



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO

PREDICCIÓN DE LA VELOCIDAD DEL VIENTO MEDIANTE REDES NEURONALES, PARA LA ESTACIÓN METEOROLÓGICA CHIMBORAZO

PAULINA FERNANDA BOLAÑOS LOGROÑO

Trabajo de Titulación modalidad: Proyectos de Investigación y Desarrollo, presentado ante el Instituto de Postgrado y Educación Continua de la ESPOCH, como requisito parcial para la obtención del grado de:

**MAGISTER EN SISTEMAS DE CONTROL Y AUTOMATIZACIÓN
INDUSTRIAL**

Riobamba – Ecuador

Marzo 2018

ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO

CERTIFICACIÓN:

EL TRIBUNAL DE TRABAJO DE TITULACIÓN CERTIFICA QUE:

El Trabajo de Titulación modalidad Proyectos de Investigación y Desarrollo, denominado: **“PREDICCIÓN DE LA VELOCIDAD DEL VIENTO MEDIANTE REDES NEURONALES, PARA LA ESTACIÓN METEOROLÓGICA CHIMBORAZO”**, de responsabilidad de la Ing. Paulina Fernanda Bolaños Logroño, ha sido prolijamente revisado y se autoriza su presentación.

Tribunal:

ING. WILSON ZÚÑIGA VINUEZA, Mgs.
PRESIDENTE

FIRMA

ING. XAVIER GAVILÁNEZ CARRIÓN, Mgs.
DIRECTOR DE TESIS

FIRMA

ING. FERNANDO MEJÍA PEÑAFIEL, Mgs.
MIEMBRO DEL TRIBUNAL

FIRMA

DR. RIGOBERTO MUÑOZ CARGUA, Mgs.
MIEMBRO DEL TRIBUNAL

FIRMA

Riobamba, Marzo 2018

DERECHOS INTELECTUALES

Yo, Paulina Fernanda Bolaños Logroño, soy responsable de las ideas, doctrinas y resultados expuestos en este **Trabajo de Titulación modalidad Proyectos de Investigación y Desarrollo**, y que el patrimonio intelectual generado por la misma pertenece a la Escuela Superior Politécnica de Chimborazo.

PAULINA FERNANDA BOLAÑOS LOGROÑO

No. Cédula: 060318437-5

©2018, Paulina Fernanda Bolaños Logroño.

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento, siempre y cuando se reconozca el Derecho de Autor.

DEDICATORIA

A Gaby, Cristian, Iván y Diego.

AGRADECIMIENTO

A mi hija Gaby, sobrinos, padres y hermanos quienes han sido fuente de paciencia, tolerancia, y apoyo incondicional en el camino transcurrido para cumplir con este objetivo.

Al Centro de Investigación de Energías Alternativas y Ambiente de la ESPOCH, por el apoyo y facilidades en el desarrollo de este proyecto.

A mi tutor y miembros del tribunal, por el apoyo brindado, y sobre todo por sus conocimientos compartidos.

Paulina

INDICE DE CONTENIDOS

RESUMEN.....	xiv
SUMMARY	xv

CAPITULO I

1.	INTRODUCCIÓN	1
1.1.	Antecedentes.....	1
1.2.	Problema de investigación	2
1.3.	Formulación del problema.....	3
1.4.	Sistematización del problema	3
1.5.	Justificación de la investigación	4
1.6.	Objetivos de la investigación.....	6
1.6.1.	<i>Objetivo general</i>	6
1.6.2.	<i>Objetivos específicos</i>	6
1.7.	Hipótesis	6

CAPITULO II

2.	MARCO REFERENCIAL.....	7
2.1.	Estado del arte	7
2.2.	Estaciones meteorológicas.....	9
2.2.1.	<i>Tipos de estaciones meteorológicas</i>	9
2.2.2.	<i>Instrumental meteorológico convencional y automático</i>	11
2.2.3.	<i>Anemómetro</i>	11
2.2.4.	<i>Termómetro de máxima y de mínima</i>	12
2.2.5.	<i>Pluviómetro</i>	12
2.3.	Energías renovables.....	13
2.3.1.	<i>Energía eólica</i>	13
2.3.1.1	<i>Viento</i>	14
2.4.	Inteligencia artificial.....	14
2.4.1.	<i>Neurona Biológica</i>	14
2.4.2.	<i>Redes neuronales artificiales</i>	15
2.4.3.	<i>Aprendizaje automático</i>	17
2.4.4.	<i>Neurona biológica vs neurona artificial</i>	17
2.4.5.	<i>Funcionamiento de una red neuronal</i>	18

2.4.6.	<i>Arquitectura de una red neuronal</i>	19
2.4.7.	<i>Topología de la Red</i>	21
2.4.8.	<i>Función de entrenamiento o aprendizaje</i>	22
2.4.9.	<i>Número de neuronas en la capa oculta</i>	23
2.4.10.	<i>Entrenamiento, aprendizaje y ejecución</i>	24
2.4.11.	<i>Clasificación de los modelos neuronales</i>	25
2.4.11.1.	Modelos supervisados unidireccionales	26
2.4.11.2.	Red NARX.....	26
2.5.	Software a utilizar	27
2.6.	Metodología para el desarrollo de la predicción de velocidad de viento.	29

CAPITULO III

3.	DISEÑO DE LA INVESTIGACIÓN	31
3.1.	Situación actual de la estación meteorológica Chimborazo.....	31
3.1.1.	<i>Ubicación.</i>	31
3.1.2.	<i>Descripción.</i>	32
3.1.3.	<i>Equipamiento</i>	32
3.1.4.	<i>Metodología utilizada para el estudio del potencial energético</i>	33
3.2.	Comportamiento de la velocidad del viento en la zona de estudio.....	34
3.4.1.	<i>Velocidad media</i>	35
3.4.2.	<i>Velocidad máxima y mínima</i>	38
3.4.3.	<i>Velocidad promedio cada 3 horas</i>	40
3.4.4.	<i>Velocidad promedio cada 6 horas</i>	43
3.5.	Diseño de la red neuronal.....	44
3.5.1.	<i>Número de neuronas en la capa oculta</i>	45
3.5.2.	<i>División de Datos</i>	46
3.5.3.	<i>Función de transferencia</i>	47
3.5.4.	<i>Aprendizaje de la red</i>	48
3.5.5.	<i>Fase de operación</i>	48
3.5.6.	<i>Medidas de Desempeño</i>	48
3.5.7.	<i>Error Cuadrático Medio (MSE)</i>	48
3.6.	Preproceso y Postproceso.....	49
3.7.	Implementación	50
3.7.1.	<i>Pre- procesamiento de datos</i>	51
3.7.2.	<i>Creación de la red</i>	52
3.7.3.	<i>Distribución del conjunto de datos</i>	52

3.7.4.	<i>Pesos y Bias</i>	53
3.7.5.	<i>Aprendizaje</i>	53
3.7.6.	<i>Desempeño de la red</i>	53
3.7.7.	<i>Épocas y momento</i>	53
3.8.	Entrenamiento de la red	54
3.8.1.	<i>Cálculo de error</i>	54
3.8.2.	<i>Entrenamiento</i>	54
3.9.	Simulación	60

CAPITULO IV

4.	RESULTADOS Y DISCUSIÓN	61
4.1.	Predicciones	62
4.1.1.	<i>Predicción con datos conocidos por la red</i>	62
4.1.2.	<i>Predicción con datos desconocidos por la red</i>	64
4.1.3.	<i>Predicción con datos desconocidos por la red – predicción dos meses</i>	65
4.2.	Comparación con otros modelos	70
4.2.1.	<i>Algoritmos de aprendizaje</i>	70
4.2.2.	<i>Modelos de red neuronal</i>	72
4.7.	Comprobación de la Hipótesis de investigación	74

CONCLUSIONES

RECOMENDACIONES

GLOSARIO

BIBLIOGRAFÍA

ANEXOS

ÍNDICE DE TABLAS

Tabla 1-2	Tipos de instrumentos meteorológicos	11
Tabla 2-2	Clasificación de las RN	26
Tabla 3-2	Características del software MATLAB	28
Tabla 4-2	Características EXCEL 2013	28
Tabla 5-2	Características de SPSS V. 22	28
Tabla 1-3	Ubicación geográfica de la Estación Meteorológica Chimborazo.....	31
Tabla 2-3	Equipos Instalados	33
Tabla 3-3	Escala Beaufort de fuerza del viento, usada en tierra	35
Tabla 4-3	Velocidad promedio mensual	37
Tabla 5-3	Velocidades máximas y mínimas mensuales.....	38
Tabla 6-3	Ejemplo de datos tomados del sensor	44
Tabla 7-3	Conjunto de datos pre procesados con función <i>premmx</i>	52
Tabla 1-4	Valores óptimos de entrenamiento	61
Tabla 2-4	Valores óptimos de entrenamiento	62
Tabla 3-4	Valores óptimos de entrenamiento, horizonte	66
Tabla 4-4	Comparación entre dos algoritmos de aprendizaje	70
Tabla 5-4	Hipótesis de normalidad	74
Tabla 6-4	Prueba de normalidad, Kolmogorov.....	74
Tabla 7-4	Transformación de datos función logaritmo natural.....	75
Tabla 8-4	Prueba de normalidad	77
Tabla 9-4	Hipótesis de comprobación.....	77
Tabla 10-4	Comparación de medias.....	77

INDICE DE FOTOGRAFÍAS

Fotografía 1-2	Estación climatológica convencional	10
Fotografía 2-2	Anemómetros	12
Fotografía 3-2	Termómetro.....	12
Fotografía 4-2	Pluviómetro	13

INDICE DE ILUSTRACIONES

Ilustración 1-2	Estación meteorológica automatizada	10
Ilustración 2-2	Estructura de una neurona biológica típica.....	15
Ilustración 3-2	Estructura de la neurona artificial.....	16
Ilustración 4-2	Estructura de una neurona biológica típica.....	18
Ilustración 5-2	Modelo neuronal de McCulloch-Pitts.....	18
Ilustración 6-2	Arquitectura unidireccional	21
Ilustración 7-2	Topología de red NARX, diseñada.....	27

