



## *Redes neuronales en la predicción de la velocidad del viento*

### *Neural networks in predicting wind speed*

### *Redes neurais na previsão da velocidade do vento*

Paulina Fernanda Bolaños-Logroño <sup>I</sup>  
[paulina.bolanos@epoch.edu.ec](mailto:paulina.bolanos@epoch.edu.ec)  
<https://orcid.org/0000-0003-3911-0461>

Jorge Luís Yaulema-Castañeda <sup>II</sup>  
[jorge.yaulema@epoch.edu.ec](mailto:jorge.yaulema@epoch.edu.ec)  
<https://orcid.org/0000-0002-0646-3984>

Oscar Danilo Gaviláñez-Álvarez <sup>III</sup>  
[oscar.gavilanez@epoch.edu.ec](mailto:oscar.gavilanez@epoch.edu.ec)  
<https://orcid.org/0000-0002-7245-5640>

Bolívar Leonardo Ayavaca-Vallejo <sup>IV</sup>  
[byavaca@unach.edu.ec](mailto:byavaca@unach.edu.ec)  
<https://orcid.org/0000-0001-8604-6277>

**Correspondencia:** [paulina.bolanos@epoch.edu.ec](mailto:paulina.bolanos@epoch.edu.ec)

Ciencias técnicas y aplicadas  
Artículo de investigación

\***Recibido:** 19 de marzo de 2020 \***Aceptado:** 27 de abril de 2020 \* **Publicado:** 21 de mayo de 2020

- I. Magíster en Sistemas de Control y Automatización Industrial, Ingeniera en Electrónica y Computación, Tecnóloga en Informática Aplicada, Docente de la Carrera Ingeniería Ambiental en la Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- II. Máster Universitario en Investigación Matemática, Ingeniero Electrónico, Docente de la Carrera Matemáticas en la Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- III. Magíster en Interconectividad de Redes, Ingeniero en Sistemas, Docente de la Carrera Mercadotecnia en la Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- IV. Magíster en Tecnologías para la Gestión y Práctica Docente, Ingeniero en Sistemas Informáticos, Docente de la Carrera Ingeniería en Tecnologías de la información en la Universidad Nacional de Chimborazo, Riobamba, Ecuador.

## Resumen

La necesidad de aumentar la contribución de las energías renovables no convencionales, dentro de la matriz productiva en Ecuador, está aumentando. Este contexto ha llevado a varias instituciones públicas y privadas a emprender proyectos de energía eólica, entre los cuales la Escuela Politécnica de Chimborazo ha emprendido el proyecto de generación de energía eólica, instalando estaciones meteorológicas en diferentes áreas de la provincia de Chimborazo, con el objetivo de analizar la viabilidad del viento. Generación de energía. Sin embargo, el auge de las fuentes de energía renovable en los últimos años ha obligado a un nuevo problema de pronóstico, a saber, saber con tiempo suficiente la energía que podrían generar los futuros parques eólicos. En este contexto, surge la necesidad de contar con herramientas que sean capaces de predecir el comportamiento aleatorio de la velocidad del viento, con un cierto grado de confiabilidad, con el fin de predecir cuánta energía puede entregarse al sistema en un momento dado. El estudio aplicado responde a una investigación exploratoria, con elementos descriptivos y explicativos, que incluye la agrupación de datos históricos, el análisis del comportamiento de la velocidad del viento, a través de técnicas de aprendizaje automático como redes neuronales artificiales no lineales, no lineales y autogestionadas, aplicadas a un conjunto de datos medidos por hora, durante 12 meses consecutivos, de la estación meteorológica de Chimborazo, propiedad de ESPOCH. Los resultados obtenidos mostraron que el uso de ARN en el proceso de predicción es muy eficiente con un nivel de aprendizaje automático del 8% y un nivel de rendimiento medido a través del error cuadrado medio de 0.016 con un horizonte de predicción de setenta y dos horas, lo que permitirá predecir con un alto grado de fiabilidad, la cantidad de energía eólica que se debe tener.

**Palabras claves:** Aprendizaje; automático; viento; error; Matlab; meteorología; potencial; redes neuronales; velocidad; viento.

## Abstract

The need to increase the contribution of non-conventional renewable energies, within the productive matrix in Ecuador, is increasing. This context has prompted several public and private institutions to undertake wind power projects, among which the Chimborazo Polytechnic School has undertaken the wind power generation project, installing meteorological stations in different areas of the province of Chimborazo, with the aim to analyze the viability of wind power

generation. However, the boom in renewable energy sources in recent years has forced a new forecasting problem, namely, to know in sufficient time the energy that could be generated by future wind farms. In this context, the need arises to have tools that are capable of predicting the random behavior of wind speed, with a certain degree of reliability, in order to predict how much energy can be delivered to the system at a given time. The applied study responds to an exploratory research, with descriptive and explanatory elements, which includes the grouping of historical data, wind speed behavior analysis, through automatic learning techniques such as non-linear, non-linear, self-managing artificial neural networks, applied to a set of data measured hourly, for 12 consecutive months, of the Chimborazo meteorological station, property of ESPOCH. The results obtained showed that the use of RNA in the prediction process is very efficient with an automatic learning level of 8% and a performance level measured through the mean square error of 0.016 with a prediction horizon of seventy two hours, which will allow to predict with a high degree of reliability, the amount of wind energy to be.

**Keywords:** Learning; automatic; wind; error; Matlab; meteorology; potential; neural networks; speed.

## Resumo

A necessidade de aumentar a contribuição das energias renováveis não convencionais, dentro da matriz produtiva no Equador, está afetada. Este contexto criou várias instituições públicas e privadas que emprestam projetos de energia eólica, entre os países da Escola Politécnica de Chimborazo, emprestaram o projeto de geração de energia eólica, instalando estações meteorológicas em diferentes áreas da província de Chimborazo, com o objetivo de analisar a viabilidade do ambiente. Geração de energia. Sem embargo, a energia dos combustíveis renováveis nos últimos anos tem afetado um novo problema de pronóstico, um saber, um saber com tempo suficiente para a energia que pode gerar os futuros programas e cristãos. Nesse contexto, aumente a necessidade de contar com hermenientes, se as capacidades sean de predeterminar o comportamento aleatório da velocidade do vento, com uma classe de confiabilidade, com a fin de predecir a quantidade de energia necessária para manter o sistema no momento. O estúdio aplicado responde a uma investigação exploratória, com elementos descritivos e explicativos, que inclui o agrupamento de dados históricos, a análise do comportamento da velocidade do vídeo, uma análise técnica de aprendizagem automática como

redes neuronais artificiais não lineares e lineares e autogestionadas, aplicadas a um conjunto de dados medidos por hora, durante 12 meses consecutivos, da estação meteorológica de Chimborazo, fornecida por ESPOCH. Os resultados obtidos mostram que o uso de ARN no processo de previsão é muito eficiente com um nível de aprendizado automático de 8% e um nível de retorno medido a uma taxa de erro calculada com média de 0,016 e um horizonte de previsão de horas e horas, que pode predeterminar com um alto grau de confiabilidade, a cantina de energia eólica que deve tener.

**Palavras-chave:** Aprendizado; automático; vento; erro; Matlab; meteorologia; potencial; redes neurais; velocidade; vento.

## Introducción

La necesidad de incrementar el aporte de las energías renovables no convencionales, dentro de la matriz productiva en el Ecuador, es cada vez mayor. Este contexto ha promovido que varias instituciones públicas y privadas emprendan proyectos de generación eólica, entre estas, la Escuela Superior Politécnica de Chimborazo ha emprendido el proyecto de generación de energía eólica, instalando estaciones meteorológicas en diferentes zonas de la provincia de Chimborazo, con la finalidad de analizar la viabilidad de generación eólica. Sin embargo el auge que han tenido las fuentes de energía renovables durante los últimos años ha obligado a plantearse un nuevo problema de previsión, el de conocer con antelación suficiente la energía que podrían generar las futuras centrales eólicas.

Conscientes de la necesidad de optimizar la gestión de energías renovables en el país como una estrategia que permita buscar mejores y más eficientes fuentes de generación energética, se plantea un sistema de predicción de la velocidad del viento mediante redes neuronales que permita aprovechar al máximo el potencial que puede producir la energía eólica.

Las directrices mencionadas evidencian los múltiples beneficios de utilizar metodologías innovadoras para la gestión energética como la predicción de la velocidad del viento, que permitirán optimizar los estudios de potencial energético en las diferentes estaciones meteorológicas.

El proyecto propuesto busca, mediante la aplicación de las teorías y los conceptos de energías renovables, modelos predictivos, inteligencia artificial y redes neuronales, encontrar y seleccionar el modelo predictivo más adecuado para el aprendizaje automatizado de la red neuronal, la misma

que aportará en el proceso de estimar con exactitud las curvas de carga originales vs las curvas de predicción realizadas por la red neuronal.

