
2020	Abril	0.70	0.98
2020	Mayo	0.74	0.96
2020	Junio	0.83	0.90
2020	Julio	0.81	0.79
2020	Agosto	0.93	0.81
2020	Setiembre	0.97	0.88
2020	Octubre	0.97	0.86
2020	Noviembre	1.00	0.93
2020	Diciembre	0.91	0.99
2021	Enero	0.88	1.00
2021	Febrero	0.84	1.02
2021	Marzo	0.82	0.95
2021	Abril	0.80	0.93

2021	Mayo	0.72	0.89
2021	Junio	0.75	0.88
2021	Julio	0.86	0.86
2021	Agosto	0.84	0.81
2021	Setiembre	0.93	0.83
2021	Octubre	0.87	0.90
2021	Noviembre	0.90	0.89
2021	Diciembre	0.90	0.98

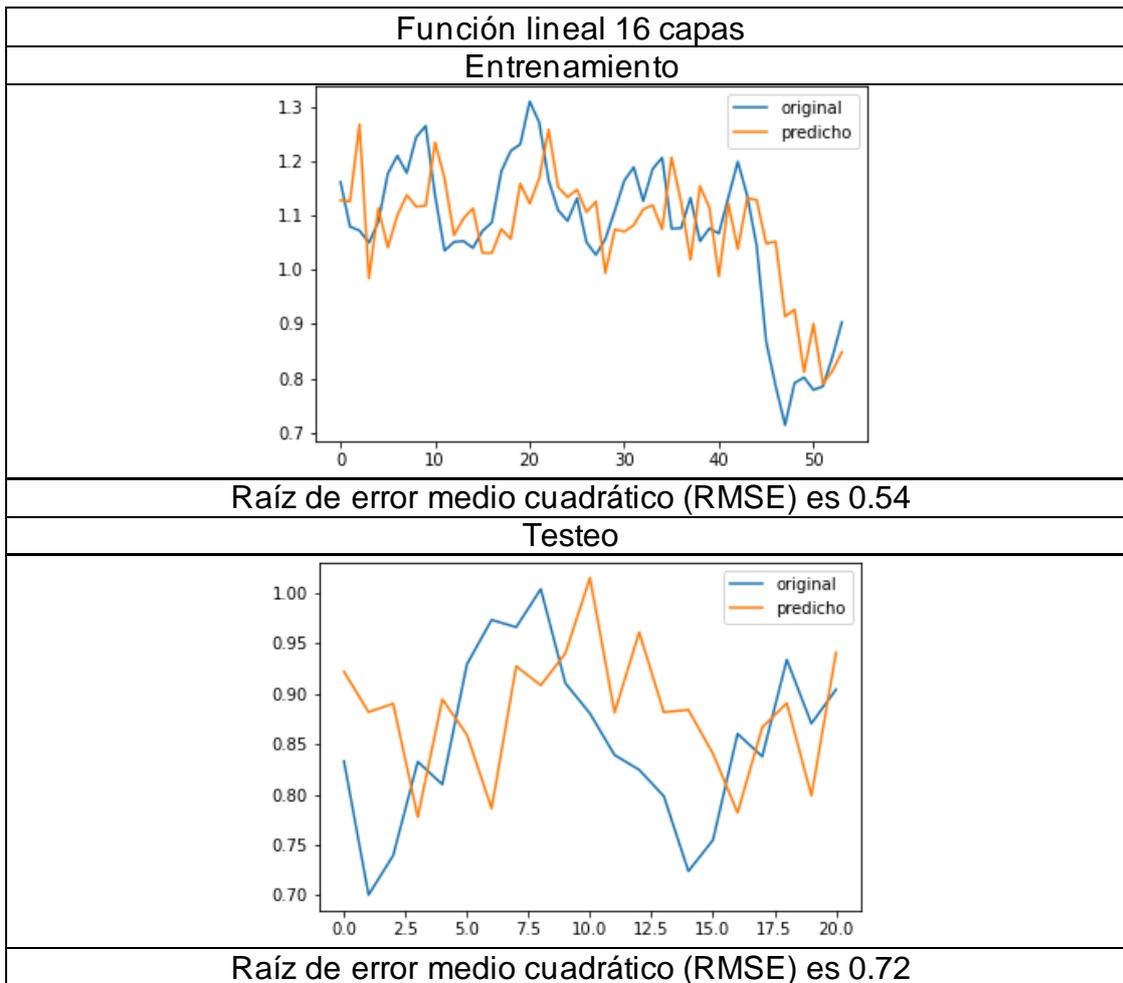


Figura 11. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 16 nodos en horizontes temporales a mediano plazo.

En la figura 11 se observó la red neuronal artificial con 16 nodos, la data de entrenamiento presentó el valor de 0.754 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó un valor de 0.72 para la raíz de error medio cuadrático (RMSE).

Tabla 14. Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 32 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal)

<b>Año</b>	<b>Meses</b>	<b>Data del SENAMHI</b>	<b>Data de testeo</b>
2014	Octubre	1.33	1.12
2014	Noviembre	1.35	1.10
2014	Diciembre	1.41	1.01
2015	Enero	1.26	1.03
2015	Febrero	1.08	1.07
2015	Marzo	1.16	1.05
2015	Abril	1.08	1.14
2015	Mayo	1.07	1.18
2015	Junio	1.05	1.10
2015	Julio	1.09	1.23
2015	Agosto	1.18	1.23
2015	Setiembre	1.21	1.15
2015	Octubre	1.18	1.08
2015	Noviembre	1.25	1.03
2015	Diciembre	1.27	1.00
2016	Enero	1.14	1.02
2016	Febrero	1.04	1.07
2016	Marzo	1.05	1.08
2016	Abril	1.05	1.15
2016	Mayo	1.04	1.20
2016	Junio	1.07	1.23
2016	Julio	1.09	1.29
2016	Agosto	1.18	1.26
2016	Setiembre	1.22	1.19
2016	Octubre	1.23	1.13
2016	Noviembre	1.31	1.05
2016	Diciembre	1.27	1.07
2017	Enero	1.17	1.05
2017	Febrero	1.11	1.04
2017	Marzo	1.09	1.05
2017	Abril	1.13	1.06
2017	Mayo	1.05	1.14
2017	Junio	1.03	1.19
2017	Julio	1.06	1.16
2017	Agosto	1.11	1.17
2017	Setiembre	1.16	1.17
2017	Octubre	1.19	1.10
2017	Noviembre	1.13	1.10
2017	Diciembre	1.19	1.09
2018	Enero	1.21	1.03
2018	Febrero	1.08	1.08
2018	Marzo	1.08	1.07
2018	Abril	1.13	1.09

2018	Mayo	1.05	1.17
2018	Junio	1.08	1.15
2018	Julio	1.07	1.10
2018	Agosto	1.13	0.95
2018	Setiembre	1.20	0.82
2018	Octubre	1.14	0.73
2018	Noviembre	1.04	0.76
2018	Diciembre	0.87	0.82
2019	Enero	0.79	0.85
2019	Febrero	0.71	0.88
2019	Marzo	0.79	0.88
2019	Abril	0.80	0.79
2019	Mayo	0.78	0.71
2019	Junio	0.79	0.79
2019	Julio	0.84	0.80
2019	Agosto	0.90	0.78
2019	Setiembre	0.96	0.79
2019	Octubre	0.93	0.90
2019	Noviembre	0.85	0.96
2019	Diciembre	0.93	0.93
2020	Enero	0.96	0.85
2020	Febrero	0.90	0.96
2020	Marzo	0.83	0.90
2020	Abril	0.70	0.95
2020	Mayo	0.74	0.93
2020	Junio	0.83	0.80
2020	Julio	0.81	0.77
2020	Agosto	0.93	0.82
2020	Setiembre	0.97	0.85
2020	Octubre	0.97	0.97
2020	Noviembre	1.00	1.00
2020	Diciembre	0.91	1.01
2021	Enero	0.88	1.06
2021	Febrero	0.84	0.98
2021	Marzo	0.82	0.93
2021	Abril	0.80	0.89
2021	Mayo	0.72	0.85
2021	Junio	0.75	0.85
2021	Julio	0.86	0.80
2021	Agosto	0.84	0.81
2021	Setiembre	0.93	0.87
2021	Octubre	0.87	0.88
2021	Noviembre	0.90	0.98
2021	Diciembre	0.90	0.96