INDICE DE GRÁFICOS

Gráfico 1-3	Ubicación geográfica Estación Meteorológica Chimborazo	31
Gráfico 2-3	Comportamiento mensual de la velocidad de viento	38
Gráfico 3-3	Curva de velocidades máximas y mínimas en el período de estudio.....	39
Gráfico 4-3	Velocidad de viento tomada cada hora - ultimo trimestre 2014.....	41
Gráfico 5-3	Velocidad promedio cada tres horas - ultimo trimestre 2014.....	41
Gráfico 6-3	Velocidad de viento tomada cada hora – periodo 2015.....	42
Gráfico 7-3	Velocidad de viento promedio cada tres horas – periodo 2015.....	42
Gráfico 8-3	Velocidad promedio cada 6 horas – periodo 2014	43
Gráfico 9-3	Velocidad promedio cada 6 horas – periodo 2015	43
Gráfico 10-3	Número de capas ocultas y neuronas por capa	46
Gráfico 11-3	División de datos, en sus diferentes etapas.....	47
Gráfico 12-3	Funciones de transferencia	47
Gráfico 13-3	Importación de datos desde Matlab	51
Gráfico 14-3	Parámetros de entrenamiento de la	55
Gráfico 15-3	Mejor performance de validación.....	56
Gráfico 16-3	Valor de la regresión o R^2	57
Gráfico 17-3	Valor de auto correlación del error cuadrático medio	58
Gráfico 18-3	Parámetros del estado de entrenamiento.....	58
Gráfico 19-3	Relación entre los targets y output de la red.....	59
Gráfico 20-3	Relación entre los targets y output etapas de entrenamiento, validación y test....	60
Gráfico 1-4	Entrenamiento de la red – horizonte de tres días.....	63
Gráfico 2-4	Curva de carga original vs curva de predicción datos conocidos	63
Gráfico 3-4	Mejor performance entrenamiento, validación y test.	64
Gráfico 4-4	Curva de carga original vs curva de predicción, 1-3 noviembre 2015.	65
Gráfico 5-4	Modelo de red utilizado.....	66
Gráfico 6-4	Datos originales vs datos estimados etapa entrenamiento	67
Gráfico 7-4	Plotresponse targets vs output	68
Gráfico 8-4	Plotperform entrenamiento, validación y test.....	68
Gráfico 9-4	Curvas de carga originales vs curvas de predicción datos desconocidos	69
Gráfico 10-4	Respuesta de relación entre los targets y las salidas estimadas	70
Gráfico 11-4	Entrenamiento con algoritmo de aprendizaje	71
Gráfico 12-4	Entrenamiento con algoritmo de aprendizaje	72
Gráfico 13-4	Entrenamiento con red modelo newff.....	72
Gráfico 14-4	Regresión o R^2 , con una red modelo newff	73

RESUMEN

El presente trabajo tiene como finalidad diseñar e implementar una red neuronal, que prediga la velocidad del viento en la estación meteorológica Chimborazo, perteneciente al Centro de Investigación de Energías Alternativas y Ambiente de la ESPOCH, ubicado en la ciudad de Riobamba. El estudio realizado responde a una investigación exploratoria, con elementos descriptivos y explicativos, que incluyen el agrupamiento de datos históricos y análisis del comportamiento de la velocidad del viento, a través de técnicas de aprendizaje automático como las REDES NEURONALES ARTIFICIALES no lineales autoregresivas aplicadas a un conjunto de datos medidos cada hora, durante 12 meses seguidos. La información fue procesada con el software matemático MATLAB, mientras que la hipótesis fue comprobada a través de métodos estadísticos como la prueba de normalidad y comparación de medias utilizando el software estadístico SPSS. Los resultados obtenidos demostraron que el uso de RNA en el proceso de predicción es muy efectivo alcanzando un nivel de aprendizaje automático del 8%, y un nivel de desempeño medido a través del error cuadrático medio de 0.016, con un horizonte de predicción de 72 horas. Los datos fueron obtenidos sin conocer previamente las salidas deseadas o targets, con una exactitud del 98.4%, aspecto que permitió estimar con alto grado de confiabilidad la cantidad de energía eólica a entregar. Se pudo concluir que la variable meteorológica más influyente en nuestro modelo es la dirección del viento, ya que sobresale en la explicación del comportamiento de la velocidad de viento. En futuros trabajos de predicción se recomienda, no excluir el escalamiento o normalización de datos, este proceso ayuda en el aprendizaje de la red neuronal, y evita confusiones en la interpretación o aprendizaje de patrones.

Palabras claves: <APRENDIZAJE AUTOMÁTICO>, <ENERGÍA EÓLICA>, <MATLAB>, <METEOROLOGÍA>, <REDES NEURONALES>, <VELOCIDAD DE VIENTO>.

SUMMARY

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.

Key words: Learning, Automatic, wind, error, Matlab, meteorology, potential, neural networks, speed, wind.

CAPITULO I

1. INTRODUCCIÓN

En este capítulo se detalla el problema de investigación: planteamiento, formulación y sistematización del mismo, así como también la justificación de la investigación, objetivo general, específicos e hipótesis.

1.1. Antecedentes

Actualmente la demanda de energía eléctrica en el Ecuador es abastecida en un 90% por generación hidroeléctrica, el resto se abastece tanto por centrales térmicas, como del aporte de la energía eólica. Ello, debido a la entrada en operación de ocho centrales hidroeléctricas, entre ellas se contempla además del Coca-Codo, las centrales Sopladora, Minas San Francisco, Toachi Pilatón, Delsintanisagua, Manduriacu, Quijos y Mazar Dudas.

En la última década, el país ha experimentado un gran desarrollo industrial, en el área de minera, petrolera y más aún en el área agrícola, de la misma manera el consumo energético ha crecido en un 200% no solo por el sector industrial, sino también por el incremento de la población, de los servicios de salud y porque no de la parte social, convirtiéndose en una necesidad la generación de energía limpia y aun renovable.

Este contexto, ha sido el impulso para realizar estudios sobre energías renovables, debido a la escasez de estas fuentes de potencial energético no convencional que se han desgastado en el transcurso de los años, quizás llegando al punto de extirparlas de nuestro planeta.

En Ecuador, según (MEER, 2012) la energía eólica se está aprovechando en la isla San Cristóbal con una capacidad de 2,4 y en la provincia de Loja, en el cerro Villonaco, con una potencia instalada de 16.5 MW, además está en construcción un proyecto en la isla

Baltra con una capacidad de 2.25 MW. El equivalente de la energía proporcionada por estos proyectos puede abastecer los hogares de 150 mil ecuatorianos

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.

Cinco estaciones meteorológicas ubicadas estratégicamente como son: Navag_Via a Canni, Estación Chimborazo (Sector Cóndor Samana), Finca Espoch-Estación Moyocancha, San José de Igualata, Chingazo Alto, mediante las cuales se muestrean variables meteorológicas como velocidad, dirección de viento, temperatura y presión atmosférica, las mismas que aportan en el estudio del potencial eólico, en nuestro estudio nos concentraremos en el estación meteorológica Chimborazo, que según referencias de los técnicos encargados esta estación presenta mayores intensidades de viento.

1.2. Problema de investigación

Con la utilización de anemómetros ubicados a una altura de 10m, se adquieren los datos generados en la estación meteorológica Chimborazo, que con un modelo físico-matemático se: calcula el potencial eólico, delimita y dimensiona la zona útil de modo que se puede preveer el potencial energético del emplazamiento, todo este proceso ayudara en la selección del aerogenerador ms adecuado para la producción de energía eólica.

Debido a las condiciones climáticas extremas, se presentan problemas como desprendimiento de paneles solares, que provoca la pérdida de datos recolectados o su vez simplemente hay días que no pueden ser censados y se pierde información valiosa que ayuda en el cálculo del potencial eólico.

Este caso cuando no existen datos, se realiza un relleno de los mismos a través de cálculos con modelos matemáticos o estadísticos que se ajusten al comportamiento de dicha variable, proceso que es denominado como relleno de datos, pero dicho proceso tiene poca confiabilidad de la información y más aún la utilización de la misma para determinar el potencial energético eólico.

El proceso relleno de datos se realiza en la base de 30 segundos, puesto que 10 minutos, no es recomendado, ya que genera un alto porcentaje de error, alrededor de 10%.

Por ello, es difícil conocer con antelación y precisión suficiente la cantidad de energía eólica con la que podremos contar en cada momento. Estas condiciones hacen especialmente compleja su operación, por lo que su producción futura tiene que ser estimada o prevista, viniendo esta previsión de potencia futura inevitablemente afectada por un error o incertidumbre de predicción.

1.3. Formulación del problema

¿Existe en la estación meteorológica Chimborazo un sistema de predicción de la velocidad de viento basado en redes neuronales que permita optimizar los estudios de potencial energético eólico?

1.4. Sistematización del problema

- a) ¿Cuáles son los procesos de adquisición de datos utilizados actualmente en la estación meteorológica Chimborazo?
- b) ¿Cuáles son los modelos de predicción de la velocidad del viento con aprendizaje automático, que se emplean en la estación meteorológica y cuál es el más adecuado?
- c) ¿Cuáles son las metodologías implementadas para la estimación de la velocidad del viento en la estación meteorológica Chimborazo?

1.5. Justificación de la investigación

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.

El estudio planteado se acomoda a la realidad energética del país, desarrollando un modelo matemático que incentive el uso de energía eólica, como una estrategia de planificación energética fundamental para minimizar los impactos ambientales, disminuir las emisiones de gases de efecto invernadero, reducir la dependencia de fuentes de energía eléctrica y térmica y minimizar los costos que implica la adquisición de energía a otros países por la falta de fuentes energéticas renovables que satisfagan la demanda del país.

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, por lo tanto este proyecto se enmarca en lo novedoso.

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.

La predicción de generación eólica se ha convertido en un tema clave para hacer factible el desarrollo e implantación de la energía eólica, y su integración en el sistema eléctrico.