Adicionalmente, se puede indicar que se han realizado estudios relacionados a la predicción de la velocidad del viento utilizando redes neuronales en países como Estados Unidos, México, España, Chile y Colombia entre otros, en el Ecuador existen estudios sobre la utilización de las Redes Neuronales en el campo de la energía eléctrica realizados por la Escuela Politécnica Nacional y CENACE pero no se han registrado publicaciones relacionadas a la predicción de la velocidad de viento mediante RN específicamente, se puede plantear que es un proyecto que pretende contribuir al desarrollo de la matriz energética. Con el diseño de una red neuronal, utilizando Matlab, se pretende crear un modelo de red basada en algoritmos de aprendizaje automatizado que ayude a predecir la velocidad del viento, lo que permitirá elevar el nivel de análisis del potencial energético eólico en la estación meteorológica Chimborazo administrada por el Centro de Investigación de Energías Alternativas y Ambiente de la ESPOCH.

## **Conceptualización**

### **Energías renovables**

Según la Agencia Internacional de la Energía “la energía renovable se deriva de procesos naturales que se reponen constantemente”.

Las tecnologías de energía renovable “son aquellas tecnologías que permiten aprovechar flujos de energía renovable que se reponen constantemente para producir energía eléctrica en formas útiles a la humanidad de un modo sostenible” [1].

### **Energía eólica**

La energía eólica es la que utiliza la fuerza del viento para generar electricidad, para ello utiliza los aerogeneradores, que se encargan de mover una turbina y consiguen transformar la energía cinética del viento en energía mecánica. Es una fuente de energía barata, una energía limpia, no contaminante y es un tipo de energía renovable [2].

Manifiesta que, la energía eólica se obtiene del viento, que mueve aspas conectadas a un generador que lo convierte en energía eléctrica, para que este método funcione, resulta de vital

importancia que los generadores estén ubicados de forma estratégica para aprovechar las corrientes [3].

## Inteligencia artificial

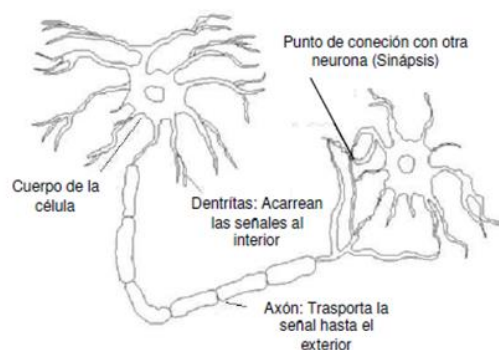
La Inteligencia Artificial (IA) es un área del conocimiento compuesta por un conjunto de técnicas que se basan en imitar computacionalmente las distintas habilidades relacionadas con la inteligencia del ser humano, como, por ejemplo: reconocimiento de patrones, diagnóstico, clasificación, entre otros [4].


## Neurona biológica vs neurona artificial

Según el libro Aprendizaje automático, el elemento básico de una red neuronal es la neurona. Una neurona biológica tiene tres partes principales, véase figura 1 dendritas, el cuerpo de la neurona o soma y el axón. Las dendritas son fibras que transmiten las señales eléctricas al cuerpo de la neurona, que la suma y si el estímulo es lo suficientemente grande (potencial de excitación), el cuerpo de la neurona o soma provocará un estímulo (potencial de acción) que transmitirá el estado de la neurona a las otras neuronas con las que está conectada. Esta conexión se realiza a través de unas largas fibras denominadas axones.

De modo semejante, siguiendo la analogía con la neurona biológica, una neurona artificial se presenta por nodos, el cuerpo de la neurona, donde se realiza la suma de las señales que recibe de otros nodos o neuronas, ver figura 2. El valor obtenido será utilizado para generar una señal que es transmitida a otras neuronas [5].

**Figura 1.** Estructura de una neurona biológica típica



**Figura 2.** Modelo neuronal de mcculloch-pitts

### Clasificación de los modelos neuronales

En función de cómo está constituido el mecanismo de aprendizaje, se clasifican como: redes supervisadas, redes no supervisadas e híbridas. La tabla 1 muestra la clasificación de las RNA.

Las redes supervisadas, necesitan un conjunto de datos de entrada previamente clasificados o cuya respuesta de salida sea conocida. Entre las redes supervisadas se encuentran las que tienen reglas de aprendizaje basadas en la corrección del error, como la regla de retro propagación del error en el caso del Perceptrón y el algoritmo de mínimos cuadrados, muy utilizados en problemas de clasificación y predicción.

Las redes no supervisadas, no tienen un conjunto de datos previamente clasificados y deben encontrar las relaciones que se pueden establecer entre los datos que se presentan en la entrada. La red por sí misma buscará su comportamiento más adecuado atendiendo a cierto criterio y encontrará estructuras o prototipos en el conjunto de patrones de entrenamiento. Como ejemplo tenemos la regla de aprendizaje competitivo no supervisado (utilizada en problemas de agrupación de patrones y obtención de prototipos), la regla de Kohonen (utilizada en reconocimiento e identificación de patrones) y la regla de Hebb.

**Tabla 1.** Clasificación de las RN

SUPERVISADO	UNIDIRECCIONALES	Perceptrón	Rosenblatt	1958
		Adaline	Widrow y Hoff	1960
		Perceptrón Multicapa Backpropagation	Rumelhart, Hinton y Williams	1986
		Correlación en cascada	Fahlman y Lebiere	1990
		Máquina de Boltzman	Ackley, Hinton y Sejnowski	1985
		Learning Vector Quantization	Kohonen	1988
		General Regresión Neural Network	Specht	1991
	RECURRENTES	Recurrent backpropagation	Pineda	1989
		Brain State in a Box	Anderson, Silverstein, Ritz y Jones	1977
		Jordan	Jordan	1986
NO SUPERVISADO	UNIDIRECCIONALES	Neocognitrón	Fukushima, Miyake e Ito; Fukushima	1983; 1988
		Principal Component Analysis	Oja; Hertz	1982; 1991
		Mapa autoorganizado	Kohonen	1982; 1995
	RECURRENTES	Red de Hopfield	Hopfield	1982
		Resonancia Adaptativa (ART)	Carpenter, Grossberg y Rosen	1987; 1990; 1991
		Bidirectional Associative Memory	Kosko	1992
		Radial Basis Funtion	Broomhead y Love; Moody y Darken	1988; 1989
HIBRIDO	Contrapropagación	Hetch-Nielsen	1990	

### Modelos supervisados unidireccionales

Es el grupo más numeroso y el Perceptrón multicapa (MLP) con aprendizaje de retro propagación (BP) es el más importante por su interés histórico, generalidad y por ser el modelo más empleado en las aplicaciones prácticas. El Perceptrón multicapa (MLP), está constituido por una capa de neuronas de entrada, una o más capas de neuronas ocultas y una capa de neuronas de salida. La información se propaga en la red hacia delante, es decir, hacia la salida y constituye una generalización del Perceptrón simple [6].

#### Aprendizaje

Aprendizaje es el proceso de interacción en el cual una persona obtiene nuevas estructuras cognitivas o cambia antiguas ajustándose a las distintas etapas del desarrollo intelectual [7].

El aprendizaje como proceso interno implica para Bruner cuatro momentos o etapas por las cuales un sujeto aprende:



**Predisposiciones:** Constituyen los motivos internos que mueven al sujeto para iniciar y mantener el proceso de aprendizaje.

**Exploración de alternativas:** Constituyen las estrategias internas que, activadas por la predisposición se mantienen en la búsqueda hasta lograr, mediante distintos ensayos descubrir lo que se buscaba.

**Salto intuitivo:** Es un estado, logrado generalmente de manera súbita como resultado del proceso del pensamiento. No es expresable verbalmente, a veces es muy rápido, otras lento, y extendido en el tiempo.

**Refuerzo:** Es el momento en que el que aprende considera valiosos sus hallazgos, válidas sus hipótesis, se corrige y se perfecciona.

### **Aprendizaje automático**

Una metáfora habitual en el área del aprendizaje automático dentro de la Inteligencia Artificial es considerar la resolución de problemas como un tipo de aprendizaje que consiste una vez resuelto un tipo de problema en ser capaz de reconocer la situación problemática y reaccionar usando la estrategia aprendida [8].

El aprendizaje automático, también llamado aprendizaje artificial [9], se dice que un sistema que aprende de forma automatizada (o aprendiz) es un artefacto (o un conjunto de algoritmos) que, para resolver problemas, toma decisiones basadas en la experiencia acumulada en los casos resueltos anteriormente para mejorar su actuación. Estos sistemas deben ser capaces de trabajar con un rango muy amplio de tipos de datos de entrada, que pueden incluir datos incompletos, inciertos, ruido, inconsistencias, etc.

### **Entrenamiento**

Conceptualmente, Sánchez-Bañuelos (1993), desde una perspectiva científica, define al entrenamiento como “una actividad de búsqueda continua de los límites físicos a los que puede llegar el ser humano en el contexto de la competición deportiva, bajo el método científico y el abandono sistemático del método empírico”, lo cual lleva consigo:

Una actitud de duda sistemática y de autocrítica constante y su relación con los procesos cíclicos en el entrenamiento deportivo.

La identificación de los problemas pertinentes y su definición precisa. La formulación tentativa de hipótesis sobre la solución de los mismos.

Los datos empíricos, los procesos de interpretación inductivos y deductivos y el sometimiento a las reglas formales.