Función lineal 32 capas
Entrenamiento

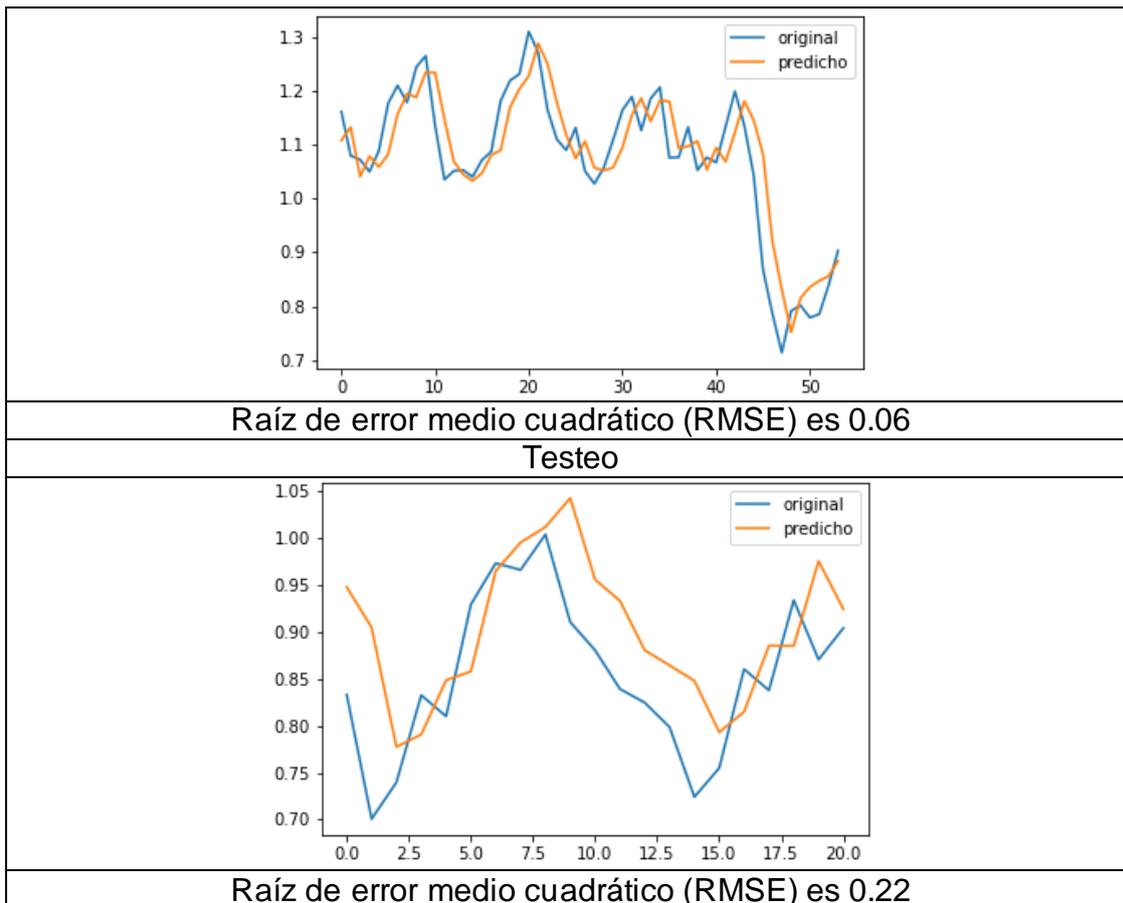


Figura 12. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 32 nodos en horizontes temporales a mediano plazo

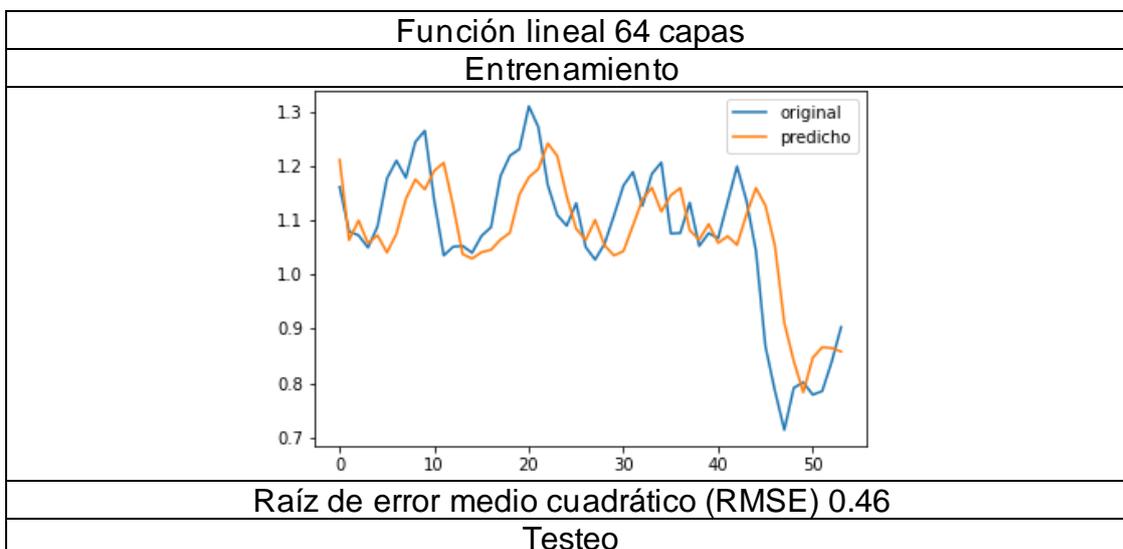
En la figura 12 se observó la red neuronal artificial con 32 nodos, la data de entrenamiento presentó el valor de 0.06 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó un valor de 0.22 para la raíz de error medio cuadrático (RMSE).

Tabla 15. Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 64 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

<b>Año</b>	<b>Meses</b>	<b>Data del SENAMHI</b>	<b>Data de testeo</b>
2014	Octubre	1.33	1.11
2014	Noviembre	1.35	1.13
2014	Diciembre	1.41	1.04
2015	Enero	1.26	1.08
2015	Febrero	1.08	1.06
2015	Marzo	1.16	1.08
2015	Abril	1.08	1.16

2015	Mayo	1.07	1.20
2015	Junio	1.05	1.19
2015	Julio	1.09	1.23
2015	Agosto	1.18	1.23
2015	Setiembre	1.21	1.15
2015	Octubre	1.18	1.07
2015	Noviembre	1.25	1.04
2015	Diciembre	1.27	1.03
2016	Enero	1.14	1.05
2016	Febrero	1.04	1.08
2016	Marzo	1.05	1.09
2016	Abril	1.05	1.17
2016	Mayo	1.04	1.20
2016	Junio	1.07	1.23
2016	Julio	1.09	1.29
2016	Agosto	1.18	1.25
2016	Setiembre	1.22	1.18
2016	Octubre	1.23	1.12
2016	Noviembre	1.31	1.07
2016	Diciembre	1.27	1.11
2017	Enero	1.17	1.06
2017	Febrero	1.11	1.05
2017	Marzo	1.09	1.06
2017	Abril	1.13	1.10
2017	Mayo	1.05	1.16
2017	Junio	1.03	1.19
2017	Julio	1.06	1.14
2017	Agosto	1.11	1.18
2017	Setiembre	1.16	1.18
2017	Octubre	1.19	1.09
2017	Noviembre	1.13	1.10
2017	Diciembre	1.19	1.11
2018	Enero	1.21	1.05
2018	Febrero	1.08	1.09
2018	Marzo	1.08	1.07
2018	Abril	1.13	1.12
2018	Mayo	1.05	1.18
2018	Junio	1.08	1.15
2018	Julio	1.07	1.08
2018	Agosto	1.13	0.92
2018	Setiembre	1.20	0.83
2018	Octubre	1.14	0.75
2018	Noviembre	1.04	0.81
2018	Diciembre	0.87	0.84
2019	Enero	0.79	0.85
2019	Febrero	0.71	0.86
2019	Marzo	0.79	0.88
2019	Abril	0.80	0.79