Desde el punto de vista de generación eólica, o de cualquier otra fuente de energía renovable, la estimación de estas energías aporta para que los actores involucrados en proyecto eólico, puedan conocer con horizontes a corto, mediano o largo plazo la cantidad de energía eólica que será inyectada en la red y así gestionar la potencia que deberán generar las centrales eólicas, y también realizar estimaciones en el área financiera, ya que estas centrales deberán aportar con ingresos al país.

Los resultados obtenidos con la aplicación de redes neuronales a diferencia del método aplicado con promedios móviles, aportará con una solución sencilla, eficaz y confiable para la predicción de la velocidad del viento con una precisión superior al 95%, ya que el método de promedios según (Ariza, 2013) no considera la tendencia, estacionalidad o patrones sistemáticos, por tal motivo sus resultados son poco confiables.

Para evaluar la predicción realizada y comparar con los métodos utilizados actualmente, es necesario tener una métrica adecuada que permita comparar el desempeño de los diferentes métodos, esto a través del Error Cuadrático Medio (MSE-Mean Square Error, por sus siglas en inglés), que mide las diferencias entre el valor real y el estimado, si el MSE es un valor pequeño, las previsiones serán más exactas que si el resultado es grande, en adición con la Raíz del Error Cuadrático Medio (RMSE-Root Mean Square Error, por sus siglas en inglés), que proporciona una idea global de la diferencia entre los valores predichos y reales.

1.6. Objetivos de la investigación

1.6.1. *Objetivo general*

Diseñar e implementar una red neuronal, que prediga la velocidad del viento en la estación meteorológica Chimborazo.

1.6.2. *Objetivos específicos*

1. Analizar la situación actual de la estación meteorológica Chimborazo.
2. Establecer y seleccionar la información que será utilizada para la implementación del modelo de predicción.
3. Determinar el modelo más adecuado para la predicción de la velocidad del viento con aprendizaje automático, de acuerdo a las necesidades de la estación en estudio.
4. Implementar un modelo de red neuronal, para la predicción de la velocidad del viento, en la estación meteorológica Chimborazo en base a los datos adquiridos.
5. Precisar los logros y bondades de las RNA aplicadas a la predicción de la velocidad del viento.

1.7. Hipótesis

El sistema de predicción de la velocidad del viento basado en redes neuronales minimizará el error presentado al aplicar modelos matemáticos o estadísticos utilizados para el relleno de datos, en la estación meteorológica Chimborazo.

CAPITULO II

2. MARCO REFERENCIAL

En este capítulo se presenta el estado del arte del proyecto de investigación, se analiza cada una de las teorías y metodologías ya implementadas en estudios previos realizados sobre el tema a nivel mundial, nacional y local.

2.1. Estado del arte

Múltiples investigaciones relacionadas con el tema de predicciones de velocidad de viento y de análisis de la misma variable a través de redes neuronales, se han revisado, contribuyendo al presente trabajo de investigación los fundamentos necesarios para:

- Entender adecuadamente el funcionamiento y estructura de una RNA.
- Conocer las diversas metodologías aplicadas por los autores en las investigaciones.
- Determinar los mejores modelos de red, y sus diferentes parámetros.
- Establecer el aporte que realizan los autores en las investigaciones realizadas.
- Indagar los resultados y conclusiones obtenidas en base a las pruebas realizadas que hacen los autores.

Las investigaciones con mayor relevancia se detallan a continuación:

Flores et al. (2005) realizan la simulación de la velocidad del viento en la siguiente hora a partir de la velocidad de viento de las tres horas anteriores. La predicción se realiza con el fin de ayudar a la toma de decisiones en el mercado eléctrico, a partir de la velocidad predicha se calculan las potencias activas y reactivas que puede ser cedidas a la red. Usa una red neuronal de retropropagación. Se concluye el buen comportamiento de la red y por lo tanto es un método adecuado para predicción a corto plazo.

Li et al. (2004) describen el funcionamiento de un sistema de control para la obtención de un coeficiente de potencia optimizado, mediante la simulación de velocidad sin necesidad de anemómetros a partir de la potencia mediante redes neuronales.

Wang et al. (2004) Analizan a partir de 3 datos de viento de la última hora de 90 días y la tendencia en las últimas 8 horas, predicen la velocidad del viento en un horizonte de hasta 12 horas, mediante una red neuronal supervisada y concluye que los resultados son buenos a corto plazo y que a largo plazo debería de incluirse información meteorológica y geográfica.

Kélouwani et al. (2004), mediante la velocidad del viento, desviación estándar y los últimos datos de potencia, predicen la potencia de una turbina con errores del 1% para ser usados en estrategias de control.

Kalogirou et al. (1999), predicen la media mensual de velocidad del viento en Chipre en un terreno llano entrenando una red neuronal con 11 años de datos. Trata de obtener dicha velocidad a partir de los datos mensuales de 2 estaciones muy cercanas a la estación objetivo. Se establece una red neuronal con 11 inputs que son las coordenadas x e y de las tres estaciones, velocidades a dos alturas de las dos estaciones input y el mes del año que se trata de simular. Examina la importancia de los inputs utilizados y llega a la conclusión de que las coordenadas no son un input relevante, por lo que propone otra red con 5 inputs, cuya aplicación sería para completar datos de una estación. Usa una red de retropropagación con momento con neuronas en la capa oculta en dos niveles con distintas funciones de activación. Llega a la conclusión de que comete errores muy bajos en la estimación y que este método es válido tanto para una zona incluida dentro de la delimitada por las tres estaciones como para una exterior.

Bechrakis et al. (2004), predicen la velocidad del viento mediante redes neuronales de retropropagación con el algoritmo de Levenberg-Marquard, con una capa oculta con 15 neuronas. Usa la correlación con estaciones cercanas (hasta 35 km), las estaciones están ubicadas en terreno complejo y establece un “time lag” para preparar los datos para simular. Analiza dos regiones una con datos diezminutales (3 estaciones) medidos en verano y otra con datos horarios (2 estaciones) de todo un año. Realiza distintas simulaciones variando el orden de las estaciones, es decir, usando una estación bien como input bien como output, y concluye que la estación que debe ser utilizada como input es la que más información contenga examinando su espectro de energía, con un coeficiente de correlación superior a 0,6.

(Infante, Ortega, & Cedeño, 2008), propone un método de reconstrucción de series de tiempo de precipitaciones, para ser aplicado a las estaciones meteorológicas de Venezuela con el propósito de corregir el problema de datos faltantes. Determinaron la dimensión de inmersión del atractor de las series y el tiempo de retardo, y luego se han usado estas medidas para definir la arquitectura de la red neuronal, para luego seleccionar usar el criterio de información de Bayes (BIC), que consiste en penalizar el error cuadrático medio de los parámetros utilizados en el ajuste del modelo. Los resultados indican que las series de precipitaciones en Venezuela tienen alguna estructura subyacente no lineal, y provienen de un sistema caótico de bajas dimensiones.

(Álvarez , Montaña, Quentin, Maldonado, & Solano, 2013), proponen un método para homogeneizar series de velocidad del viento en las estaciones meteorológicas del Instituto Nacional de Meteorología e Hidrología (INAMHI) ubicadas en la provincia de Loja, República del Ecuador, a partir de los datos obtenidos en las mismas. Utilizan pruebas no paramétricas de homogeneización, así como el método de Alexandersson (SNHT). Se incorpora el Análisis de Regresión Múltiple para determinar los valores que presentan las discontinuidades a partir de los valores absolutos de los residuos de Student mayores que 3 y recalcular los mismos, y se presentan los resultados obtenidos para las series del mes de enero.

2.2. Estaciones meteorológicas

(Malvé, 2014) Manifiesta que, una estación meteorológica es una instalación destinada a medir y registrar regularmente diversas variables meteorológicas mediante los instrumentos meteorológicos.

2.2.1. Tipos de estaciones meteorológicas

Pueden ser convencionales o automáticas:

Estaciones convencionales.- necesitan de un *observador meteorológico*, que es una persona calificada para recopilar y transmitir información meteorológica.



Fotografía 1-2 Estación climatológica convencional
Fuente: (Jansá Guardiola, 2015)

La fotografía 1-2 muestra un ejemplo del tipo de instalación convencional, instalada en centros dedicados al estudio de la energía renovable.

Estaciones automáticas.- son configuradas para que registren datos en lugares remotos y lo transmitan de manera automatizada. Una estación meteorológica automática (EMA) es una versión autónoma de la tradicional estación meteorológica, preparada tanto para ahorrar en personal, o realizar mediciones en áreas remotas o de difícil acceso. El sistema puede reportar en tiempo real vía sistema Argos, o el Global Telecommunications System, tener enlace de microondas, o salvar los datos para posteriores trabajos de investigación o calibración de la misma, un ejemplo de la misma se puede observar en la figura la misma que claramente indica la tecnología instalada para la obtención y monitoreo de datos de varias variables meteorológicas.

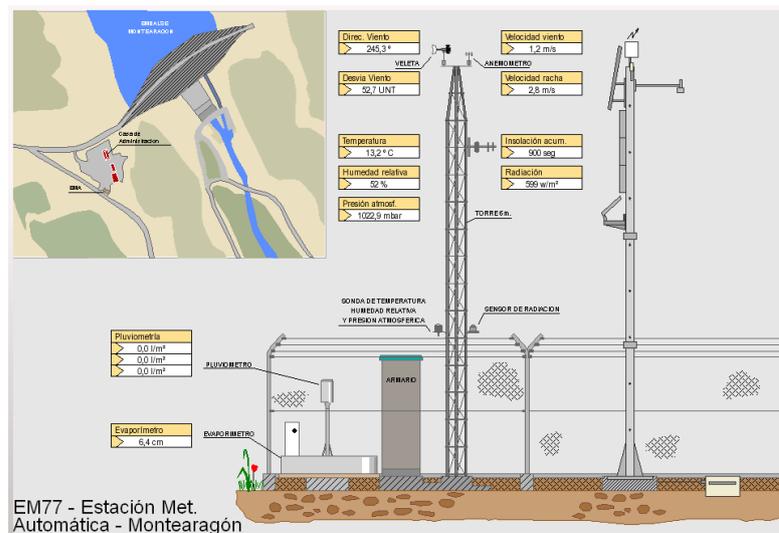


Ilustración 1-2 Estación meteorológica automatizada
Fuente: (Villarrubia, 2012)

Los instrumentos meteorológicos pueden ser medidores o registradores, pero el patrón siempre será el que mide, ver tabla 1-2.