### **Metodología del entrenamiento basada en la selección y priorización del trabajo**

El entrenamiento es el procedimiento mediante el cual la red neuronal aprende y el aprendizaje es el resultado final de este proceso. El aprendizaje se realiza a partir de todo el conjunto más que por la aportación individual de cada elemento [6].

El proceso de entrenamiento es normalmente iterativo, actualizándose los pesos una y otra vez hasta que se alcanza el objetivo deseado. Una vez que la red ha sido entrenada se pasa al modo de ejecución o recuerdo, que consiste en mantener fijos los pesos de la red y procesar datos, es decir, la red es capaz de responder ante entradas no vistas con anterioridad.

### **Estación meteorológica**

Manifiesta que, una estación meteorológica es una instalación destinada a medir y registrar regularmente diversas variables meteorológicas mediante los instrumentos meteorológicos, pueden ser convencionales o automáticas [10].

Las estaciones convencionales necesitan de un observador meteorológico, que es una persona calificada para recopilar y transmitir información meteorológica.

Las estaciones automáticas son configuradas para que registren datos en lugares remotos y lo transmitan de manera automatizada.

Los instrumentos meteorológicos pueden ser medidores o registradores, pero el patrón siempre será el que mide, ver tabla 2.

**Tabla 2.** Instrumentos meteorológicos

<b>Instrumentos meteorológicos</b>	
<b>Medidores</b>	<b>Registradores</b>
Pluviómetro	Pluviógrafo
Termómetro	Termohigrógrafo
Veleta	Heliógrafo
Anemómetro	Anemógrafo
Barómetro	Barógrafo
Evaporímetro	
Piranómetro	

### **Instrumental meteorológico convencional y automático**

Los Instrumentos son una herramienta vital en el trabajo meteorológico, el cual nos permite cuantificar parámetros ambientales bajo un convencimiento reglamentado, facilitando la medición, estudio y comparación.

Gracias al uso de estas herramientas, podemos medir distintos fenómenos ambientales, determinar si hay frío o calor, la intensidad y dirección del viento, la visibilidad, etc., los que debido a su carácter numérico son utilizados posteriormente en el análisis, pronóstico y estudio de la ciencia meteorológica.

### **Anemómetro**

El Anemómetro es el instrumento que se utiliza para medir la dirección y la intensidad del viento, por lo tanto posee dos sensores, uno de ellos determina la dirección desde donde proviene el viento, conocido comúnmente como veleta, y el otro consiste en tres semiesferas construidas de un material muy liviano y que al girar permiten obtener la velocidad del viento. La unidad en que se mide la velocidad del viento es el Nudo [11].


**Figura 5.** Anemómetros



### **Termómetro de máxima y de mínima**

Miden el valor máximo y el valor mínimo de la temperatura durante termómetro de Máxima tiene como elemento sensor el mercurio, mientras que el termómetro de Mínima contiene una solución de alcohol y glicerina en donde se halla inmerso un Índice que es el que registra la temperatura más baja.

**Figura 6.** Termómetro



### **Pluviómetro**

Está compuesto por un recipiente colector y parte inferior, ambos de chapa de zinc, con jarro colector y probeta graduada de vidrio o acrílico transparente. El conjunto va montado en un mástil, el que a su vez debe estar situado en un área libre de obstáculos. La unidad de medida es el milímetro, que es equivalente a la altura que alcanzaría un litro de agua vertido en una superficie de 1 metro cuadrado.

**Figura 7.** Pluviómetro



### **Diseño de la investigación**

## Comportamiento de la velocidad del viento en la zona de estudio

Se considera que partir de 10 metros de altura las perturbaciones no afectan de forma notable a la medida de la velocidad del viento, esta puede verse afectada por la presencia de árboles, edificios, colinas y valles existentes a su alrededor [12]. Tomando en consideración estos aspectos, la turbina instalada en la estación meteorológica Chimborazo está libre de obstáculos, dado que una leve turbulencia puede disminuir el rendimiento del aerogenerador que ha futuro sea instalado, ya que una turbina no puede reaccionar a los cambios rápidos en la dirección del viento, y una fuerte turbulencia puede reducir la vida útil de la misma.

Por lo tanto, se debe tomar en consideración que para establecer un sistema de energía eólica se requiere una velocidad media a lo largo del año superior a los 4 m/s, siendo conveniente tener velocidades mayores a la media [13].

Como se menciona en el apartado anterior la estación meteorológica en estudio, ha venido tomando datos de varios años atrás, para este caso se van a considerar el último trimestre del año 2104 y los tres primeros trimestres del año 2015, tomados cada hora, registrados a 10m de altura, además de considerar como ayuda comparativa la escala de Beaufort utilizada para la estimación de la velocidad del viento, ver tabla 3.

**Tabla 1.** Escala Beaufort de fuerza del viento, usada en tierra

Número Beaufort	Descripción	Velocidad del viento [Nudos]	Equivalente [ms <sup>-1</sup> ]	Especificaciones para observaciones sobre suelo firme
0	Calma		0-0.2	Calma, el humo sube verticalmente.
1	Ventolina	1-3	0.3-1.5	Se define la dirección del viento por el humo, pero por veletas.
2	Brisa suave	4-6	1.6-3.3	El viento se siente en la cara; se mueven las hojas de los árboles; el viento mueve las veletas.
3	Brisa leve	7-10	3.4-5.4	Las hojas y ramas pequeñas se hallan en constante movimiento.
4	Brisa moderada	11-16	5.5-7.9	Se levanta polvo y papeles sueltos; se mueven las ramas pequeñas de los árboles.
5	Brisa fresca	17-21	8.0-10.7	Se mueven los árboles pequeños; se forman pequeñas olas en estanques y lagunas.
6	Brisa fuerte	22-27	10.8-13.8	Se mueven las ramas grandes de los árboles; silban los cables telegráficos; los paraguas se utilizan con dificultad.
7	Viento fuerte	28-33	13.9-17.1	Todos los árboles se mueven es difícil caminar contra el viento.
8	Temporal	34-40	17.2-20.7	Se rompen las ramas delgadas de los árboles; generalmente no se puede andar contra el viento.
9	Temporal fuerte	41-47	20.8-24.4	Se producen pequeños daños los edificios, (se caen los sombreros de las chimeneas, las tejas de los techos, etc.)
10	Temporal violento	48-55	24.5-28.4	Se experimenta raramente en violento tierra adentro; se arrancan árboles; se producen considerables daños en los edificios.
11	Temporal muy violento	56-63	28.5-32.6	Se experimenta muy raras veces; ocasiona daños generales por doquier.
12	Huracán	64 y más	32.7 y más	

## **Velocidad media**

### **Último trimestre año 2014**

Para el estudio se calculó la velocidad promedio mes a mes, y como se puede observar en la figura 8, los meses de octubre y noviembre han generado velocidades medias de 5.49 m/s y 6.39 m/s respectivamente, ver tabla 4, que según la escala de Beaufort en este periodo corto se ha generado brisas moderadas en relación a la fuerza del viento, provocando el levantamiento de polvo, hojas y papeles. Sin embargo, en el mes de diciembre se intensifica la fuerza del viento hasta una velocidad promedio de 8.02 m/s produciéndose una brisa fresca con movimientos de árboles pequeños y pequeñas olas en los estanques y lagunas si existieran en el sector. Estos datos contrastan con lo mencionado en el manual del observador de meteorología, confirmando que la velocidad promedio supera los 4m/s necesarios para considerar un sistema de energía eólica.

### **Primer trimestre año 2015**

En este periodo, se puede observar según la tabla 5 y el gráfico 3-2, que la velocidad media aumenta en el mes de enero a un valor aproximado de 11.27 m/s siendo una brisa fuerte la que se genera, con efectos de agitación de ramas grandes, silbido de hilos telegráficos y el uso de paraguas se dificulta, sin embargo, en los dos meses siguientes de baja un nivel en la escala es decir se producen brisas frescas con velocidades promedio de 9.15 y 7.94 m/s respectivamente. Si hacemos una comparación con el último trimestre del año 2014, podríamos decir que el potencial eléctrico a producirse se ve más eficiente y estable en el primer trimestre del 2015, tomando en consideración que a mayor velocidad del viento mayor energía se puede producir.

### **Segundo trimestre año 2015**

En los meses de abril y mayo se observan velocidades promedios de 10.55 y 12.01 m/s, respectivamente, produciéndose brisas frescas y fuertes manteniendo de esta manera la producción de energía eólica estable, sin embargo, en el mes de junio la velocidad promedio se eleva a 18.23 m/s produciendo un estado duro o temporal según la escala utilizada, en donde el viento rompe las ramas, siendo imposible la marcha contra el viento. Lo que indica que la producción de energía eólica en el mes de junio aumentará totalmente.

### Tercer trimestre año 2015

En este periodo la velocidad media se presenta con valores de 13.69, 16.53 y 15.28 m/s, respectivamente, ver gráfico 3-2, efectuándose desde brisas fuertes hasta vientos fuertes, donde también se hace difícil caminar contra el viento, pero más allá de esto, se evidencia que desde el segundo periodo del año es donde se debe aprovechar generando la mayor cantidad de energía eólica ya que sus velocidades son superiores a diferencia del resto del año.