2019	Mayo	0.78	0.71
2019	Junio	0.79	0.79
2019	Julio	0.84	0.80
2019	Agosto	0.90	0.78
2019	Setiembre	0.96	0.79
2019	Octubre	0.93	0.84
2019	Noviembre	0.85	0.90
2019	Diciembre	0.93	0.93
2020	Enero	0.96	0.85
2020	Febrero	0.90	0.93
2020	Marzo	0.83	0.96
2020	Abril	0.70	0.90
2020	Mayo	0.74	0.90
2020	Junio	0.83	0.78
2020	Julio	0.81	0.79
2020	Agosto	0.93	0.85
2020	Setiembre	0.97	0.86
2020	Octubre	0.97	0.97
2020	Noviembre	1.00	1.00
2020	Diciembre	0.91	1.01
2021	Enero	0.88	1.04
2021	Febrero	0.84	0.96
2021	Marzo	0.82	0.93
2021	Abril	0.80	0.88
2021	Mayo	0.72	0.86
2021	Junio	0.75	0.85
2021	Julio	0.86	0.79
2021	Agosto	0.84	0.81
2021	Setiembre	0.93	0.89
2021	Octubre	0.87	0.89
2021	Noviembre	0.90	0.98
2021	Diciembre	0.90	0.92



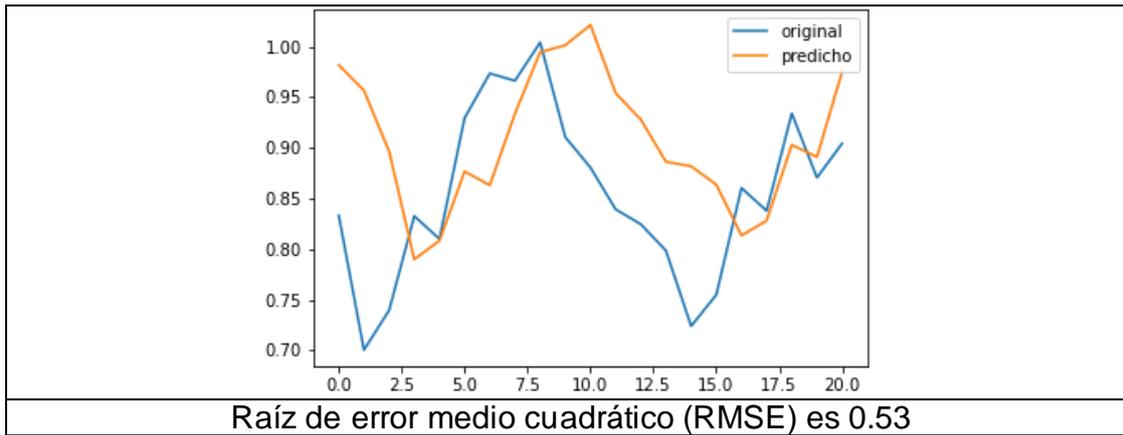


Figura 13. Aprendizaje de la red neuronal artificial con la data de entrenamiento y testeo usando 64 nodos en horizontes temporales a mediano plazo.

En la figura 13 se observó la red neuronal artificial con 64 nodos, la data de entrenamiento presentó el valor de 0.46 para la raíz de error medio cuadrático (RMSE), mientras que la data de testeo presentó un valor de 0.53 para la raíz de error medio cuadrático (RMSE).

Tabla 16. Cotejo de la velocidad del viento en el horizonte temporal a mediano plazo en la estación Matapalo usando 4 nodos ocultos (data del SENAMHI y los data de salida de la red neuronal).

Año	Data del SENAMHI	Data de testeo
2014	1.36	error
2015	1.16	error
2016	1.14	error
2017	1.12	error
2018	1.09	error
2019	0.84	error
2020	0.88	error
2021	0.84	error

### 4.3. Pronóstico de valores futuros de la variable velocidad del viento.

Tabla 17. Data de testeo del 1 de enero al 4 de enero del 2022 horizonte temporal a corto plazo.

Fecha	Hora	Data de testeo
01/01/2022	00:00:00	0.74
01/01/2022	01:00:00	0.81
01/01/2022	02:00:00	1.46

01/01/2022	03:00:00	0.46
01/01/2022	04:00:00	0.23
01/01/2022	05:00:00	0.58
01/01/2022	06:00:00	0.26
01/01/2022	07:00:00	0.54
01/01/2022	08:00:00	0.71
01/01/2022	09:00:00	0.87
01/01/2022	10:00:00	1.04
01/01/2022	11:00:00	0.64
01/01/2022	12:00:00	0.71
01/01/2022	13:00:00	0.96
01/01/2022	14:00:00	1.76
01/01/2022	15:00:00	1.93
01/01/2022	16:00:00	1.08
01/01/2022	17:00:00	1.26
01/01/2022	18:00:00	1.34
01/01/2022	19:00:00	1.11
01/01/2022	20:00:00	0.87
01/01/2022	21:00:00	1.24
01/01/2022	22:00:00	0.04
01/01/2022	23:00:00	0.11
02/01/2022	00:00:00	0.66
02/01/2022	01:00:00	0.26
02/01/2022	02:00:00	0.03
02/01/2022	03:00:00	0.38
02/01/2022	04:00:00	0.26
02/01/2022	05:00:00	0.84
02/01/2022	06:00:00	0.31
02/01/2022	07:00:00	0.37
02/01/2022	08:00:00	0.24
02/01/2022	09:00:00	0.24
02/01/2022	10:00:00	0.51
02/01/2022	11:00:00	0.46
02/01/2022	12:00:00	0.96
02/01/2022	13:00:00	0.73
02/01/2022	14:00:00	2.28
02/01/2022	15:00:00	1.36
02/01/2022	16:00:00	1.84
02/01/2022	17:00:00	2.31
02/01/2022	18:00:00	1.67
02/01/2022	19:00:00	0.74
02/01/2022	20:00:00	0.94
02/01/2022	21:00:00	1.91
02/01/2022	22:00:00	1.86
02/01/2022	23:00:00	0.76
03/01/2022	00:00:00	0.03
03/01/2022	01:00:00	0.28
03/01/2022	02:00:00	0.46

03/01/2022	03:00:00	0.06
03/01/2022	04:00:00	0.31
03/01/2022	05:00:00	0.87
03/01/2022	06:00:00	0.64
03/01/2022	07:00:00	0.94
03/01/2022	08:00:00	0.51
03/01/2022	09:00:00	0.66
03/01/2022	10:00:00	1.56
03/01/2022	11:00:00	1.53
03/01/2022	12:00:00	1.08
03/01/2022	13:00:00	1.16
03/01/2022	14:00:00	2.84
03/01/2022	15:00:00	2.81
03/01/2022	16:00:00	1.67
03/01/2022	17:00:00	1.54
03/01/2022	18:00:00	1.24
03/01/2022	19:00:00	0.61
03/01/2022	20:00:00	0.96
03/01/2022	21:00:00	1.96
03/01/2022	22:00:00	0.73
03/01/2022	23:00:00	0.38
04/01/2022	00:00:00	0.16
04/01/2022	01:00:00	1.34
04/01/2022	02:00:00	0.41
04/01/2022	03:00:00	0.27
04/01/2022	04:00:00	0.24
04/01/2022	05:00:00	0.64
04/01/2022	06:00:00	0.11
04/01/2022	07:00:00	0.46
04/01/2022	08:00:00	0.66
04/01/2022	09:00:00	0.43
04/01/2022	10:00:00	0.88
04/01/2022	11:00:00	2.06
04/01/2022	12:00:00	2.54
04/01/2022	13:00:00	1.81
04/01/2022	14:00:00	1.97
04/01/2022	15:00:00	2.54
04/01/2022	16:00:00	1.74
04/01/2022	17:00:00	2.71
04/01/2022	18:00:00	1.96
04/01/2022	19:00:00	1.46
04/01/2022	20:00:00	1.63
04/01/2022	21:00:00	1.78
04/01/2022	22:00:00	1.06
04/01/2022	23:00:00	0.44

Tabla 18. Data de testeo del mes de enero del 2022 a diciembre del 2023 en el horizonte temporal a mediano plazo.