Tabla 1-2 Tipos de instrumentos meteorológicos

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

Fuente: (Malvé, 2014)

2.2.2. 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.

2.2.3. Anemómetro

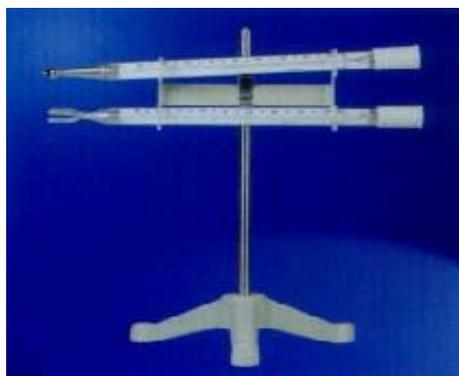
El Anemómetro es el instrumento que se utiliza para medir la dirección y la intensidad del viento, por lo tanto posee dos sensores, uno de ellos determina la dirección desde donde proviene el viento, conocido comúnmente como veleta, y el otro consiste en tres semiesferas construidas de un material muy liviano y que al girar permiten obtener la velocidad del viento. La unidad en que se mide la velocidad del viento es el Nudo. (Unidad de ciencias de la atmósfera, 2014)



Fotografía 2-2 Anemómetros
Fuente: (Unidad de ciencias de la atmósfera, 2014)

2.2.4. *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.



Fotografía 3-2 Termómetro
Fuente: (Unidad de ciencias de la atmósfera, 2014)

2.2.5. *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.



Fotografía 4-2 Pluviómetro
Fuente: (Unidad de ciencias de la atmósfera, 2014)

2.3. Energías renovables

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

Según Boyle (2010), 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”.

2.3.1. Energía eólica

Según (Ouanani, 2015) 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.

(Vaughn , 2013) 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.

2.3.1.1 Viento

Según (Villarrubia, 2012) el viento es el aire en movimiento, a escala global se debe a las diferencias de temperatura que provoca la radiación solar sobre las distintas partes del globo terrestre. Las diferencias de densidad y presión originadas por estas variaciones de temperatura son la causa del movimiento de las masas de aire.

(Rittenhouse, 1981), Indica que el viento es una manifestación indirecta de la energía solar, ésta se produce como resultado del diferente grado de calentamiento de la superficie terrestre por los rayos solares y por el movimiento de rotación de la tierra sobre si misma (fuerza de Coriolis). Se considera que un 0.7 por ciento de la radiación solar incidente en las capas altas de la atmósfera, acaba transformada en la energía cinética de los vientos (2,3 W/m²), aunque mediciones directas dan valores ligeramente superiores (de 4 a 10 W/m²). Considerando que la aportación del sol en su interacción con el sistema de la atmósfera tierra es de 172.000 TW (un TW son 1.000 megawatios), sólo 1.200 TW están destinados a mantener la circulación general de la atmósfera, es decir los vientos.

2.4. 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. (Cortina Januchs, 2012)

2.4.1. *Neurona Biológica*

Según (Llinàs, 2003), La historia de las redes neuronales artificiales comenzó con el científico aragonés Santiago Ramón y Cajal, descubridor de la estructura neuronal del sistema nervioso. Ramón y Cajal, demostró que el sistema nervioso está compuesto por una red de células individuales, las neuronas, ampliamente conectadas entre sí. Estableció que la información fluye en la neurona desde las dendritas hacia el axón, atravesando el soma. Este descubrimiento fue básico en el desarrollo de la neurociencia en el siglo XX.

Se estima que el sistema nervioso contiene alrededor de cien mil millones de neuronas. Las neuronas constituyen procesadores de información sencillos y están formadas por tres componentes principales: dendritas, el cuerpo celular y el axón (ver ilustración 2.2).

Las dendritas son como un árbol de redes de fibras nerviosas que llevan señales eléctricas al cuerpo de la célula (canal de entrada de información). El cuerpo celular, contiene el núcleo que es donde se ejecutan todas las transformaciones necesarias para la vida de la neurona (órgano de cómputo).

El axón transmite la señal de salida a otras neuronas (canal de salida), el intercambio químico de información entre una neurona y otra se hace a través de la sinapsis, la cual es el punto de interconexión entre neuronas.

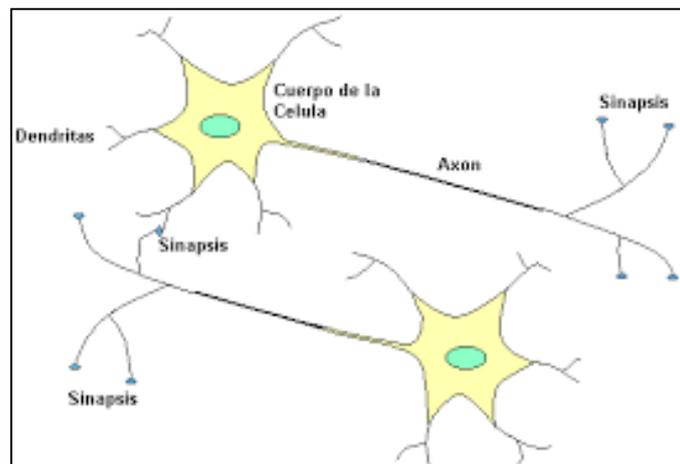


Ilustración 2-2 Estructura de una neurona biológica típica
Fuente: (Cortina Januchs, 2012)

2.4.2. Redes neuronales artificiales

Las redes neuronales son sistemas dinámicos autoadaptativos. Son adaptables debido a la capacidad de autoajustarse de los elementos procesales (neuronal) que componen el sistema. Son dinámicos, pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones. (Hilera J. , 1995)

Las redes neuronales artificiales (RNA) trabajan de la manera que trabaja nuestro cerebro. Básicamente es un conjunto de neuronas (algo como 10 a 100000 millones) conectadas, cuando nosotros aprendemos algunas de esas conexiones se ponen más fuertes, así si nosotros vemos algo con nuestros ojos, esa información tomará un camino a través de las neuronas, y finalmente nosotros reconocemos el objeto que hemos visto, como por ejemplo: cuando se bebe alcohol, reduce la velocidad de las conexiones y los desarregla a un cierto sector de neuronas, atrasando la reacción del estímulo de salida. (Christos Stergiou & Dimitrios Siganos, 2016)

Las RNA imitan el sistema nervioso, son capaces de reproducir con exactitud las principales tareas que desarrolla el cerebro humano, al replicar el comportamiento del mismo. De este modo, se construyen sistemas o redes de neuronas que presentan un cierto grado de inteligencia o aprendizaje automático, al detectar como se generan los patrones para el entrenamiento de la RNA, como se muestra en la figura.

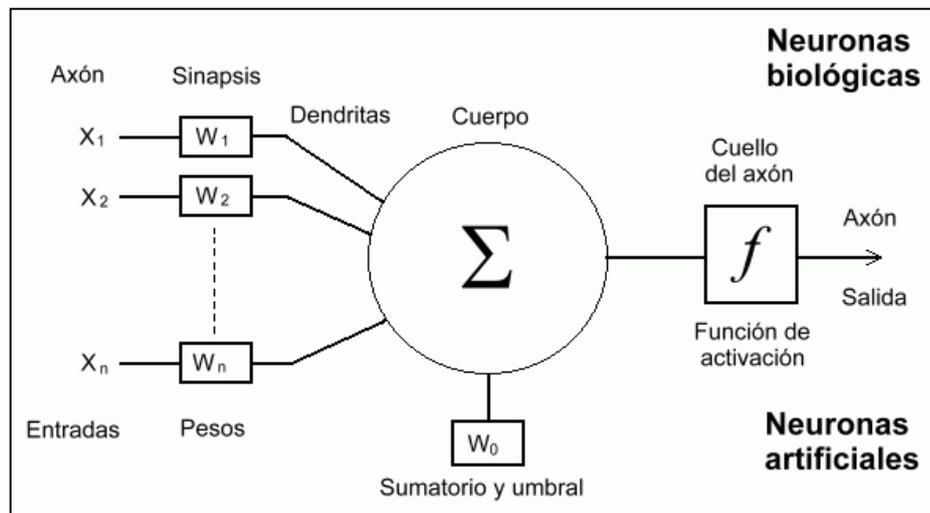


Ilustración 3-2 Estructura de la neurona artificial
Fuente: (Cortina Januchs, 2012)

Una de las principales propiedades de este sistema es la capacidad de aprender y generalizar a partir de ejemplos reales. Es decir, la red aprende a reconocer la relación que existe entre el conjunto de entradas proporcionadas como ejemplos y sus correspondientes salidas, de modo que, finalizado el aprendizaje, cuando a la red se le presenta una nueva entrada, en base a la relación funcional establecida en el mismo, es capaz de generalizarla ofreciendo una salida.

Según (Martínez Albaladejo, 2001), “Las redes neuronales artificiales (RNAs) se basan en las redes neuronales biológicas imitando la estructura del sistema nervioso”, ya que las NB trabajan de manera no secuencial, y además toda la información del cerebro no está ubicada en una sola posición, sino que se distribuye. Estas tienen adaptabilidad al entorno y aprenden de las experiencias, en cambio la NA generaliza o busca patrones.