### Octubre año 2015

A diferencia del año anterior en este periodo se eleva la velocidad media a 9.87 m/s en el mes de octubre, pasando de una brisa moderada a una brisa fresca en el 2015, lamentablemente las condiciones meteorológicas tan variables en nuestro planeta nos impiden hacer una estimación más concreta y estable sobre el comportamiento de la velocidad del viento y por ende de la producción de energía eólica. Sin embargo los niveles presentados son óptimos para la viabilidad de un sistema de energía eólica.

**Tabla 2.** Velocidad promedio mensual

Mes	Año	Velocidad/promedio (m/s)
Octubre	2014	5,49
Noviembre	2014	6,39
Diciembre	2014	8,02
Enero	2015	11,27
Febrero	2015	9,15
Marzo	2015	7,94
Abril	2015	10,55
Mayo	2015	12,01
Junio	2015	18,23
Julio	2015	13,69
Agosto	2015	16,53
Septiembre	2015	15,28
Octubre	2015	9,87

**Figura 8.** Comportamiento mensual de la velocidad de viento

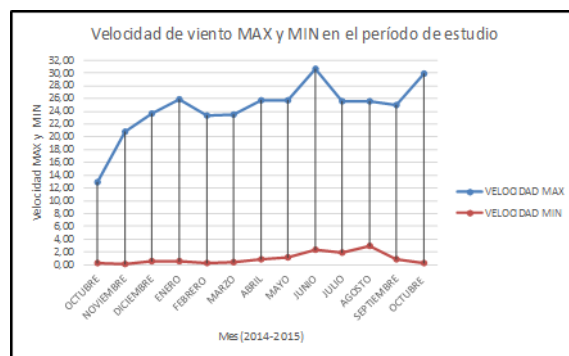


## Velocidad máxima y mínima mensual

**Tabla 3.** Velocidades máximas y mínimas mensuales

Mes	Año	Velocidad	Velocidad
Octubre	2014	12,92	0,19
Noviembre	2014	20,81	0,11
Diciembre	2014	23,65	0,59
Enero	2015	25,91	0,52
Febrero	2015	23,29	0,20
Marzo	2015	23,54	0,46
Abril	2015	25,74	0,86
Mayo	2015	25,76	1,13
Junio	2015	30,61	2,32
Julio	2015	25,59	1,82
Agosto	2015	25,57	2,86
Septiembre	2015	24,91	0,79
Octubre	2015	29,89	0,19

**Figura 9.** Curva de velocidades máximas y mínimas en el período de estudio



La velocidad máxima presentada en el último trimestre del año 2014, se presenta en el mes de diciembre con un valor de 23.65 m/s, contrastando con la velocidad promedio producida en este mes que son las de más alto valor con un temporal fuerte que a diferencia de la velocidad mínima en este periodo se produce en el mes de noviembre con un valor de 0.11 m/s, lo que indica un efecto de total calma.

En el primer periodo del año 2015, la velocidad máxima se produce en el mes de enero con 25.91m/s, experimentándose un temporal violento muy raro en los continentes, donde se producen importantes daños en las viviendas y en la naturaleza misma. Por el contrario la velocidad mínima en este periodo se produce en el mes de febrero con un valor de 0.20 m/s donde se considera calma total.



Para el segundo trimestre su máxima velocidad se genera en junio con 30.61m/s y una velocidad mínima en abril de 0.82m/s, claramente se puede observar que este periodo es en el cual se generan los vientos más fuertes, considerando su módulo que es la máxima velocidad de viento. En este periodo se experimenta un temporal muy violento o también conocido como borrascas el mismo que es observado muy raramente y acompañado de grandes destrozos, para en el mes de abril experimentar una ventolina siendo su mínima velocidad del periodo. En el mes de junio donde se produce un temporal violento se puede observar que va desde una brisa suave hasta llegar al punto máximo ya descrito.

Para el tercer trimestre pasar a un temporal violento en el mes de julio que se presenta la velocidad máxima de 25.59 m/s, es decir baja levemente la intensidad del viento, llegando incluso a efecto ventolina en el mes de septiembre que es donde se genera la mínima velocidad del viento de 0.79 m/s.

Luego en el mes de octubre 2015, se eleva la intensidad a 29.89 m/s donde se puede observar que a diferencia del año anterior la velocidad máxima se duplica es decir que pasa de una brisa fuerte a un temporal violento. Claramente los efectos de la naturaleza son muy impredecibles y mucho menos constantes o repetitivos.

#### Diseño de la red neuronal

Luego de analizar el comportamiento de la velocidad de viento, se debe seleccionar la topología de RNA adecuada para la estimación más certera de la variable en estudio y que además no demore el entrenamiento de la red neuronal, ya que mientras menos entradas tengan el proceso es más óptimo, simple y eficiente para la apropiada implementación en MATLAB.

Un parámetro importante en la selección del modelo es que la predicción se la va a realizar en base a los datos obtenidos del sensor, tomados cada hora, que se resumen en la tabla 6:

**Tabla 4.** Ejemplo de datos tomados del sensor

Date	Time	Vv	Dv	Temp	Pres
18/10/2014	01/01/1900 0:00	5,76	107,15	2,12	609,38
18/10/2014	01/01/1900 1:00	6,03	98,40	1,86	608,76
18/10/2014	01/01/1900 2:00	5,69	88,46	1,25	608,63
18/10/2014	01/01/1900 3:00	5,23	84,04	1,17	608,56
18/10/2014	01/01/1900 4:00	4,64	101,76	1,71	608,52
18/10/2014	01/01/1900 5:00	6,14	83,74	0,89	608,77

Donde:

Vv=velocidad del viento (m/s)

Dv=dirección de viento (grados)

Temp= temperatura

Pres=presión

En la tabla 7, se presentan los datos tomados cada hora en el periodo de octubre 2014 – octubre 2015, en este grupo de datos no se registran valores para la temperatura y presión a excepto del mes de octubre 2014, por lo tanto, estas variables son descartadas ya que son necesarias para el entrenamiento y simulación de la red. Por lo tanto, nos queda a considerar la variable DIRECCION DEL VIENTO (DV), que nos servirá para poder predecir la velocidad de viento de acuerdo a la dirección generada.

**Tabla 5.** Datos tomados cada hora durante el periodo octubre 2014-octubre 2015

Nº	Date	Time	VV	DV
1	18/10/2014	01/01/1900 0:00	5,76	107,15
2	18/10/2014	01/01/1900 1:00	6,03	98,40
3	18/10/2014	01/01/1900 2:00	5,69	88,46
4	18/10/2014	01/01/1900 3:00	5,23	84,04
5	18/10/2014	01/01/1900 4:00	4,64	101,76
6	18/10/2014	01/01/1900 5:00	6,14	83,74
7	18/10/2014	01/01/1900 6:00	5,56	88,24
8	18/10/2014	01/01/1900 7:00	6,81	92,70
9	18/10/2014	01/01/1900 8:00	10,16	106,49
10	18/10/2014	01/01/1900 9:00	9,09	110,00
11	18/10/2014	01/01/1900 10:00	7,48	112,00

En este punto se puede observar que podríamos utilizar también la información del año, mes, día y hora en que fueron tomados los datos. Por tal motivo se realizaron varias topologías con la finalidad de seleccionar el mejor modelo, de las cuales se escogieron dos que presentaron los mejores resultados, sin embargo, se describe a detalle el modelo 2, debido a que el error de este se acerca más a cero.

Variables entrada=año, mes, día y hora

Variable salida=velocidad de viento

Variable entrada=dirección de viento

Variable salida=velocidad de viento

## Topología de la Red

A pesar del desarrollo tecnológico existente en el área de matemática aplicada y métodos de predicción, no se ha llegado a un consenso generalizado sobre cuál es la mejor manera de escoger la mejor topología de red, es decir, el número de capas y el número de neuronas por capas. Basados en esto, el método de “ensayo y error” sigue siendo la herramienta más útil al momento de seleccionarla.

Antes es necesario relacionarnos con el término serie de tiempo que según [14], “El modelado de las series de tiempo ha tomado cada vez más importancia en la investigación debido a la necesidad de contar con mejores herramientas para la toma de decisiones. Las técnicas de redes neuronales han ido mejorando ante tal demanda por ser técnicas de regresión no paramétricas y no lineales y debido a las ventajas que antes mencionamos para la predicción, relativo a otras metodologías, ya que, en general, las series de tiempo tienen un proceso generador de datos de difícil identificación.”

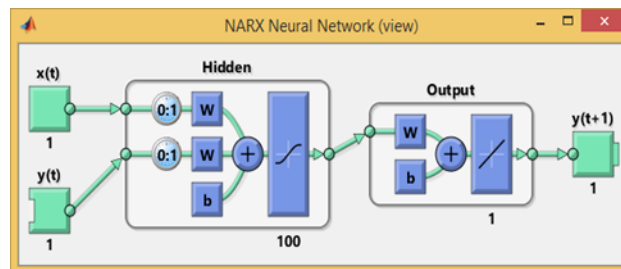
Las series de tiempo pueden presentar patrones regulares como tendencias, ciclos y estacionalidades, e irregularidades como cambios estructurales o días atípicos.