<b>Año</b>	<b>Mes</b>	<b>Data de testeo</b>
2022	Enero	0.93
2022	Febrero	0.97
2022	Marzo	0.83
2022	Abril	0.86
2022	Mayo	0.75
2022	Junio	0.80
2022	Julio	0.78
2022	Agosto	0.83
2022	Setiembre	0.88
2022	Octubre	0.9
2022	Noviembre	1.02
2022	Diciembre	0.99
2023	Enero	0.96
2023	Febrero	0.85
2023	Marzo	0.9
2023	Abril	0.88
2023	Mayo	0.84
2023	Junio	0.79
2023	Julio	0.82
2023	Agosto	0.77
2023	Setiembre	0.8
2023	Octubre	0.79
2023	Noviembre	0.86
2023	Diciembre	0.98

Tabla 19. Data de testeo de los años 2022 y 2029 en el horizonte temporal a largo plazo.

<b>Año</b>	<b>Data de testeo</b>
2022	0.88
2023	0.85

#### 4.4. Producción de energía eólica.

Tabla 20. Producción de la energía eólica en el horizonte temporal a corto plazo del 1 de enero del 2022.

<b>Hora</b>	<b>Velocidad del viento (m/s)</b>	<b>Producción de energía eólica (kW)</b>
00:00:00	1.70	0
01:00:00	1.86	0
02:00:00	3.35	20

03:00:00	1.06	0
04:00:00	0.53	0
05:00:00	1.33	0
06:00:00	0.60	0
07:00:00	1.24	0
08:00:00	1.63	0
09:00:00	2.00	10
10:00:00	2.39	10
11:00:00	1.47	0
12:00:00	1.63	0
13:00:00	2.21	10
14:00:00	4.04	30
15:00:00	4.43	30
16:00:00	2.48	10
17:00:00	2.89	10
18:00:00	3.08	20
19:00:00	2.55	10
20:00:00	2.00	10
21:00:00	2.85	10
22:00:00	0.09	0
23:00:00	0.25	0
<b>Total</b>		<b>180</b>

Tabla 20. La velocidad del viento fue calculada para una altura de 100 metros y el resultado se comparó con tabla de curva de potencia de aerogenerador, obteniendo la producción de energía eólica.

#### IV. DISCUSIÓN

Quiñonez, J; Huanca, E y Holguino A (2019). En su trabajo de investigación examinaron datos entre los años 2013 y 2014 por el Servicio Nacional de Meteorología e Hidrología del Perú – SENAMHI, los cuales fueron comparados con los datos de Surface Meteorology and Solar Energy de la NASA completando así la falta de datos. Mientras Ibarguengoytia, Reyes, Borunda y García (2017) usaron datos meteorológicos del centro regional de tecnología eólica (CERTER) incompletos, para lo cual usaron un método de reconstrucción donde se trabaja con los valores de entrada y salida completando los datos faltantes. El presente trabajo empleo el tratamiento Missing para la estación Matapalo mismo método que Espíritu y Flores (2021) donde este método permite completar los datos faltantes con ayuda de datos existentes, por medio de la desviación estándar y el promedio de la velocidad del viento.

Bolaños (2028) para pronosticar la velocidad del viento empleo una red neuronal artificial con el software MATLAB en el cual trabajo sus datos, su RNA presenta una característica especial la cual es el aprendizaje automático, por consecuente obtuvo un error cuadrático medio de 0.016 para pronosticar en un lapso 3 días, con un nivel de aprendizaje no mayor al 10% y para cotejar los datos de testeo con los datos de entrenamiento obteniendo alrededor del 90% de similitud. Mientras que Nogay y Eidukeviciute (2012) emplearon varios prototipos de redes neuronales artificiales para predecir en corto plazo la velocidad del viento concluyendo que 60 capas ocultas es el prototipo más exitoso con error cuadrático medio de 0.378088 y 0.970490. Por otra parte, en el desarrollo de la presente investigación, al momento del adiestramiento de la red neuronal fue hecha en el software Python en la interface Jupiter, alcanzando los valores en el error cuadrático medio (RMSE) en el periodo de corto plazo de 1.1 con 4 nodos, 1.03 con 8 nodos, 0.96 con 16 nodos, 0.79 con 32 nodos y 1.03 con 64 nodos y para el periodo de mediano plazo de 1.02 con 4 nodos, 0.92 con 8 nodos, 0.72 con 16 nodos, 0.22 con 32 nodos y 0.53 con 64 nodos, dichos valores determinan el nivel de desempeño del modelo para pronosticar las velocidades del viento a futuro.

Para poder producir energía eólica la velocidad del viento como mínimo debe de ser 2 m/s, para el pronóstico del 1 de enero del 2022, solo es aprovechable 14 horas de las 24 horas del día mencionado, obteniendo 180 kW por día para una altura de 100 m, mientras que Charaja (2017) necesita de 336 kW, para que su planificación de inversión propuesta de un aerogenerador sea aceptada, por lo tanto se podría llegar a los kW requeridos aumentando la altura del aerogenerador, puesto a que mayor altura la velocidad del viento es mayor.

El instrumento creado para pronosticar la velocidad del viento es la red neuronal artificial autorregresivo, capas de pronosticar en 2 de los 3 horizontes temporales tiene una peculiaridad especial, al momento de ingresar la data de entrenamiento y de testeo, se puede medir el error cuadrático medio mientras se encuentra en pleno adiestramiento, caso contrario al trabajo presentado por Carmelo (2017) que usa modelos autorregresivos formadas por Holt-Winter, que solo se puede medir su error cuadrático medio al finalizar el adiestramiento. Por otra parte, Ibarguengoytia, Reyes Borunda y Garcia (2017) plasman una Inteligencia Artificial (IA) para la predicción del potencial eólico apoyado de bases de datos meteorológicos de años pasados, al compararse se hallaron resultados satisfactorios, pero al momento de realizar algunos cambios en la variable se tiene que volver a reestructurar la inteligencia artificial.

Yaulema (2020) en la implementación del modelo neuronal, plantea lo siguiente, mientras más datos se ingresen a la red neuronal, abra una mayor eficiencia y por ende la predicción será más cercana y con horizontes más amplios, mientras tanto Lopez, Velo y Maseda (2017) resaltan que las redes neuronales tienen una mayor eficiencia pronosticando la velocidad del viento en periodos a corto plazo trabajando con una amplia base de datos, lo cual tan bien se ve evidenciado en el trabajo de Nascimento (2019) quien pronosticó la velocidad del viento en Uruguay empleado redes neuronales artificiales en periodo de corto plazo, entre 1 y 3 horas con predicciones casi exactas. Tan bien presentó inconvenientes al momento de prolongar el tiempo de pronóstico, teniendo una menor precisión, lo cual se ve reflejado en el trabajo presentado, debido a que en los horizontes a largo plazo la base de datos no es muy extensa ya que se parte del 2014, por ende, las redes neuronales no pueden

pronosticar en dicho horizonte presentando un error en la parte del entrenamiento de la red, caso contrario con los horizontes temporales a corto plazo y mediano plazo que presentan una base de datos extensa.