La estructura está compuesta por un vector de pesos $w = (w_1, \dots, w_d)^T$, equivalente a las conexiones sinápticas en una neurona real, w_0 es el umbral de acción o activación, el vector x es la entrada y el escalar y la salida de la unidad. La actividad consiste en generar una única salida y a partir de la aplicación de la función de activación \gg a la suma

ponderada entre el vector de entrada $x = (x_1, \dots, x_m)^T$, y el vector de pesos $w = (w_1, \dots, w_d)^T$, más un sesgo w_0 , obteniéndose la siguiente expresión:

$$y = \gamma \left(\sum_{i=1}^m w_i x_i + w_0 \right) \quad (\text{Ecuación. 1})$$

Donde, γ es una función no-lineal. La función propuesta por McCulloch-Pitts posee una salida binaria ± 1 conocida como la función de todo o nada que equivale a la función signo dada por

$$\gamma(z) = \text{sgn}(z) = \begin{cases} 1 & z \geq 0 \\ -1 & z < 0 \end{cases} \quad (\text{Ecuación. 2})$$

2.4.3. *Aprendizaje automático*

Según (Moreno, 1994), 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.

El aprendizaje automático, también llamado aprendizaje artificial (Plaza, 1992), 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.

2.4.4. *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 gráfico 2-1: 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 provocara 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 ilustración 4-2. El valor obtenido será utilizado para generar una señal que es transmitida a otras neuronas. (Pajares & De la Cruz, 2011)

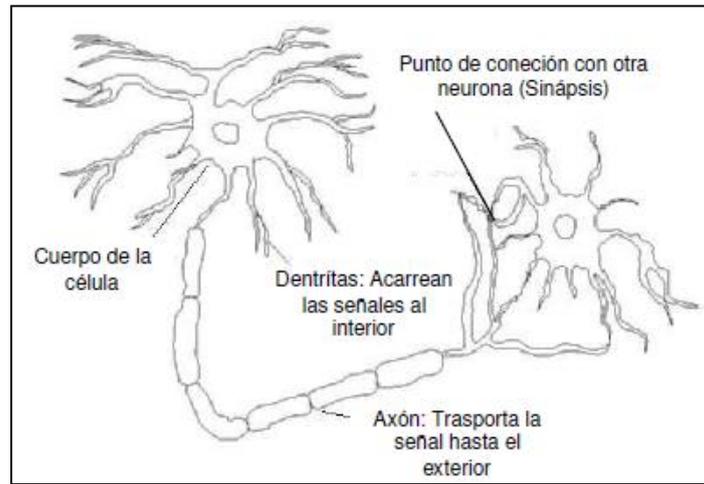


Ilustración 4-2 Estructura de una neurona biológica típica
Fuente: (Cortina Januchs, 2012)

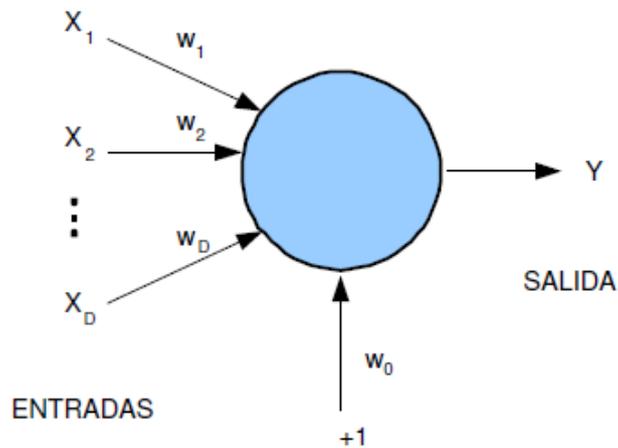


Ilustración 5-2 Modelo neuronal de McCulloch-Pitts
Fuente: (Cortina Januchs, 2012)

2.4.5. Funcionamiento de una red neuronal

Para el óptimo funcionamiento de la RNA, es recomendable seguir los siguientes pasos:

- Caracterización del fenómeno en estudio, se deben señalar las entradas, salidas y un conjunto de datos desconocidos por la red, que sirvan para verificar el desempeño de la red, mediante el cálculo del mse.
- Escalamiento o normalización de los datos que se dispone, es decir patrones que la red pueda entender de manera más sencilla, puesto que la red puede confundirse y el resultado de aprendizaje no será el adecuado. Pueden ser patrones entre (0,1) o (-1, 1).
- Train o entrenamiento, etapa en la que se proporciona las entradas y salidas deseadas escaladas a la red, este proceso se repite un cierto número de etapas, hasta que encuentra las salidas con el mejor valor de performance.
- Validation o validación. El conjunto de datos de entrada se divide por defecto en el 75% para train, 15 % para validación y 15% para test, en la etapa de validación se puede observar el desempeño de la red con la medida del error cuadrático medio.
- Test o prueba. Luego de entrenar y validar la red realiza pruebas como modelo predictor, si el resultado final del mse o performance es tendiente a cero se puede concluir que la red ha aprendido de manera exitosa y se puede probar la red con entradas desconocidas para la misma y verificar la confiabilidad del modelo, a través de la comparación de datos targets vs salidas de red.

2.4.6. *Arquitectura de una red neuronal*

Según (López Álvarez , Velo Sabín , & Maseda Eimil, 2007), La arquitectura de la red neuronal es la interconexión entre las distintas neuronas. Estas se agrupan en capas, cada una de ellas con un conjunto de neuronas de número variable y comportamiento similar.

Dentro del esquema de red, se distinguen tres tipos de capas:

- **Capa de entrada:** El número y tipo de neuronas de esta capa depende de la caracterización y datos del fenómeno en estudio. Esta capa recibe los datos o señales externas, recibe los vectores de entrada y los redistribuye a las neuronas de la capa oculta, hace las funciones de recepción de datos.

- **Capas ocultas:** El número de capas ocultas va depender del problema a resolver, a través de los pesos y bias estas capas consiguen la extracción de características y generalidades de los patrones de ingreso.
- **Capa de salida:** El número de neuronas de esta capa depende de la salida de la red, es decir, sus neuronas proporcionan la respuesta de la red neuronal a partir de un estímulo de la capa oculta, por lo general si tenemos una variable de salida, utilizaremos una sola neurona para esta capa.

Por lo tanto de acuerdo a la arquitectura seleccionada las redes puedes ser:

- Redes mono capa. - se establecen conexiones laterales entre las neuronas de la misma capa. Se utilizan en tareas auto-asociativas.
- Redes multicapa. - disponen de neuronas agrupadas en varios niveles, en este caso las capas se diferencian por el tipo de señal que recibe, por ejemplo, conexiones hacia adelante (feedforward), conexiones hacia atrás (feedback).

Un modelo de red con una sola capa oculta presenta menos diversificación y eleva el nivel de generalización de los datos de entrenamiento, por lo tanto, es más eficiente.

Dependiendo de la circulación de información entre las distintas capas se puede distinguir:

- Redes unidireccionales, en las cuáles la información circula en un sólo sentido, desde la capa de entrada a la de salida.
- Redes recurrentes o realimentadas, en las que la información puede circular entre capas en cualquier sentido, incluido el de salida a entrada.

En la ilustración 6-2, se muestra la arquitectura típica de una red neuronal unidireccional de tres capas: entrada, oculta y salida.

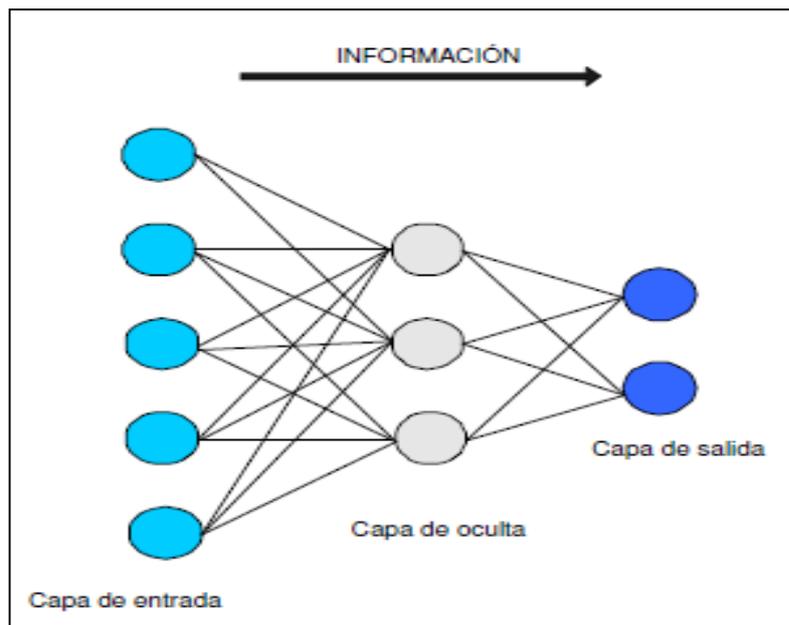


Ilustración 6-2 Arquitectura unidireccional con tres capas de neuronas
Fuente: (Jansá Guardiola, 2015)

2.4.7. 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 (Benedetti & Baigún, 2012) “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.

2.4.8. 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” (Hilera & Martínez, 2000).

Biológicamente, se suele aceptar que la información memorizada en el cerebro está más relacionada con los valores sinápticos de las conexiones entre las neuronas que con ellas mismas; es decir, el conocimiento se encuentra en las sinapsis. En el caso de las redes neuronales artificiales, se puede considerar que el conocimiento se encuentra representado en los pesos de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones, En realidad, puede decirse que se aprende modificando los valores de los pesos de la red.

Al igual que el funcionamiento de una red depende del número de neuronas de las que disponga y de cómo estén conectadas entre sí, cada modelo dispone de sus o sus propias técnicas de aprendizaje.

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:

$$H = J^T J = \begin{bmatrix} J_1^T & J_2^T \end{bmatrix} \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = J_1^T J_1 + J_2^T J_2 \quad (\text{Ecuación. 3})$$

El Hessian 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*.

2.4.9. 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.

En (Tebelskis, 1995), se menciona que “la precisión aumenta a medida que más neuronas son añadidas a la capa oculta”.