Red neuronal utilizada

NARX.- Nonlinear Autorregresive Network with Exogenous inputs, red autorregresiva no lineal con entradas exógenas o externa. Las redes pueden aprender a predecir una serie de tiempo dado los valores anteriores de la misma serie de tiempo, la entrada de retroalimentación, y otra serie de tiempo, llamado externa o exógena de series de tiempo.

La principal ventaja de la red NARX sobre una red feed-forward es que permite ganar grados de libertad al incluir la predicción de un período como dato en períodos siguientes, resumiendo información de las variables exógenas, permitiendo incluir menos rezagos de las mismas y resumiendo el número de parámetros “a estimar”.

Figura 1. Topología de red NARX, diseñada

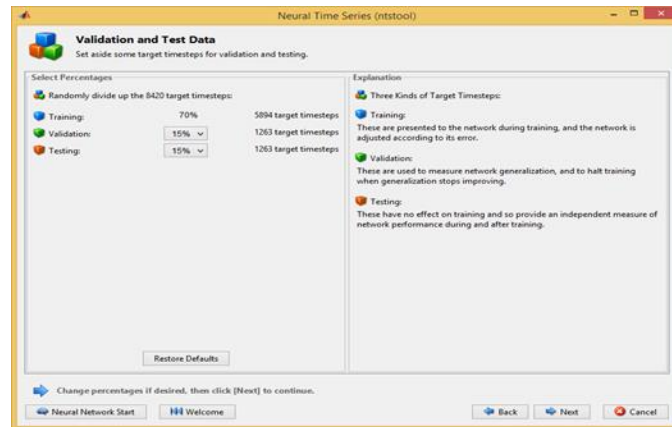


Cuando el feedback loop está abierto en la red neuronal NARX, predice el próximo valor de  $y(t)$  de los valores previos de  $y(t)$  y  $x(t)$  (insumos externos). Cuando el feedback loop está cerrado, la red se puede utilizar para ejecutar predicciones varias pasas hacia adelante. Esto se debe a que las predicciones de la variable dependiente en  $t$ , van a ser usadas en lugar de valores efectivamente futuros de la misma.

### **Número de neuronas en la capa oculta**

El número de neuronas en la capa oculta tiene un alto impacto en el funcionamiento de cualquier topología, mientras más capas ocultas tenga una red, más complejas son las superficies de decisión que pueda formar y por ende mejor precisión se puede obtener al momento de la clasificación o reconocimiento de patrones. Sin embargo, también se puede producir un efecto contrario si se excede con el número de las mismas ya que se puede caer en el efecto de minado de datos de prueba.

**Figura 2.** Número de capas ocultas y neuronas por capa



En figura 11, se puede observar que el modelo tiene una sola capa oculta con 100 neuronas y una sola neurona en la capa de salida. Como se mencionó anteriormente este cálculo se lo realizó utilizando el método de “ensayo y error”, además de considerar que tenemos como entrada un vector de 8420 datos.

“La precisión aumenta a medida que más neuronas son añadidas a la capa oculta” [15], esto fundamenta el uso de las 100 neuronas utilizadas en la topología de red, ya que se fue probando desde 7 hasta llegar al centenar de unidades y se pudo ver el mejor resultado con el número seleccionado.

Cada aumento del número de neuronas, aumenta el tiempo de computación y por ende el consumo de recursos y de lógica en la tarjeta, generándose la necesidad de computadores de alta gama para procesar una topología de red compleja y demasiado grande. Es por ello que en implementaciones normales en computadores secuenciales se limitan dichas neuronas a 100, manteniendo así un excelente compromiso entre precisión en el reconocimiento y requerimientos de computación.

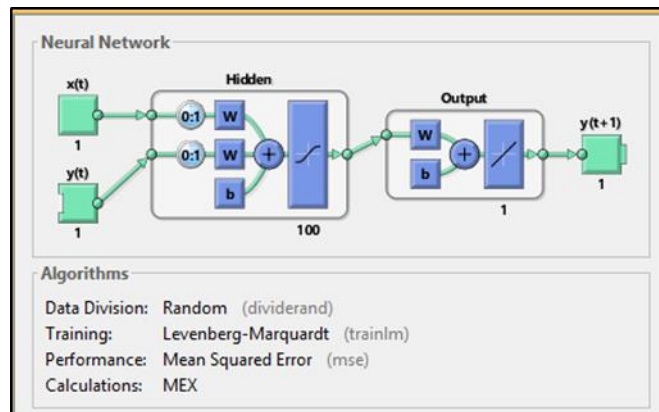
En vista de estas consideraciones, se diseñó una red con tres capas: Una capa de entrada, una capa oculta y una capa de salida.

#### División de Datos

Un aspecto importante en el diseño de la red neuronal es la distribución de los datos tanto para el entrenamiento, validación y test o prueba, según varias investigaciones realizadas sugieren que se opte por 70 -15-15. En la figura 12, se aprecia la distribución de los datos de entrada, 70% para entrenamiento o training, 15% para validación y 15% para prueba o testing. Este proceso tiene el objetivo de verificar la capacidad de generalización de la red para lo cual es necesario disponer

de un grupo de datos independientes de las variables de entrada que no se hayan utilizados en la fase de entrenamiento, y una vez que se obtenga el modelo cuya configuración de parámetros arroje los mejores resultados, estos deberán ser suministrados a la red y observar el comportamiento de los errores de estimación.


**Figura 3.** División de datos, en sus diferentes etapas



### Función de transferencia

Para aprovechar la capacidad de las RNA de aprender relaciones complejas o no lineales entre variables, es absolutamente imprescindible la utilización de funciones no lineales al menos en las neuronas de la capa oculta, en este caso se utilizara la función la función tangente hiperbólica que permite oscilar entre valores positivos y negativos, en el rango de -1 a 1, para la neurona de la capa de salida se emplea la función de activación lineal, que reproduce exactamente el valor resultante después de la sumatoria.

**Figura 4.** Funciones de transferencia o activación de cada capa en la red neuronal



### Aprendizaje de la red

El diseño de una red neuronal implica también dos fases o modos de operación: fase de aprendizaje o entrenamiento, y la fase de operación o ejecución.

En la primera fase, la red entrena para realizar un determinado tipo de procesamiento. Alcanzado un nivel de entrenamiento adecuado, la segunda fase, donde la red es utilizada para llevar a cabo la tarea para la cual fue entrenada, es decir pronosticar o estimar.

Función de entrenamiento o aprendizaje

La definición de aprendizaje se puede tomarse como, “La modificación de comportamiento inducido por la interacción con el entorno y como resultado de experiencias conducente al establecimiento de nuevos modelos de respuesta a estímulos externos. Esta definición fue enunciada muchos años antes de que surgieran las redes neuronales, sin embargo puede ser aplicada también a los procesos de aprendizaje de estos sistemas” [16].

La técnica de optimización numérica que mejor desempeño presentó es Trainlm, (algoritmo Levenberg-Marquardt backpropagation), basado en la matriz Hessiana pero hecha con una aproximación usando la matriz Jacobian.

El algoritmo de Levenberg-Marquardt requiere hacer el almacenamiento de las matrices que con toda seguridad es bastante grande. El tamaño de la matriz de Jacobianos es  $Q \times n$ , donde  $Q$  es que el número de juegos de entrenamiento y  $n$  es el número de pesos y el umbral en la red.

Resulta que esta matriz no tiene que ser computada y guarda en conjunto. Por ejemplo, si se quiere dividir el Jacobiano en dos submatrices iguales que se pueden computar como la matriz aproximada de Hesianos así:

$$H = J^T J = [J_1^T \ J_2^T] \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = J_1^T J_1 + J_2^T J_2 \quad (\text{Ec. 1})$$

El Hesiano aproximado puede ser computado sumando una serie de subterminos. Una vez un subtermino se ha computado pueden aclararse las submatrices correspondientes del Jacobiano.

Cuando se usa la función de entrenamiento trainlm, el parámetro mem\_reduc se usa para determinar cuántas filas del Jacobiano serán computadas en cada submatriz. Si el mem\_reduc toma el valor 1, entonces el Jacobiano lleno se computa y ninguna reducción de memoria se logra. Si el mem\_reduc se pone a 2, entonces sólo la mitad del Jacobiano se computará. Esto ahorra es la mitad de la memoria usada por el cálculo del Jacobiano lleno. La red NARX utiliza por defecto el algoritmo trainlm.

Fase de operación

Finalizada el proceso de aprendizaje, la red puede ser utilizada para realizar la tarea para la predicción. Una de las principales ventajas que posee este modelo es que la red aprende la relación existente entre los datos, adquiriendo la capacidad de generalizar conceptos. De esta manera, una red neuronal puede tratar con información que no le fue presentada durante de la fase de entrenamiento.

### Medidas de Desempeño

Para una serie de tiempo el error de predicción se define como la diferencia entre el valor real de dicha serie en un instante  $t+k$ , y el valor estimado por el modelo para ese mismo instante  $t+k$ . Por lo tanto, el error de predicción para un determinado instante futuro se define como:

$$e(t+k|t) = V(t+k|t) - V'(t+k|t) \quad (\text{Ec. 2})$$

A diferencia del error de predicción que se utiliza para un instante en particular, existen medidas de desempeño que permiten un análisis cuantitativo del modelo de predicción para todas las estimaciones obtenidas [21]. En este trabajo se utilizan el MSE.