## V. CONCLUSIÓN

Se determinó el pronóstico de la velocidad del viento en la estación Matapalo para los horizontes temporales a corto plazo y mediano plazo, mientras que a largo plazo no se puede determinar ya que la data no cuenta con la antigüedad suficiente para obtener una base de data en la cual pueda trabajar la red neuronal. Durante el pronóstico la red neuronal artificial fue un éxito ya que los valores de predicción de la velocidad del viento, tuvieron un rendimiento optimo el cual fue medido por el error cuadrático medio (RMSE), que dio valores para corto plazo de 0.13 para la data de entrenamiento y 0.79 para la data de testeo, por otra parte, a mediano plazo arrojó valores de 0.06 tanto para la data de entrenamiento como para la data de testeo, con los datos pronosticados se calculó la producción de energía eólica para una altura de 100 metros obteniendo 180 kW por día.

Se creó un instrumento para pronosticar la velocidad del viento que es la red neuronal artificial modelo secuencial supervisada, con rangos de 4 a 64 para los nodos o capas ocultas, se probó en los diferentes horizontes temporales como a corto plazo y mediano plazo, en los cuales se observó una mayor eficiencia en las redes neuronales que presentan 32 nodos.

Las redes neuronales para el pronóstico de la velocidad del viento fueron un éxito en los horizontes temporales a corto plazo y a mediano plazo, pero en el horizonte temporal de largo plazo no se pudo usar la red neuronal debido a la falta de antigüedad de datos brindados por el SENAMHI por esta razón los promedios anuales en las predicciones de los años 2022 y 2023 son la suma de los meses y la división de los meses predichos en los horizontes temporales a mediano plazo.

## **VI. RECOMENDACIONES**

Al momento de trabajar con datos incompletos, se podrá caer en diferentes tipos de errores que perjudique el tratamiento de la base de datos, por lo tanto, se recomienda ordenar los datos por días, meses y años y trabajarlos por separado, para tener una visión detallada de los datos y se pueda escoger un método estadístico adecuado para la imputación de estos mismos.

Para trabajos similares donde se pronostique la velocidad del viento por medio de la red neuronal artificial se sugiere que dicha RNA sea de característica supervisada ya que se podrá comparar la data la data de entrenamiento y la data de testeo, con ello se podrá ver la eficacia de las predicciones para años posteriores.

Cuando se examine los resultados y el valor del error cuadrático medio (RMSE) en los horizontes temporales en cada nodo o capa oculta tanto para la data de entrenamiento y la data de testeo, se recomienda que la información sea plasmada en una hoja de cálculo Excel donde se podrá apreciar mediante un gráfico el cual reflejara las variaciones en cada periodo y así tomar valores para obtener data confiable.

## REFERENCIAS

A. J. Serrano, E. Soria, y J. Martín, "Redes neuronales artificiales", Universidad de Valencia. Escuela Técnica Superior Ingeniería, Departamento de Ingeniería Electrónica, 2009.

A. Gupta, AO Salau, P. Chaturvedi, SA Akinola y N. Ikechi Nwulu, "Notice of Violation of IEEE Publication Principles; Artificial Neural Networks: Its Techniques and Applications to Forecasting", *Conferencia Internacional de 2019 sobre Automatización, Gestión Computacional y Tecnológica (ICACTM)*, 2019, págs. 320-324, doi: 10.1109 / ICACTM.2019.8776701. Disponible es: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8776701&isnumber=8776675>

AZUMENDI GÓNGORA, D (2018). *Predicción de la velocidad del viento para la estimación de la energía generada por un aerogenerador*. [en línea]. Proyecto de Grado. Bogota:Universidad de los Andes [Fecha consulta: 4 de octubre 2021] Disponible en: <https://repositorio.uniandes.edu.co/bitstream/handle/1992/40261/u808065.pdf?sequence=1>

B. Martínez Pérez y A. Roque Rodríguez, "Pronóstico energético a muy corto plazo para el Parque Eólico Gibara I utilizando un modelo autorregresivo", *Revista Cubana de Meteorología*, vol. 25, n.o 2, feb. 2019.

BOJORQUEZ (2018) Planteamiento de un parque eólico marino en la costa peruana: regiones de Ica, Piura y La Libertad. Disponible en: <https://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/13054/BOJ>

[ORQUEZ CHAVEZ MIGUEL PLANEAMIENTO PARQUE EÓLICO.pdf?sequence=1](http://repositorio.unsa.edu.pe/bitstream/handle/UNSA/10071/UPcahawr.pdf?sequence=1)

CABANA (2019). ALGORITMO DE REDES NEURONALES ARTIFICIALES PARA EL SEGUIMIENTO DEL PUNTO DE MÁXIMA POTENCIA DE UN PANEL FOTOVOLTAICO”

Disponible en:  
<http://repositorio.unsa.edu.pe/bitstream/handle/UNSA/10071/UPcahawr.pdf?sequence=1&isAllowed=y>

CAMELO, Henrique do Nascimento et al. Métodos de Previsão de Séries Temporais e Modelagem Híbrida ambos Aplicados em Médias Mensais de Velocidade do Vento para Regiões do Nordeste do Brasil. Revista Brasileira de Meteorologia [online]. 2017, v. 32, n. 4, pp. 565-574. Disponible en:  
<https://www.scielo.br/j/rbmet/a/XCmF6ssBPJvfDVJgWZVDF6t/?lang=pt>

CEPAL (2013) Energía. Una visión sobre los retos y oportunidades en América Latina y el Caribe <https://www.cepal.org/es/publicaciones/1505-energia-vision-retos-oportunidades-america-latina-caribe>

CHARAJA ZAPANA H. (2018). Estudio de factibilidad para la implementación de un parque eólico en el entorno de una operación vitícola en la irrigación majes Arequipa – Perú 2017. Disponible:  
<http://repositorio.unsa.edu.pe/bitstream/handle/UNSA/5820/llchzahg.pdf?sequence=1&isAllowed=y>

COLUMBUS, DEL RIO MENDOZA, ESQUIVEL Y MARTÍNEZ (2018). Planeamiento Estratégico para el Sector de Energía Eólica del Perú Disponible en:

[https://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/12586/COL\\_UMBUS\\_DEL%20RIO\\_PLANEAMIENTO\\_EOLICA.pdf?se](https://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/12586/COL_UMBUS_DEL%20RIO_PLANEAMIENTO_EOLICA.pdf?se)

CUI, Y., Huang, C., & Cui, Y. (2020). A novel compound wind speed forecasting model based on the back propagation neural network optimized by bat algorithm. *Environmental science and pollution research international*, 27(7), 7353–7365. Disponible en: <https://doi.org/10.1007/s11356-019-07402-1>

Custódio, R. (2013). *Energía Eólica para Producción de Energía Eléctrica*. Synergia Editora, Rio de Janeiro, Brasil

DE ALMEIDA LUCAS, Everton, 2019. *Pronóstico de energía eólica para horizontes temporales de corto plazo en base a modelo numérico de mesoescala y redes neuronales artificiales*. [en línea]. Tesis de maestría. Uruguay: Universidad de la República. Facultad de Ingeniería. 2019. [Fecha consulta: 4 de octubre 2021]. Disponible en: <https://www.colibri.udelar.edu.uy/jspui/handle/20.500.12008/22126>

DE LA CRUZ BUELVAS, Jhonatan; VALENCIA OCHOA, Guillermo y VANEGAS CHAMORRO, Marley. *Estudio estadístico de la velocidad y la dirección del viento en los departamentos de Atlántico y Bolívar en Colombia. Ingeniare. Rev. chil. ing.* [online]. 2018, vol.26, n.2 [citado: 04 de octubre 2021], pp.319-328. ISSN 0718-3305. Disponible en: [http://www.scielo.cl/scielo.php?script=sci\\_arttext&pid=S0718-33052018000200319&lng=es&nrm=iso](http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-33052018000200319&lng=es&nrm=iso)

Espiritu, Y., Flores I. (2021) *Modelamiento Ambiental utilizando redes neuronales y sistemas de información geográfica para determinar el potencial de energía eólica en Lambayeque – 2021* [en línea]. Tesis para obtener el título profesional de ingeniero ambiental. Peru: Universidad Cesar Vallejo. 2021.