(Flórez López & Fernández Fernández, 2008), considera que para determinar el número de neuronas ocultas en cada capa suelen utilizarse reglas *ad hoc*, aunque no resultan matemáticamente justificables, han demostrado un buen comportamiento en diversas aplicaciones prácticas. Entre las reglas más conocidas se destacan:

a) Regla de la pirámide Geométrica

Se basa en la suposición de que el número de neuronas de la capa oculta ha de ser inferior al total de variables de entrada, pero superior al número de variables de salida. Se considera que el número de neuronas en cada capa sigue una progresión geométrica, tal que para una red con una única capa oculta, el número de neuronas intermedias debe ser próximo a $\sqrt{N \cdot M}$, siendo N el número de variables de entrada y M el total de neuronas de salida.

b) *Regla de la capa oculta-capla entrada*

Según esta regla, el número de neuronas ocultas está relacionado con el número de neuronas de entrada. En particular suele aplicarse la regla 2x1, de forma que el número de neuronas ocultas no puede ser superior al número de variables de entrada.

c) *Regla de la capa oculta-número de patrones*

Esta regla relaciona el número de neuronas de la capa oculta, con el número de patrones presentados al sistema, siendo habitual la relación 1/30 (una neurona oculta por cada 30 patrones).

2.4.10. Entrenamiento, aprendizaje y ejecución

Las RNA son capaces de realizar un cálculo a partir de un conjunto de patrones de entrenamiento o variables independientes, siendo la capacidad de aprendizaje una de sus principales características, ya que de acuerdo al porcentaje de aprendizaje la red modifica sus pesos, adaptándolos hasta conseguir la salida deseada o target.

El entrenamiento es el proceso mediante el cual la red aprende, mediante algoritmos de aprendizaje que aplican modelos matemáticos para garantizar el aprendizaje más óptimo de la red.

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 o simular los datos, es decir, la red es capaz de replicar o predecir los targets ante entradas desconocidas por la red.

Se pueden distinguir los siguientes tipos de aprendizaje (Martínez Albaladejo, 2001):

- **Aprendizaje supervisado:** La red aprende a partir de ejemplos de entrenamiento, es decir, la red es entrenada a partir de la entrada y la salida aprendiendo la relación entre ellos sin necesidad de disponer de una forma funcional de partida, ajustando los pesos a partir de la información del error que se comete en cada paso.
- **Aprendizaje no supervisado:** El conjunto de entrenamiento está constituido sólo por la entrada, sin la salida esperada para estos elementos. El aprendizaje se realiza a

través de la asociación de la información recibida con la almacenada y como consecuencia reconociendo regularidades en el conjunto de datos, es decir, la red es capaz de extraer las características, estableciendo una clasificación o categorización.

- Aprendizaje híbrido: Es una mezcla de los anteriores tomando la regla de aprendizaje supervisado para casos maestros, conocidos y generales. Normalmente el aprendizaje supervisado y no supervisado tienen lugar en capas distintas.
- Aprendizaje reforzado: está a medio camino entre el supervisado y no supervisado, la información del error es sólo global (bien, mal) y no se suministra la salida deseada.

2.4.11. 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 gráfica 4 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 2-2 Clasificación de las RN

SUPERVISADO	UNIDIRECCIONALES	Perceptrón	Rosenblatt	1958
		Adaline	Widrow y Hoff	1960
		Perceptrón Multicapa Backpropagation	Rumelhart, Hinton y Willians	1986
		Correlación en cascada	Fahlman y Lebiere	1990
		Máquina de Bolzman	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	Holfield	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	

Fuente: (López Álvarez , Velo Sabín , & Maseda Eimil, 2007)

2.4.11.1. 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 (López Álvarez , Velo Sabín , & Maseda Eimil, 2007)

2.4.11.2. Red NARX

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”.

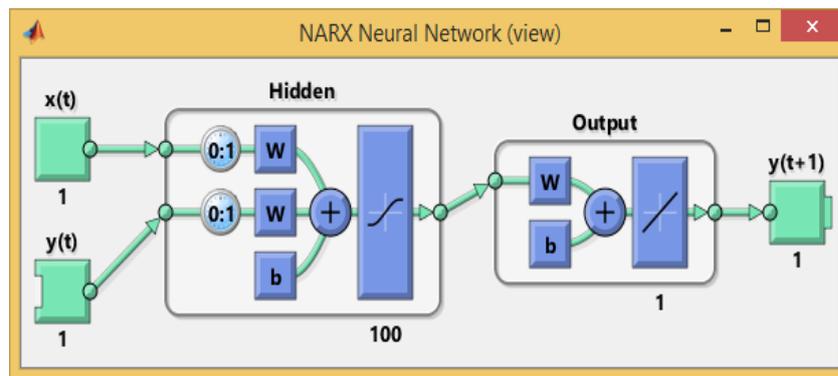


Ilustración 7-2 Topología de red NARX, diseñada
Realizado por: Paulina F. Bolaños L

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.

2.5. Software a utilizar

MATLAB es una herramienta de software matemático que ofrece un entorno de desarrollo integrado con un lenguaje de programación propio, debido al potencial de procesamiento que esta herramienta y a la gama de aplicaciones entorno a la ingeniería el uso de este software es la base fundamental para el desarrollo de la investigación.

En la siguiente tabla se presenta las características del software y herramientas específicas a utilizar.

Tabla 3-2 Características del software MATLAB

Característica	Descripción	Uso
Versión	R2016a	Software para procesamiento de datos.
APPS	Neural Net Time Series	Aplicación para el uso y configuración de Redes neuronales.

Realizado por: Paulina F. Bolaños L.

EXCEL, Microsoft Excel es una aplicación de hojas de cálculo que forma parte de la suite de oficina Microsoft Office. Es una aplicación utilizada en tareas financieras y contables, con fórmulas, gráficos y un lenguaje de programación. La utilización de este software es de gran utilidad en la adquisición de datos desde los sensores, puesto los archivos se generan en esta aplicación para luego ser procesados según la necesidad.

Tabla 4-2 Características EXCEL 2013

Característica	Descripción	Uso
Versión	Microsoft Office Profesional Plus 2013	Software para procesamiento de datos adquiridos desde los sensores. Clasificación de datos

Realizado por: Paulina F. Bolaños L.

SPSS, programa estadístico informático muy usado en las ciencias sociales y aplicadas, además de las empresas de investigación de mercado. Utilizado actualmente en muchas de las investigaciones para la comprobación de hipótesis.

Tabla 5-2 Características de SPSS V. 22

Característica	Descripción	Uso
Versión	IBM SPSS Statistics Base 22	Software estadístico utilizado en esta investigación específicamente para la comprobación de hipótesis.

Realizado por: Paulina F. Bolaños L.

2.6. Metodología para el desarrollo de la predicción de velocidad de viento.

Múltiples trabajos de investigación presentan similitud en la metodología utilizada para la predicción de velocidad de viento mediante redes neuronales, en el estudio denominado: **“Pronóstico de la Velocidad y Dirección del Viento mediante Redes Neuronales Artificiales”** (Parreño & Gomez, 2004), se explica la metodología utilizada con el modelo ARIMA de Box-Jenkins, que servirá de base para la ejecución de la presente investigación. A continuación se detalla los procesos a seguir, que durante el desarrollo de la investigación se podrá cambiar de acuerdo a la necesidad del experimento.

1. Caracterización del viento como el agente fundamental en el proceso de generación eólica
2. Análisis de la influencia de medidas anteriores (históricas) del viento en el mismo lugar.
3. Selección de modelo de red a diseñar según los resultados del análisis de influencia.
4. Parametrización de la red neuronal
5. Entrenamiento de la red
6. Corrección de errores
7. Simulación de la red.

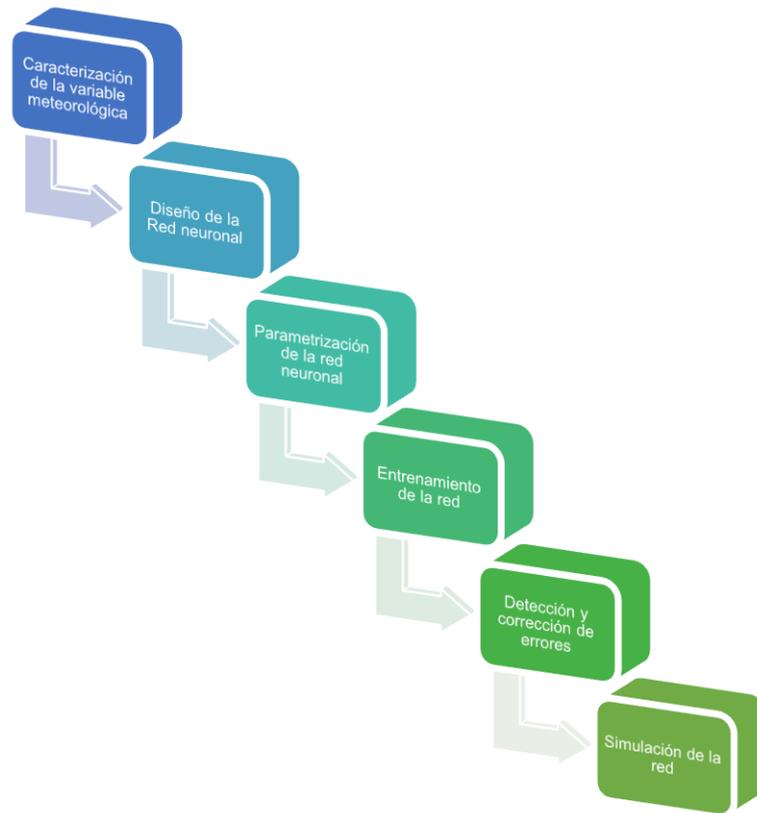


Gráfico 1-2 Diagrama de bloques del proceso de predicción
Realizado por: Paulina F. Bolaños L

CAPITULO III

3. DISEÑO DE LA INVESTIGACIÓN

3.1. Situación actual de la estación meteorológica Chimborazo.

3.1.1. Ubicación.

La estación meteorológica Chimborazo, está ubicada en la provincia de Chimborazo, cantón Riobamba, parroquia de Loma de Rasutambo, zona de Pinanquil, con un área de 1000 km aproximadamente, temperatura media de 7.1°C, cuyas coordenadas se resumen en la tabla 1-3 y se pueden visualizar en el gráfico 1-3.