### Error Cuadrático Medio (MSE)

Para un horizonte de predicción de  $k$  pasos, el error cuadrático medio (Mean Square Error) se define como:

$$MSE(k) = \frac{1}{k} \sum_{i=1}^k e(t+k|t)^2 \quad (\text{Ec. 3})$$

$$MSE(k) = \frac{1}{k} \sum_{i=1}^k V(t+k|t) - V'(t+k|t) \quad (\text{Ec. 4})$$

Podemos calcular el error de una predicción como la diferencia entre el valor actual de la predicción y el valor real que se produce. Donde  $e$ , es el error en la predicción, en el periodo  $t$ ,  $V$  es el valor actual en el periodo  $t$ , y  $V'$  es la predicción en el periodo  $t$ .

### Preproceso y postproceso

Con la finalidad de alcanzar una red neuronal más eficaz se realizan ciertos pasos en el preproceso de las entradas y los objetivos o salidas de la red, esto mediante las funciones siguientes. Antes de entrenar, es útil escalar las entradas y targets (salidas deseadas) para que siempre estén dentro de un rango específico. La función `premnmx` puede usarse para escalar las entradas y objetivos para que queden en el rango  $[-1,1]$ .

$$[pn, minp, maxp, tn, mint, maxt] = \text{premnmx}(xx, tt);$$



Donde:

pn = valor normalizado de la entrada

tn = valor normalizado de target o salida

minp y maxp = valores mínimos y máximos de las entradas originales

mint y maxt = valores mínimos y máximos de las salidas o targets

xx = vector o matriz de entrada

tt = vector o matriz de salida

Se dan las entradas y objetivos originales de la red en matrices xx y tt, pn y tn que devuelven todos a caer en el intervalo [-1,1]. El minp de los vectores y maxp que contienen el mínimo y el máximo valor de las entradas originales y los vectores, los maxt que contienen el mínimo y el máximo valor de los objetivos originales.

Después que la red ha sido entrenada, estos vectores deben usarse para convertir cualquier entrada futura que se aplica a la red.

Para convertir estos resultados en las mismas unidades que se usaron para los objetivos originales, usamos el comando postmnmx.

$A = \text{postmnmx}(q, \text{mint}, \text{maxt});$

Luego de entrenar la red se genera datos de salida que en este caso se almacenan en la variable q y se combina con el min y max del vector salida o target, para convertir los datos estimados en las mismas unidades de los datos originales.

El rendimiento de la red corresponde al tn de las salidas normalizadas. El rendimiento de la red in-normalizado está en las mismas unidades como los objetivos originales t.

### **Análisis de resultados**

El entrenamiento de la red se la realizo con 8420 datos correspondientes al periodo del 18 de octubre 2014 al 31 de octubre 2015, y los parámetros para establecer el valor óptimo de la red a través del método de ensayo y error:

Numero de interacciones o épocas: con la finalidad de reducir el error cuadrático medio, a partir de las 12 interacciones, las aportaciones de estas son despreciables.

Numero de neuronas en la capa oculta: como se mencionó en el apartado anterior, 100 neuronas fueron necesarias para llegar a un valor óptimo del mse (error cuadrático medio), tomando en consideración el número de datos y la dispersión que existe entre cada dato, todo este proceso mediante prueba y error.

Tasa de aprendizaje: la tasa óptima para un buen aprendizaje de la red, se estableció en nuestro caso en 0.8.

Momento: valor óptimo de 0.95.

Algoritmo de aprendizaje: función de entrenamiento trainlm (algoritmo de levenberg marquart back propagation), este es el método de aprendizaje más relevante para la optimización de la red.

Predicciones

Culminada la etapa de entrenamiento, se puede asumir que la red ha sido capaz de aprender las relaciones entre los datos presentados, por lo tanto, la red está lista para predecir.

La predicción se puede realizar de dos maneras:

Con datos conocidos por la red, es decir datos que fueron utilizados en el entrenamiento.

Con datos desconocidos por la red, nunca utilizados en el entrenamiento.

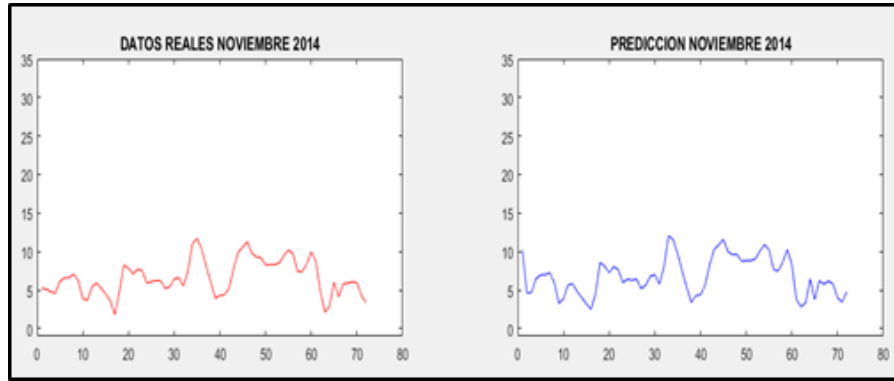
Predicción con datos conocidos por la red – horizonte de predicción 3 tres días

En este caso de los 8420 datos de entrenamiento, se tomaron como entradas los 3 primeros días del mes de noviembre del 2014, con la variable dirección del viento, es decir 72 datos ya conocidos por la red, ver tabla 8 y gráfica 14.

**Tabla 8.** Valores óptimos de entrenamiento – horizonte de tres días

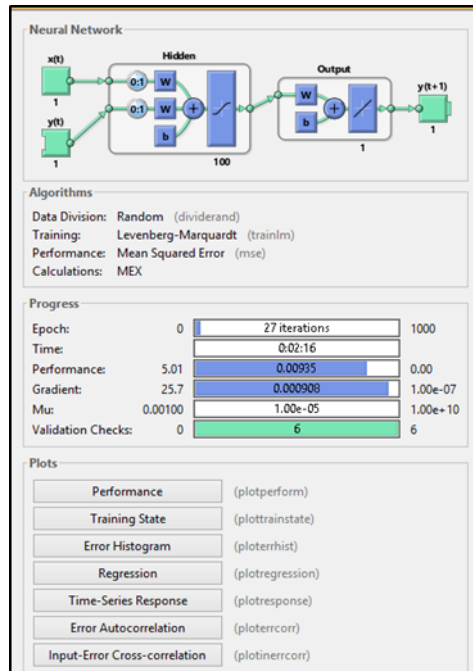
<b>Valores óptimos de los parámetros del</b>	
<b>Observaciones</b>	72
<b>Iteraciones o épocas</b>	21
<b>Neuronas ocultas</b>	100
<b>Tasa de aprendizaje</b>	0.8
<b>Momento</b>	0.95
<b>Algoritmo de aprendizaje</b>	trainlm
<b>Error cuadrático medio o</b>	0.0098

**Figura 14.** Entrenamiento de la red – horizonte de tres días



En la gráfica 15, curva de carga original vs curva de predicción de los tres primeros días del mes de noviembre del 2014, se puede observar que la red neuronal reproduce con gran precisión la curva de carga original, con lo que se puede asumir que el entrenamiento ha sido completamente satisfactorio.

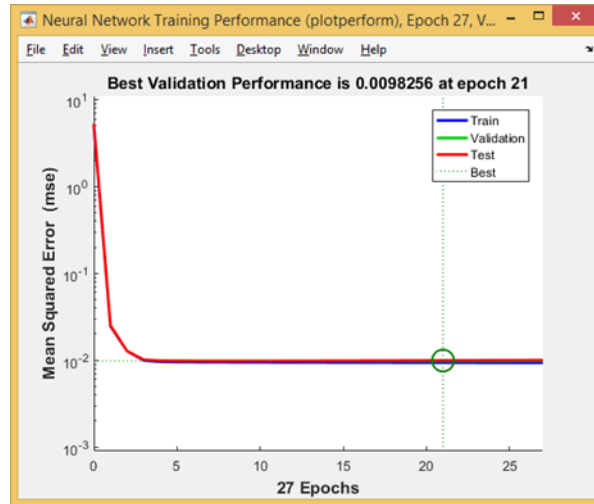
**Figura 15.** Curva de carga original vs curva de predicción, tres primeros días noviembre 2014- datos conocidos



Esto se puede corroborar en la gráfica 14, parámetros de entrenamiento en donde se puede observar el performance en 0.0098 es decir tiende a cero, y eso es lo que garantiza que la

predicción sea confiable, sin embargo, en gráfico 16, se puede observar que el mejor valor del performance en la etapa de entrenamiento, validación y test se da en la época 21.

**Figura 16.** Mejor performance entrenamiento, validación y test




Predicción con datos desconocidos por la red - horizonte de predicción 3 tres días

En este caso se hizo el mismo procedimiento que el anterior a diferencia que los datos de entrada fueron desconocidos por la red, ya que nunca se proporciona a la red para su entrenamiento. De tal manera que obtuvieron los siguientes resultados:

Datos de entrada: los tres primeros días de noviembre 2015, variable dirección del viento, igual 72 datos.