[Fecha consulta: 4 de mayo 2021]. Disponible en: disponible:  
<https://repositorio.ucv.edu.pe/handle/20.500.12692/81092>

FAMOSO, F., Brusca, S., D'Urso, D., Galvagno, A. y Chiacchio, F. (2020). Un modelo híbrido novedoso para la estimación de la conversión de energía en un parque eólico que combina efectos de estela y confiabilidad estocástica. *Energía aplicada*, 280, 115967. doi: 10.1016 / j.apenergy.2020.115967.

Disponible en:  
<https://www.sciencedirect.com/science/article/abs/pii/S0306261920314197>

Feng Zhao, Joyce Lee (2021). Welcome to the Global Wind Report 2021. *Global Wind Energy Council*. [en línea]. Disponible en: <https://gwec.net/wp-content/uploads/2021/03/GWEC-Global-Wind-Report-2021.pdf>. [consulta: 30 de setiembre del 2021]

G. Li y J. Shi, "On comparing three artificial neural networks for wind speed forecasting", *Applied Energy*, vol. 87, n.o 7, pp. 2313-2320, jul. 2010.

H. Masrur, M. Nimol, M. Faisal, y S. M. G. Mostafa, "Short term wind speed forecasting using Artificial Neural Network: A case study", en 2016 International Conference on Innovations in Science, Engineering and Technology (ICISSET), 2016, pp. 1-5.

IBARGÜENGOYTIA, Pablo, et al., 2017. Predicción de potencia eólica utilizando técnicas modernas de inteligencia artificial [en línea]. *Mexico, Ingeniería, investigación y tecnología*, vol. XIX, núm. 4, 2018, [consulta: 03 de octubre de 2021] DOI: [10.22201/fi.25940732e.2018.19n4.033](https://doi.org/10.22201/fi.25940732e.2018.19n4.033) Disponible en:

<https://www.redalyc.org/journal/404/40458316007/html/>

IRENA (2020). ESTADÍSTICAS DE CAPACIDAD RENOVABLE 2020. Disponible en: [https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2020/Mar/IRENA\\_RE\\_Capacity\\_Statistics\\_2020.pdf](https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2020/Mar/IRENA_RE_Capacity_Statistics_2020.pdf)

L. A. Fernández, "Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos", Tesis Doctoral, Universidad de La Rioja, 2007.

M. Ouanani Allachi, "Predicción de energía eólica utilizando técnicas de aprendizaje automático", may 2016.

M. Ritter, Z. Shen, B. López Cabrera, M. Odening and L. Deckert (2015). "Designing an index for assessing wind energy potential". Renew. Energy. Vol. 83, pp. 416-424. Disponible en: <https://cepei.org/documents/emisiones-del-sector-electrico/>

OBANE, H., Nagai, Y. y Asano, K. (2020). Evaluación del uso de la tierra y los posibles conflictos en la energía solar y eólica terrestre en Japón. Energía renovable. doi: 10.1016/j.renene.2021.06.18 Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0960148120309125>.

OSINERGMIN (2020). División de Supervisión de Electricidad. Supervisión de contratos de proyectos de generación y transmisión de energía eléctrica. [en línea]. [fecha de Consulta: 19 de octubre de 2021] Disponible en: [https://www.osinergmin.gob.pe/seccion/centro\\_documental/electricidad/Documentos/Publicaciones/Compendio-Proyectos-GTE-Construccion-agosto-2020.pdf](https://www.osinergmin.gob.pe/seccion/centro_documental/electricidad/Documentos/Publicaciones/Compendio-Proyectos-GTE-Construccion-agosto-2020.pdf)

P. F. Bolaños Logroño, "Predicción de la velocidad del viento mediante redes neuronales, para la Estación Meteorológica Chimborazo.", Escuela Politécnica Superior de Chimborazo, mar. 2018.

PEREZ RODRIGUEZ, Daniel, 2019. *Predicción de la Velocidad del Viento para la Generación Eólica mediante Redes Neuronales Artificiales*. [en línea]. Trabajo de diploma. Cuba: Universidad central marta abreu de las villas. Facultad de Ingeniería Eléctrica. [Fecha consulta: 4 de octubre 2021]. Disponible en: <https://dspace.uclv.edu.cu/bitstream/handle/123456789/11402/Daniel%20P%20A9rez%20Rodr%C3%ADguez.pdf?sequence=1&isAllowed=n>

RANGANAYAKI, V., & Deepa, S. N. (2016). An Intelligent Ensemble Neural Network Model for Wind Speed Prediction in Renewable Energy Systems. *TheScientificWorldJournal*, 2016, 9293529. Recuperado en: <https://doi.org/10.1155/2016/9293529>

Rodriguez Rangel, Hector & Carrillo, Noel & Flores, Juan & Morales Rosales, Luis & Montelongo, Giovanni. (2017). Pronóstico a corto plazo de velocidad del viento a partir de datos incompletos Wind Speed Short-term Forecasting from Incomplete Data. *Research in Computing Science*. 139. 10.13053/rcs-139-1-7. disponible en: [https://www.rcs.cic.ipn.mx/2017\\_139/Pronostico%20a%20corto%20plazo%20de%20velocidad%20del%20viento%20a%20partir%20de%20datos%20incompletos.pdf](https://www.rcs.cic.ipn.mx/2017_139/Pronostico%20a%20corto%20plazo%20de%20velocidad%20del%20viento%20a%20partir%20de%20datos%20incompletos.pdf)

QUINONEZ CHOQUECOTA, José; HUANCA CALLATA, Elmer y HOLGUINO HUARZA, Antonio. Caracterización del recurso eólico en la ciudad de

Juliaca. *Rev. investig. Altoandin.* [online]. 2019, vol.21, n.1 [Fecha consulta: 09 de octubre 2021] pp.57-68. Disponible en: <[http://www.scielo.org.pe/scielo.php?script=sci\\_arttext&pid=S2313-29572019000100005&lng=es&nrm=iso](http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S2313-29572019000100005&lng=es&nrm=iso)>. ISSN 2313-2957. <http://dx.doi.org/10.18271/ria.2019.445>.

RANGANAYAKI, V., & Deepa, S. N. (2016). An Intelligent Ensemble Neural Network Model for Wind Speed Prediction in Renewable Energy Systems. *TheScientificWorldJournal*, 2016, 9293529.

Recuperado en: <https://doi.org/10.1155/2016/9293529>

S. Kumar y K. B. Sahay, "Wind Speed Forecasting using Different Neural Network Algorithms", en 2018 2nd International Conference on Electronics, Materials Engineering Nano-Technology (IEMENTech), 2018, pp. 1-4.

SELCUK NOGAY, H.; AKINCI, Tahir Cetin y EIDUKEVICIUTE, Marija. Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey . *J. Energy South. Afr.* [en línea]. 2012, vol.23, n.4 [consulta: 03 de octubre 2021], pp.2-7. ISSN 2413-3051. Disponible en: [http://www.scielo.org.za/scielo.php?script=sci\\_arttext&pid=S1021-447X2012000500001&lng=en&nrm=iso](http://www.scielo.org.za/scielo.php?script=sci_arttext&pid=S1021-447X2012000500001&lng=en&nrm=iso)

V. A. Profillidis y G. N. Botzoris, "Chapter 8 - Artificial Intelligence—Neural Network Methods", en *Modeling of Transport Demand*, V. A. Profillidis y G. N. Botzoris, Eds. Elsevier, 2019, pp. 353-382.