Tabla 1-3 Ubicación geográfica de la Estación Meteorológica Chimborazo

Estación meteorológica	Altitud (m.s.n.m)	Latitud (deg)	Longitud (deg)
Loma de Rasutambo - zona Pinanquil. Chimborazo	4302	1° 32' 0.43" S	78° 52' 40.27" O

Fuente: Centro de Investigación de Energías Alternativas y Ambiente de la ESPOCH



Gráfico 1-3: Ubicación geográfica Estación Meteorológica Chimborazo
Realizado por: Paulina F. Bolaños L.

Como dato importante es conocer que la estación meteorológica está ubicada en un terreno abierto sin obstáculos, con una rugosidad de 0.03, lo que permitirá la estimación de la velocidad del viento.

3.1.2. Descripción.

El Centro de Investigación de Energías Alternativas y Ambiente de la ESPOCH es el ente encargado de la producción científica y académica que generan estas estaciones a través de proyectos de investigación y desarrollo, en el ámbito del estudio de las energías renovables y en especial de la energía eólica.

El centro de investigación ha instalado varias estaciones meteorológicas con el objetivo de estudiar el potencial eólico de la provincia de Chimborazo con miras a producir energía limpia.

Con el propósito de obtener datos reales, que ayuden en el estudio del potencial eólico, la estación Meteorológica Chimborazo cuenta con equipos sofisticados (ver tabla N°. 1), los mismos permiten la medición de varios parámetros como:

- Radiación global
- Radiación difusa
- Velocidad de viento
- Dirección de viento
- Precipitación
- Temperatura ambiente
- Humedad relativa
- Presión barométrica
- Temperatura de suelo a 7 niveles y nivel de batería.

3.1.3. Equipamiento

Con el fin de garantizar el funcionamiento correcto de los equipos y la fiabilidad de la información, los técnicos del centro de investigación con una frecuencia quincenal,

realizan calibraciones y mantenimiento correctivo y preventivo a todos los equipos instalados, ver tabla 2-3.

Tabla 2-3 Equipos Instalados

Equipo	Marca/modelo
Estación Meteorológica	Vaisala / MAWS100DCP
2 Piranómetros	Hukseflux / sr11
1 Sensor de temperatura suelo	Vaisala /QMT 107
1 Modem GPRS	Sierra Wireless / FXT009
1 Caja Nema	ABB / 1SL0222A00
1 Datalogger	Vaisala / QML201
1 Batería 12V/26Ah	POWER SONIC /PS-12350 NB
1 Sensor de Temperatura/Humedad	Vaisala / HUMICAP HMP155
1 Anillo de Sombra	
1 panel solar	ZYTECH / ZT30S
1 Sensor Presión Barométrica	Vaisala / BAROCAP BARO-1
1 Anemómetro ultrasónico	Young / 85000
1 regulador	Phocos/CML 10-2. 1

Fuente: Centro de Investigación de Energías Alternativas y Ambiente de la ESPOCH

3.1.4. Metodología utilizada para el estudio del potencial energético

Según información proporcionada por técnicos del centro de investigación, la metodología se basa en tres parámetros importantes para el futuro estudio del potencial eólico: 1. Selección de lugares con características óptimas para el estudio eólico, 2. Adquisición de datos medidos por los sensores, y 3. Procesamiento de información para el cálculo del potencial eólico y determinación de los lugares recomendables para la instalación de aerogeneradores que permitan la generación de energía limpia.

1. La selección de los lugares de monitoreo del potencial eólico se basa en encuestas, se realizan mediciones instantáneas de: velocidad de viento, altura, presión atmosférica con un dispositivo portátil, lo que permite seleccionar el sitio donde se ubicarán las estaciones meteorológicas.

2. Los datos de las estaciones meteorológicas se toman mes a mes, por un período de dos años.
3. Con los datos del primer año y con un modelo físico-matemático, y su respectivo software previamente desarrollado se calculará el potencial eólico (densidad superficial de energía kW/m²), además se corregirá el modelo y el software, y con los datos del segundo año se tendrá una cuantificación más precisa del potencial energético eólico. Se delimitará, y dimensionará la zona útil de modo que se pueda estimar el potencial energético del emplazamiento, además se seleccionará el tipo de aerogenerador para que maximice la producción energética, y finalmente se hará un análisis económico para validar su viabilidad.

3.2. Comportamiento de la velocidad del viento en la zona de estudio.

Según un estudio realizado por (Ministerio del Ambiente, 2016), 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. 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, (Hulshorst, 2015)

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 2014 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 4.

Tabla 3-3. Escala Beaufort de fuerza del viento, usada en tierra

Número Beaufort	Descripción	Velocidad del viento [Nudos]	Equivalente [ms ⁻¹]	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	

Fuente: (Jansá Guardiola, 2015)

La estación meteorológica Chimborazo, presenta una variación mínima en la medición de la presión barométrica mes a mes, dando muestras de estabilidad en dicha variable meteorológica y poca influencia en el comportamiento de la velocidad de viento en los datos proporcionados para el estudio. De tal manera que podemos descartar esta variable y concentrarnos en analizar como se muestra el viento en el periodo de estudio.

3.4.1. Velocidad media

Último trimestre año 2014.

Para el estudio se calculó la velocidad promedio mes a mes, y como se puede observar en el gráfico 3-2, los meses de octubre y noviembre han generado velocidades medias de 5.49 m/s y 6.39 m/s respectivamente, ver tabla 5, 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 4-3 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 impide hacer una estimación más concreta y estable sobre el comportamiento de la velocidad del viento y por ende de la producción de energía eólica. Sim embargo los niveles presentados son óptimos para la viabilidad de un sistema de energía eólica.

Tabla 4-3. 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

Realizado por: Paulina F. Bolaños L.

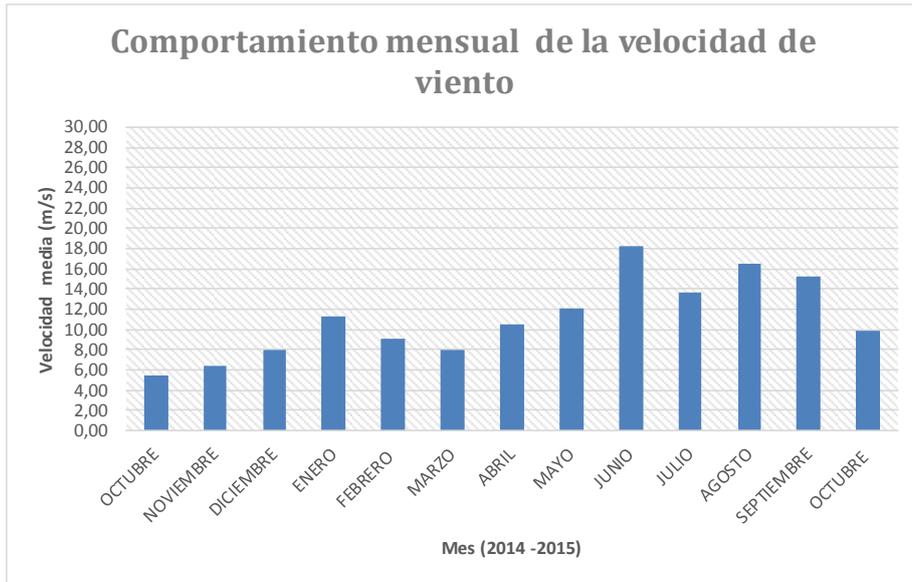


Gráfico 2-3: Comportamiento mensual de la velocidad de viento
Realizado por: Paulina F. Bolaños L.

3.4.2. Velocidad máxima y mínima

Velocidad máxima y mínima mensual

Tabla 5-3 Velocidades máximas y mínimas mensuales

Mes	Año	Velocidad Max (m/s)	Velocidad Min (m/s)
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

Realizado por: Paulina F. Bolaños L.

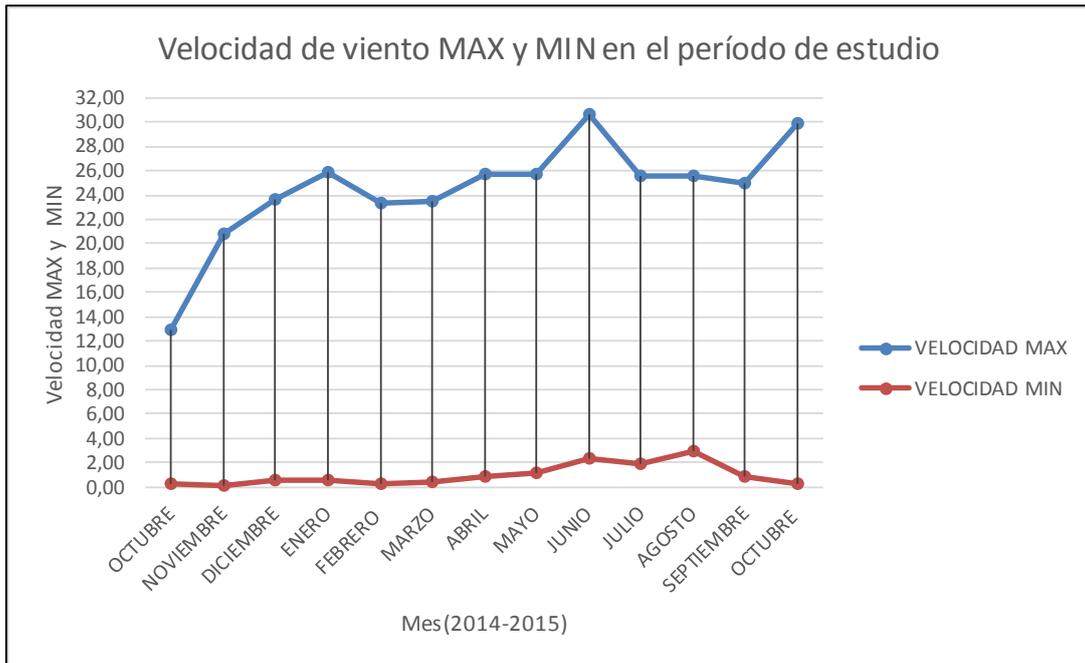


Gráfico 3-3: Curva de velocidades máximas y mínimas en el período de estudio
 Realizado por: Paulina F. Bolaños L.