Se puede observar en la gráfica 17, la reproducción casi exacta de la curva de carga original vs la curva de predicción, dando un mse o performance de 0.38, siendo clara la diferencia de error cuadrático medio entre datos conocidos y datos que no han sido utilizados en la red.

**Figura 17.** Curva de carga original vs curva de predicción, 1-3 noviembre 2015 – datos desconocidos por la red



A pesar de manejar los mismos parámetros de entrenamiento, se puede observar que el error se incrementa debido a que existen más de mil datos que la red nunca los conoció, es decir no se entrenó con estos, lo que hace presumir que la predicción sería más cercana con datos conocidos. Sin embargo, en cada simulación los pesos de la red se actualizan y se entrenan cada vez mejor para que el aprendizaje se mantenga y además el error no tenga cambios bruscos.

Predicción con datos desconocidos por la red – horizonte de predicción dos meses

Los parámetros de entrenamiento para este horizonte son los mismos utilizados en el apartado anterior:

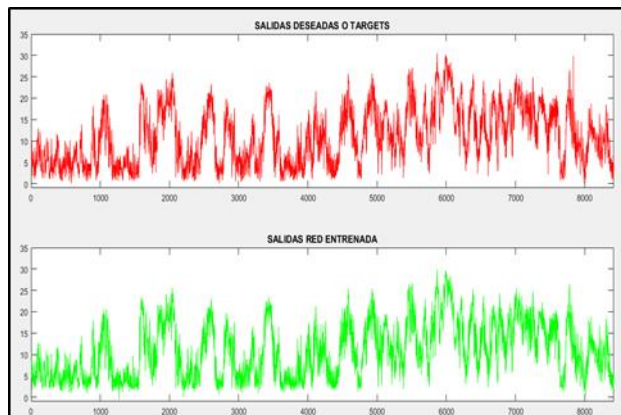
**Tabla 9.** Valores óptimos de entrenamiento – horizonte de dos meses

Valores óptimos de los parámetros del entrenamiento.	
Observaciones	720 c/m
Iteraciones o épocas	12
Neuronas ocultas	100
Tasa de aprendizaje	0.8
Momento	0.95
Algoritmo de aprendizaje	trainlm

En este caso los datos a simular cambian y se amplían a 1440 datos, es decir 720 datos por cada mes predecir, en el ejemplo se van a estimar las velocidades de viento de los meses de noviembre y diciembre 2015, datos que la red no conoce puesto que el entrenamiento se lo hizo con datos hasta octubre del 2015, por lo tanto, es un gran reto simular para un horizonte más grande y comprobar la eficacia tanto del modelo matemático como del diseño de la red neuronal.

Los resultados obtenidos son los siguientes:

**Figura 18.** Datos originales vs datos estimados etapa entrenamiento

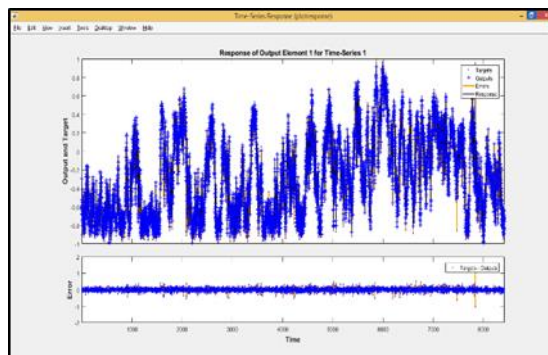


En referencia a la figura 18, se muestran los resultados del entrenamiento y las gráficas muestran gran similitud entre la carga original y la predicción, luego podemos observar que el plotresponse entre los datos de salida y los originales tienen gran coincidencia. Los puntos representan las salidas originales o targets y los + representan las salidas de la red, ver gráfica 19.

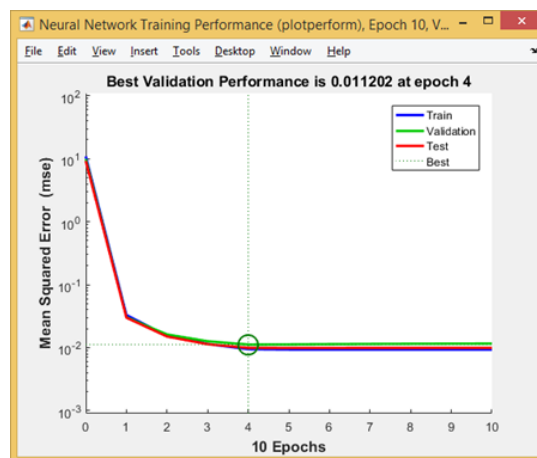
Para luego observar la gráfica 20, del performance generado en el entrenamiento de esta serie, que es de 0.001 en la cuarta época o iteración.

Lo que nos indica que el aprendizaje de la red cumple con las expectativas y que además no necesita mucho tiempo a diferencia del otro modelo.

**Figura 19.** Plotresponse targets vs output

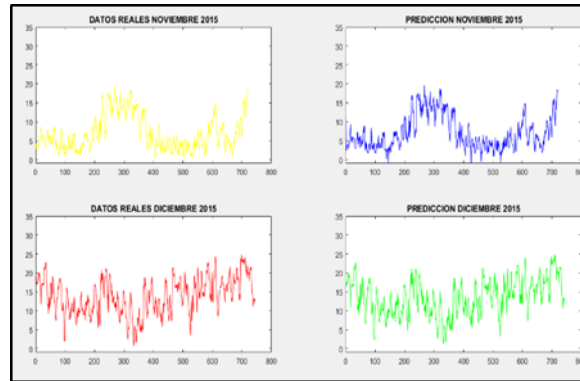


**Figura 20.** Plotperform entrenamiento, validación y test



Luego podemos ver el cálculo del mse, generado ya en la simulación de los dos meses a predecir, que nos da un valor de 0.0169 y que además se puede verificar con la gráfica que relaciona las curvas originales vs los dos meses a predecir, ver gráfica 21.


**Figura 21.** Curvas de carga originales vs curvas de predicción de dos meses- datos desconocidos



Se puede observar que tanto el mes de noviembre como el mes de diciembre estimados por la red neuronal, reproducen las curvas originales con exactitud, esto corrobora lo dicho anteriormente y más aún el error cuadrático medio de 0.016 que estaría alrededor de 1.6%, un valor que en estimaciones de variables meteorológicas es considerado como muy bueno.

Como complemento a estos resultados tenemos también el plotresponse entre las salidas originales y las salidas estimadas, donde los puntos (targets) deben coincidir con los signos + (estimaciones), dando a entender que existe una coincidencia entre estas variables, además se entiende claramente que la variable independiente dirección del viento incide en la variable dependiente velocidad del viento, ver gráfica 22.

**Figura 22.** Respuesta de relación entre los targets y las salidas estimadas



## Conclusiones

La variable meteorológica más influyente en nuestro modelo es la dirección del viento, puesto que luego de varias pruebas fue la que mejor resultados demostró y siendo la variable que mejor explica el comportamiento de la velocidad de viento.

El modelo de red neuronal más adecuado para la predicción de la velocidad de viento tomando en consideración las características e información de la estación en estudio, es la red autoregresiva no lineal con entradas exógenas (NARX).

En la implementación del modelo neuronal, mientras más datos se puedan disponer para el entrenamiento de la red, más eficiente será el aprendizaje de la red y por ende la predicción será más cercana y con horizontes más amplios.

La red neuronal diseñada ha sido capaz de predecir un horizonte de 72 horas, sin conocer previamente las salidas deseadas o targets, con una exactitud del 98.4%.

## Referencias

1. G. Boyle, J. Bushnell y K. Gillingham, *Electricidad Verde*, Madrid: Marcial Pons, 2010.
2. M. Ouanani, *Predicción de la energía eólica utilizando técnicas de aprendizaje automático*, Madrid, 2015.
3. N. Vaughn , *Wind Energy: Renewable Energy and the Environment*, Second Edition, NW: CRC Press, 2013.
4. M. G. Cortina Januchs, *Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos*, Madrid, 2012.
5. G. Pajares y J. De la Cruz, *Aprendizaje automático*, Bogotá: Ra - ma, 2011.
6. P. López Álvarez, R.Velo Sabín y F. Maseda Eimil, «<http://www.aepro.com>,» Septiembre 2007. [En línea]. Available: [http://www.aepro.com/files/congresos/2007lugo/ciip07\\_1083\\_1092.501.pdf](http://www.aepro.com/files/congresos/2007lugo/ciip07_1083_1092.501.pdf).
7. J. Bruner, *El proceso mental en el aprendizaje*, Madrid: Narcea, S. A, 2001.
8. Antonio Moreno y otros, *Aprendizaje automático*, Barcelona: Edicions UPC, 1994, p. 22.
9. E. Plaza, «Tendencias en Inteligencia Artificial: hacia la cuarta década,» de *Nuevas tendencias en Inteligencia Arti*, Universidad de Deusto, 1992, p. 379.
10. B. Malvé, «Foro climático Nacional Napo – Tena situación meteorológica,» Quito, 2014.