V. Kumar, V. K. Singhal, A. Kushwaha, M. Agarwal, y A. Gupta, "Wind Speed & Power Forecasting using Artificial Neural Network (NARX) for new York Wind Energy Farm", Journal for Research| Volume, vol. 3, n.o 09, 2017.

X. Zhao, S. Wang, y T. Li, "Review of evaluation criteria and main methods of wind power forecasting", Energy Procedia, vol. 12, pp. 761-769, 2011. (<https://www.sciencedirect.com/science/article/pii/S187661021101928X>)

Y. García López, "Predicción de la demanda eléctrica empleando redes neuronales artificiales", Thesis, Universidad Central "Marta Abreu" de Las Villas. Facultad de Ingeniería Eléctrica. Departamento de Electroenergética, 2009.

YAN, J., Liu, Y., Han, S., Wang, Y. y Feng, S. (2015). Reseñas sobre análisis de incertidumbre de la previsión de energía eólica. Revisiones de energías renovables y sostenibles, 52, 1322-1330. doi: 10.1016 / j.rser.2015.07.197.

Disponible en:

<https://www.sciencedirect.com/science/article/abs/pii/S1364032115008552>

ZUCATELLI, P. J., Nascimento, E., Aylas, G., Souza, N., Kitagawa, Y., Santos, A., Arce, A., & Moreira, D. M. (2019). Short-term wind speed forecasting in Uruguay using computational intelligence. Heliyon, 5(5), e01664.

Disponible en: <https://doi.org/10.1016/j.heliyon.2019.e01664>

## ANEXOS

### ANEXO 1. Matriz de operacionalización de variable

Variables	Definición Conceptual	Definición Operacional	Dimensiones	Indicadores	Escala o unidad
<b>INDEPENDIENTE: Redes neurales</b>	Las redes neuronales se encuentran en el grupo de inteligencia artificial que emplea software para simular, desarrollar o predecir, para ello necesita una base de datos. (Kilic,2019, p.3)	La variable redes neuronales empleara los datos históricos de la velocidad del viento los serán representados con graficas.	Análisis de predicción (ANN)	Datos históricos del sistema real de la velocidad del viento (m/s)	m/s
			Análisis de la velocidad del viento	Graficas de predicción de la velocidad del viento	m/s
<b>DEPENDIENTE: Pronóstico de la velocidad del viento</b>	Velocidad del viento: Es el resultado del aumento de temperatura en la masa de aire, al tener una masa de aire caliente se desplaza a la superficie de la atmosfera y por la presión atmosférica la masa de aire fría de la superficie se desplaza a la parte inferior Custodio (2013).	La variable Pronóstico de la velocidad del viento será medida por los factores que afectan la velocidad del viento y los horizontes a pronosticar.	Velocidad del viento	Temperatura	°C
				Presión atmosférica	msnm
				Dirección del viento	grados
			Horizontes de predicción	Corto plazo	Horas
				Mediano Plazo	Meses
				Largo plazo	Años

ANEXO 2. Matriz de consistencia

Problema	Objetivo	Hipótesis	Variables	Diseño Meteorológico	Población y muestra
<p><b>Problema General</b> ¿Es posible determinar el pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neurales en Tumbes - 2022</p> <p><b>Problema Específicos</b>                      ¿Se podrá crear un instrumento para pronosticar en diferentes horizontes temporales la velocidad del viento para la producción de energía eólica utilizando redes neuronales en tumbes – 2022?</p> <p>¿En qué horizonte temporal determinado el pronóstico de la velocidad del viento para la producción de energía eólica utilizando Redes Neuronales es aceptable en Tumbes – 2022?</p>	<p><b>Objetivo General</b>                      Determinar el pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neurales en Tumbes - 2022</p> <p><b>Objetivo Especifico</b>                      Elaborar un instrumento para pronosticar en diferentes horizontes temporales la velocidad del viento para la producción de energía eólica utilizando redes neuronales en tumbes – 2022</p> <p>Determinar en qué horizonte temporal los pronósticos de la velocidad del viento para la producción de energía eólica utilizando Redes Neuronales es aceptable en Tumbes – 2022</p>	<p>Se podrá determinar el pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neurales en Tumbes - 2022</p> <p>Se podrá elaborar un instrumento para pronosticar en diferentes horizontes temporales la velocidad del viento para la producción de energía eólica utilizando Redes neuronales en Tumbes – 2022.</p> <p>Hasta que horizonte el pronóstico de la velocidad del viento para la producción de energía eólica utilizando Redes Neuronales es aceptable en Tumbes – 2022</p>	<p><b>Variable Independiente</b>                      Redes neurales</p> <p><b>Variable Dependiente</b>                      Pronóstico de la velocidad del viento</p>	<p>Tipo: Descriptivo</p> <p>Diseño: No experimental</p>	<p><b>Población:</b> Esta constituida por los datos históricos de la velocidad del viento con una antigüedad de 20 años</p> <p><b>Muestra:</b> Información de la velocidad del viento registrada en los últimos 20 años que fueron tomadas en 5 estaciones meteorológicas</p> <p><b>Muestreo:</b> Es la recopilación de toda la información meteorológica otorgada por el (SENAMHI)</p>

### ANEXO 3. Instrumento de recolección de datos



#### Instrumento de recolección de datos

##### DATOS DEL SOLICITANTE

<b>NOMBRE O RAZÓN SOCIAL:</b>			
<b>Dirección:</b>			
<b>RUC (*):</b>		<b>Teléfono:</b>	
<b>E-mail :</b>			
<b>Sector o Rubro (*):</b>			
<b>Representante (*):</b>		<b>DNI:</b>	

(\*) Solo completar en caso de ser una persona jurídica.

##### INFORMACIÓN REFERENCIAL

**Descripción del estudio:**

**Alcance:**

##### SERVICIO 1: Expedición de información procesada de variables hidrometeorológicas

Estación / Área de Interés	Variable Hidrometeorológica	Escala (diaria / mensual)	Período

##### Información Adicional / Observaciones

--

**Fecha:**


## ANEXO 4. Validación de Instrumentos



**SOLICITUD:** Validación de instrumento de recojo de información.

### **Dr. Euterio Horacio Acosta Suasnabar**

Yo Edson Adrian, Perez Lucas identificados con DNI N°75279548, alumno de la EAP de Ingeniería Ambiental, a usted con el debido respeto me presento y le manifiesto:

Que siendo requisito indispensable el recojo de datos necesarios para la tesis que vengo elaborando titulada: **“Pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neuronales en Tumbes – 2022”**, solicito a Ud. Se sirva validar el instrumento que le adjunto bajo los criterios académicos correspondientes. Para este efecto adjunto los siguientes documentos:

- Ficha de evaluación
- Instrumento
- Matriz de operacionalización de variables

Por tanto:

A usted, ruego acceder mi petición.

Lima, 25 de noviembre del 2021

A handwritten signature in blue ink, appearing to read "Edson Adrian Perez Lucas".

---

Perez Lucas Edson Adrian  
DNI: 75279548

### 3. VALIDACIÓN DE INSTRUMENTO

#### I. DATOS GENERALES

- 1.1. Apellidos y Nombres:.....  
 1.2. Cargo e institución donde labora:.....  
 1.3. Especialidad o línea de investigación:.....  
 1.4. Nombre del instrumento motivo de evaluación:.....  
 1.5. Autor(A) de Instrumento:.....