11. Unidad de ciencias de la atmósfera, «Departamento de Ciencias de la Atmósfera,» 2014. [En línea]. Available: [www.meteo.fisica.edu.uy/Materias/climatologia/.../Instrumentos%20Meteorologicos.pdf](http://www.meteo.fisica.edu.uy/Materias/climatologia/.../Instrumentos%20Meteorologicos.pdf).
12. O. Barajas, «Arman robot inspector de líneas eléctricas,» Electrónicos online, 2010.
13. AIN, REE, «Proyecto Pelicano,» hisparob, 2004.
14. L. M. Checa, Líneas de Transporte de Energía, 2006.
15. Coppeliarobotics, «V-REP Create, compose, simulate, any robot,» 29 Agosto 2016. [En línea]. Available: [www.coppeliarobotics.com](http://www.coppeliarobotics.com).
16. D. Elizondo, «Overview of Robotic Applications for Energized Transmission Line Work –Technologies, Field Projects and Future Developments,» 1st International Conference on Applied Robotics for the Power, 2010.
17. R. S. Gonçalves, «Review and latest trends in mobile robots used on power transmission lines. International Journal of Advanced Robotic Systems,» pp. 10(12), 408., 2013.
18. N. Pouliot, «LineScout Technology Opens the Way to Robotic Inspection and Maintenance of High-Voltage Power Lines,» IEEE, 2015.
19. R. Aracil, «ROBTET: A new teleoperated system for live-line,» Proceedings of the 7th International Conference on Transmission and Distribution Construction and Live Line Maintenance, pp. 205-211, 1995.
20. W. Wei, «The Mechanism of a Snake-Like Robot's Clamping Obstacle Navigation on High Voltage Transmission Lines,» International Journal of Advanced Robotic Systems, 2013.
21. CONELEC, «Informe estadístico sector eléctrico ecuatoriano,» 2010.
22. M. I. Armendáriz, «Riesgos en el mantenimiento de instalaciones de alta tensión en tensión y la aplicación del RD 614/2001,» 2015.
23. P. Debenest, «Expliner – Robot for Inspection of Transmission Lines,» IEEE International Conference on, 2008.

## References

1. G. Boyle, J. Bushnell and K. Gillingham, Electricidad Verde, Madrid: Marcial Pons, 2010.
2. M. Ouanani, Prediction of wind energy using machine learning techniques, Madrid, 2015.

3. N. Vaughn, *Wind Energy: Renewable Energy and the Environment*, Second Edition, NW: CRC Press, 2013.
4. M. G. Cortina Januchs, *Application of artificial intelligence techniques to the prediction of air pollution*, Madrid, 2012.
5. G. Pajares and J. De la Cruz, *Machine Learning*, Bogotá: Rama, 2011.
6. P. López Álvarez, R. Velo Sabín and F. Maseda Eimil, «<http://www.aepro.com>,» September 2007. [Online]. Available: [http://www.aepro.com/files/congresos/2007lugo/ciip07\\_1083\\_1092.501.pdf](http://www.aepro.com/files/congresos/2007lugo/ciip07_1083_1092.501.pdf).
7. J. Bruner, *The mental process in learning*, Madrid: Narcea, S. A, 2001.
8. Antonio Moreno et al., *Machine Learning*, Barcelona: Edicions UPC, 1994, p. 22.
9. E. Plaza, «Trends in Artificial Intelligence: towards the fourth decade,» of *New Trends in Artificial Intelligence*, University of Deusto, 1992, p. 379.
10. B. Malvé, «Napo National Weather Forum - Tena meteorological situation,» Quito, 2014.
11. Atmospheric Sciences Unit, «Department of Atmospheric Sciences,» 2014. [Online]. Available: [www.meteo.fisica.edu.uy/Materias/climatologia/.../Instrumentos%20Meteorologicos.pdf](http://www.meteo.fisica.edu.uy/Materias/climatologia/.../Instrumentos%20Meteorologicos.pdf).
12. O. Barajas, «Arman robot inspector of electrical lines,» Electronic online, 2010.
13. AIN, REE, "Pelican Project," Hisparob, 2004.
14. L. M. Checa, *Energy Transportation Lines*, 2006.
15. Coppeliarobotics, «V-REP Create, compose, simulate, any robot,» August 29, 2016. [Online]. Available: [www.coppeliarobotics.com](http://www.coppeliarobotics.com).
16. D. Elizondo, «Overview of Robotic Applications for Energized Transmission Line Work –Technologies, Field Projects and Future Developments,» 1st International Conference on Applied Robotics for the Power, 2010.
17. R. S. Gonçalves, «Review and latest trends in mobile robots used on power transmission lines. *International Journal of Advanced Robotic Systems*, »pp. 10 (12), 408., 2013.
18. N. Pouliot, "LineScout Technology Opens the Way to Robotic Inspection and Maintenance of High-Voltage Power Lines," IEEE, 2015.
19. R. Aracil, "ROBTET: A new teleoperated system for live-line," *Proceedings of the 7th International Conference on Transmission and Distribution Construction and Live Line Maintenance*, pp. 205-211, 1995.

20. W. Wei, "The Mechanism of a Snake-Like Robot's Clamping Obstacle Navigation on High Voltage Transmission Lines," International Journal of Advanced Robotic Systems, 2013.
21. CONELEC, «Statistical Report on the Ecuadorian Electricity Sector,» 2010.
22. M. I. Armendáriz, «Risks in the maintenance of high voltage installations in tension and the application of RD 614/2001,» 2015.
23. P. Debenest, "Expliner - Robot for Inspection of Transmission Lines," IEEE International Conference on, 2008.

## Referências

1. G. Boyle, J. Bushnell e K. Gillingham, Electricidad Verde, Madri: Marcial Pons, 2010.
2. M. Ouanani, Previsão de energia eólica usando técnicas de aprendizado de máquina, Madri, 2015.
3. N. Vaughn, Energia Eólica: Energia Renovável e Meio Ambiente, Segunda Edição, NW: CRC Press, 2013.
4. M. G. Cortina Januchs, Aplicação de técnicas de inteligência artificial à previsão de poluição do ar, Madri, 2012.
5. G. Pajares e J. De la Cruz, Machine Learning, Bogotá: Rama, 2011.
6. P. López Álvarez, R. Velo Sabín e F. Maseda Eimil, «<http://www.aepro.com>», setembro de 2007. [Online]. Disponível: [http://www.aepro.com/files/congresos/2007lugo/ciip07\\_1083\\_1092.501.pdf](http://www.aepro.com/files/congresos/2007lugo/ciip07_1083_1092.501.pdf).
7. J. Bruner, O processo mental na aprendizagem, Madri: Narcea, S. A, 2001.
8. Antonio Moreno et al., Machine Learning, Barcelona: Edicions UPC, 1994, p. 22)
9. E. Plaza, «Tendências em Inteligência Artificial: rumo à quarta década», de Novas Tendências em Inteligência Artificial, Universidade de Deusto, 1992, p. 379
10. B. Malvé, «Fórum Meteorológico Nacional de Napo - Situação meteorológica de Tena», Quito, 2014.
11. Unidade de Ciências Atmosféricas, «Departamento de Ciências Atmosféricas», 2014. [Online]. Disponível: [www.meteo.fisica.edu.uy/Materias/climatologia/.../Instrumentos%20Meteorologicos.pdf](http://www.meteo.fisica.edu.uy/Materias/climatologia/.../Instrumentos%20Meteorologicos.pdf).
12. O. Barajas, «inspetor robô Arman de linhas elétricas», Electronic online, 2010.
13. AIN, REE, "Projeto Pelican", Hisparob, 2004.

14. L. M. Checa, *Linhas de Transporte de Energia*, 2006.
15. Coppeliarobotics, «V-REP Crie, componha, simule qualquer robô», 29 de agosto de 2016. [Online]. Disponível: [www.coppeliarobotics.com](http://www.coppeliarobotics.com).
16. D. Elizondo, «Visão geral das aplicações robóticas para o trabalho na linha de transmissão energizada - tecnologias, projetos de campo e desenvolvimentos futuros» »1ª Conferência Internacional sobre Robótica Aplicada à Energia, 2010.
17. R. S. Gonçalves, «Revisão e últimas tendências em robôs móveis usados em linhas de transmissão de energia. *Revista Internacional de Sistemas Robóticos Avançados*, »pp. 10 (12), 408., 2013.
18. N. Pouliot, "A tecnologia LineScout abre caminho para a inspeção e manutenção robótica de linhas de alta tensão", IEEE, 2015.
19. R. Aracil, "ROBTET: Um novo sistema teleoperado para linha viva", *Anais da 7ª Conferência Internacional sobre Construção de Transmissão e Distribuição e Manutenção de Linha Viva*, pp. 205-211, 1995.
20. W. Wei, "O Mecanismo da Navegação por Obstáculos de Fixação de Robôs Parecidos com Cobras em Linhas de Transmissão de Alta Tensão", *International Journal of Advanced Robotic Systems*, 2013.
21. CONELEC, «Relatório Estatístico do Setor Elétrico Equatoriano», 2010.
22. M. I. Armendáriz, «Riscos na manutenção de instalações de alta tensão em tensão e aplicação do RD 614/2001», 2015.
23. P. Debenest, "Expliner - Robô para Inspeção de Linhas de Transmissão", IEEE International Conference on, 2008.

©2020 por el autor. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).