#### II. ASPECTOS DE VALIDACIÓN

CRITERIOS	INDICADORES	INACEPTABLE					MINIMAMENTE ACEPTABLE			ACEPTABLE				
		40	45	50	55	60	65	70	75	80	85	90	95	100
1. CLARIDAD	Esta formulado con lenguaje comprensible.												X	
2. OBJETIVIDAD	Esta adecuado a las leyes y principios científicos.												X	
3. ACTUALIDAD	Esta adecuado a los objetivos y las necesidades reales de la investigación.												X	
4. ORGANIZACIÓN	Existe una organización lógica.												X	
5. SUFICIENCIA	Toma en cuenta los aspectos metodológicos esenciales												X	
6. INTENCIONALIDAD	Esta adecuado para valorar las variables de la Hipótesis.												X	
7. CONSISTENCIA	Se respalda en fundamentos técnicos y/o científicos.												X	
8. COHERENCIA	Existe coherencia entre los problemas objetivos, hipótesis, variables e indicadores.												X	
9. METODOLOGÍA	La estrategia responde una metodología y diseño aplicados para lograr probar las hipótesis.												X	
10. PERTINENCIA	El instrumento muestra la relación entre los componentes de la investigación y su adecuación al Método Científico.												X	

#### III. OPINIÓN DE APLICABILIDAD

- El instrumento cumple con los Requisitos para su aplicación
- El instrumento no cumple con Los requisitos para su aplicación

SI

#### IV. PROMEDIO DE VALORACIÓN :

95 %
------

Lima,..... del 2021

  
 FIRMA DEL EXPERTO INFORMANTE  
 Dr. HORACIO ACOSTA GUASHANBAR  
 CIP.....  
 DNI N°..... Telf:.....

**SOLICITUD:** Validación de instrumento de recojo de información.

**Sr: Mg Freddy Pillpa Aliaga**

Yo Edson Adrian, Perez Lucas identificados con DNI N°75279548, alumno de la EAP de Ingeniería Ambiental, a usted con el debido respeto me presento y le manifiesto:

Que siendo requisito indispensable el recojo de datos necesarios para la tesis que vengo elaborando titulada: **“Pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neuronales en Tumbes – 2022”**, solicito a Ud. Se sirva validar el instrumento que le adjunto bajo los criterios académicos correspondientes. Para este efecto adjunto los siguientes documentos:

- Ficha de evaluación
- Instrumento
- Matriz de operacionalización de variables

Por tanto:

A usted, ruego acceder mi petición.

Lima, 25 de noviembre del 2021



---

Perez Lucas Edson Adrian  
DNI: 75279548

### 3. VALIDACIÓN DE INSTRUMENTO

#### I. DATOS GENERALES

- 1.1. Apellidos y Nombres:.....  
 1.2. Cargo e institución donde labora:.....  
 1.3. Especialidad o línea de investigación:.....  
 1.4. Nombre del instrumento motivo de evaluación:.....  
 1.5. Autor(A) de Instrumento:.....

#### II. ASPECTOS DE VALIDACIÓN

CRITERIOS	INDICADORES	INACEPTABLE					MINIMAMENTE ACEPTABLE			ACEPTABLE				
		40	45	50	55	60	65	70	75	80	85	90	95	100
1. CLARIDAD	Esta formulado con lenguaje comprensible.													
2. OBJETIVIDAD	Esta adecuado a las leyes y principios científicos.													
3. ACTUALIDAD	Esta adecuado a los objetivos y las necesidades reales de la investigación.													
4. ORGANIZACIÓN	Existe una organización lógica.													
5. SUFICIENCIA	Toma en cuenta los aspectos metodológicos esenciales													
6. INTENCIONALIDAD	Esta adecuado para valorar las variables de la Hipótesis.													
7. CONSISTENCIA	Se respalda en fundamentos técnicos y/o científicos.													
8. COHERENCIA	Existe coherencia entre los problemas objetivos, hipótesis, variables e indicadores.													
9. METODOLOGÍA	La estrategia responde una metodología y diseño aplicados para lograr probar las hipótesis.													
10. PERTINENCIA	El instrumento muestra la relación entre los componentes de la investigación y su adecuación al Método Científico.													

#### III. OPINIÓN DE APLICABILIDAD

- El Instrumento cumple con los Requisitos para su aplicación
- El Instrumento no cumple con Los requisitos para su aplicación

85
85

#### IV. PROMEDIO DE VALORACIÓN :

85 %
------



Firmado digitalmente por Lima,..... del 2021  
 Freddy Pilpa Alaga  
 Nombre de reconocimiento  
 (DN): cn=Freddy Pilpa Alaga,  
 o=Colegio de Ingenieros del  
 Perú, ou=CIP  
 email=fpilpa@gmail.com  
 c=PE DNI N°..... Telf.:.....  
 Fecha: 2021.11.30 11:41:59  
 -05'00'

**SOLICITUD:** Validación de instrumento de recojo de información.

**Ing. Lucero Castro Tena**

Yo Edson Adrian, Perez Lucas identificados con DNI N°75279548, alumno de la EAP de Ingeniería Ambiental, a usted con el debido respeto me presento y le manifiesto:

Que siendo requisito indispensable el recojo de datos necesarios para la tesis que vengo elaborando titulada: **“Pronóstico de la velocidad del viento para la producción de energía eólica en horizontes temporales utilizando redes neuronales en Tumbes – 2022”**, solicito a Ud. Se sirva validar el instrumento que le adjunto bajo los criterios académicos correspondientes. Para este efecto adjunto los siguientes documentos:

- Ficha de evaluación
- Instrumento
- Matriz de operacionalización de variables

Por tanto:

A usted, ruego acceder mi petición.

Lima, 25 de noviembre del 2021



---

Perez Lucas Edson Adrian

DNI: 75279548

### 3. VALIDACIÓN DE INSTRUMENTO

#### I. DATOS GENERALES

- 1.1. Apellidos y Nombres: Castro Tena Lucero  
 1.2. Cargo e institución donde labora: Universidad César Vallejo  
 1.3. Especialidad o línea de investigación: Gestión y Restauración Ambiental  
 1.4. Nombre del instrumento motivo de evaluación:  
 1.5. Autor(A) de Instrumento:

#### II. ASPECTOS DE VALIDACIÓN

CRITERIOS	INDICADORES	INACEPTABLE						MINIMAMENTE ACEPTABLE			ACEPTABLE			
		40	45	50	55	60	65	70	75	80	85	90	95	100
1. CLARIDAD	Esta formulado con lenguaje comprensible.												x	
2. OBJETIVIDAD	Esta adecuado a las leyes y principios científicos.												x	
3. ACTUALIDAD	Esta adecuado a los objetivos y las necesidades reales de la investigación.												x	
4. ORGANIZACIÓN	Existe una organización lógica.												x	
5. SUFICIENCIA	Toma en cuenta los aspectos metodológicos esenciales												x	
6. INTENCIONALIDAD	Esta adecuado para valorar las variables de la Hipótesis.												x	
7. CONSISTENCIA	Se respalda en fundamentos técnicos y/o científicos.												x	
8. COHERENCIA	Existe coherencia entre los problemas objetivos, hipótesis, variables e indicadores.												x	
9. METODOLOGÍA	La estrategia responde una metodología y diseño aplicados para lograr probar las hipótesis.												x	
10. PERTINENCIA	El instrumento muestra la relación entre los componentes de la investigación y su adecuación al Método Científico.												x	

#### III. OPINIÓN DE APLICABILIDAD

- El Instrumento cumple con los Requisitos para su aplicación
- El Instrumento no cumple con Los requisitos para su aplicación

SI

#### IV. PROMEDIO DE VALORACIÓN :

95%
-----

Lima, ..... del 2021

  
 LUCERO KATHERINE CASTRO TENA  
 DNI: 70837735  
 CIP: 162994

FIRMA DEL EXPERTO INFORMANTE