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.

Teniendo claro el comportamiento de la velocidad de viento, y con el objetivo de analizar y establecer un horizonte de predicción mayor a los dos días que según la mayoría de estudios lo demuestran, se realizó el cálculo de la velocidad de viento promedio cada tres horas, generándose los siguientes resultados:

3.4.3. *Velocidad promedio cada 3 horas*

Se realiza una comparación entre el comportamiento de la velocidad de viento tomada cada hora versus la velocidad promedio cada tres horas, en el último trimestre del año 2014, claramente se observa el mismo patrón es decir que este comportamiento no tiene demasiada variación en el lapso de tres horas, en un solo día se reduciría a 8 intervalos de tiempo.

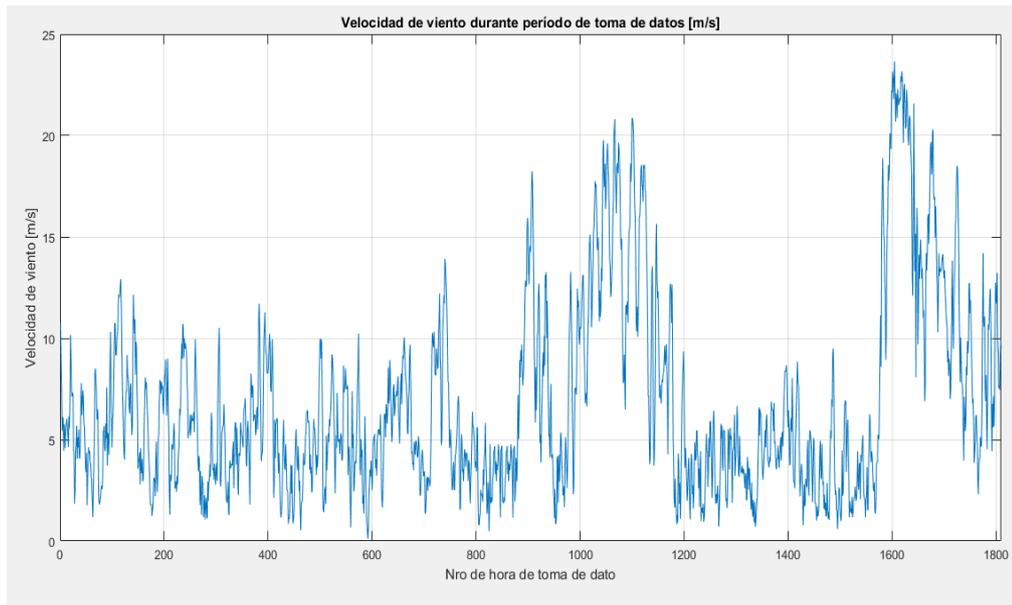


Gráfico 4-3: Velocidad de viento tomada cada hora - ultimo trimestre 2014
 Realizado por: Paulina F. Bolaños L

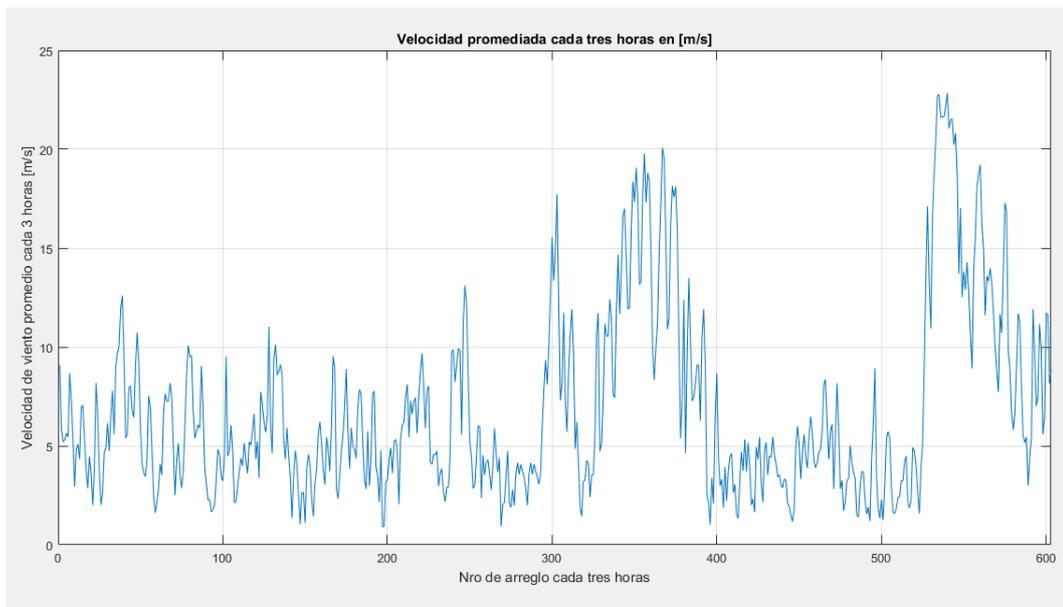


Gráfico 5-3: Velocidad promedio cada tres horas - ultimo trimestre 2014
 Realizado por: Paulina F. Bolaños L

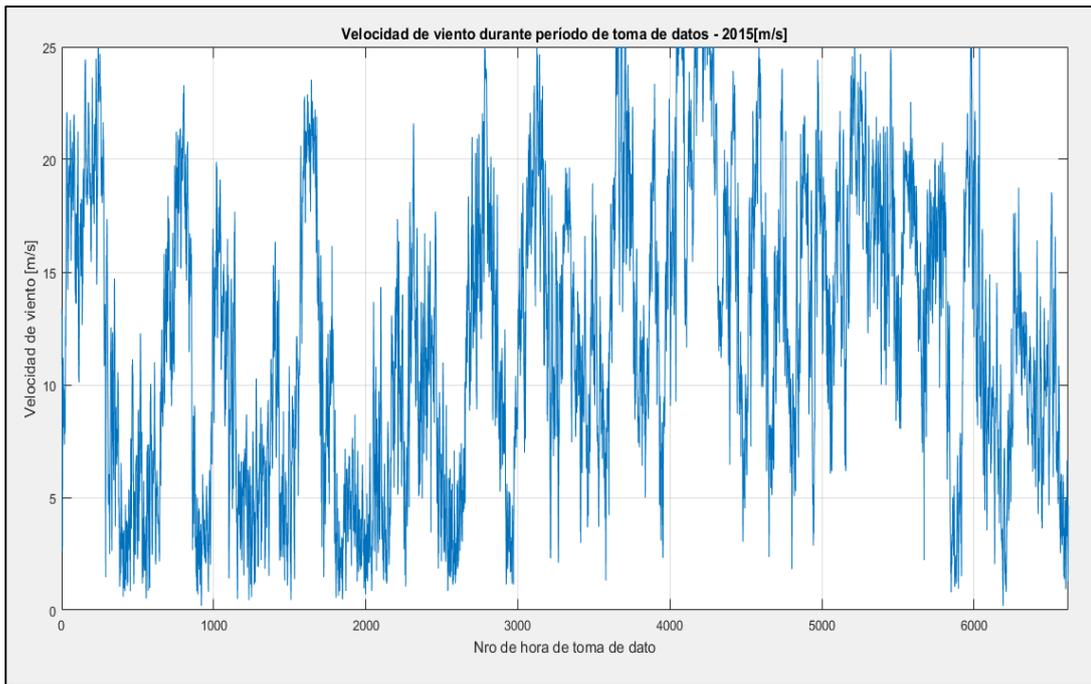


Gráfico 6-3: Velocidad de viento tomada cada hora – periodo 2015
 Realizado por: Paulina F. Bolaños L

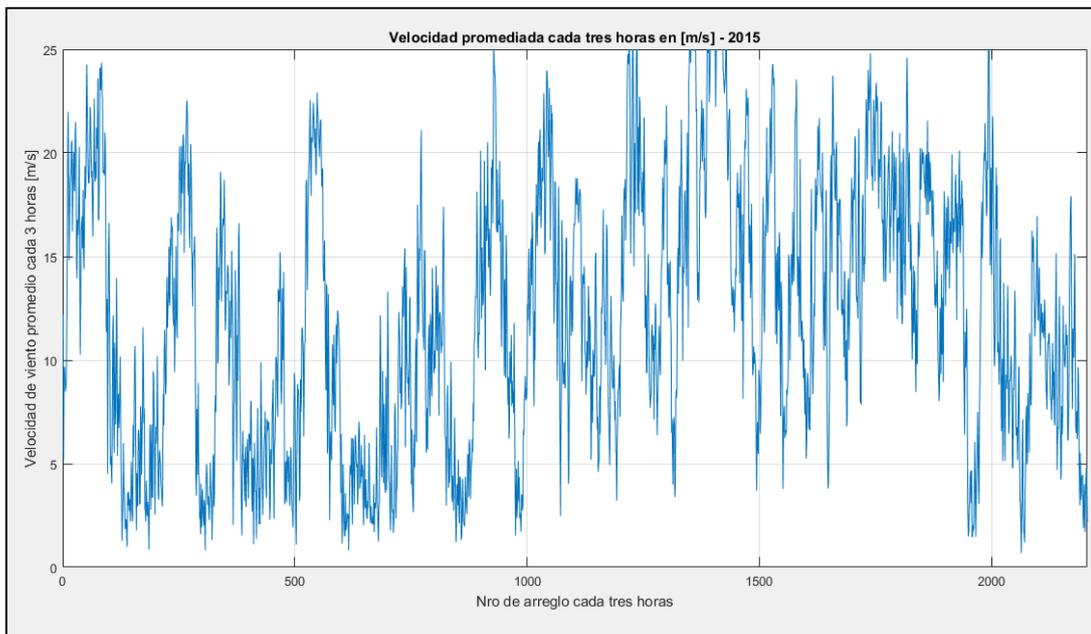


Gráfico 7-3: Velocidad de viento promedio cada tres horas – periodo 2015
 Realizado por: Paulina F. Bolaños L

3.4.4. Velocidad promedio cada 6 horas

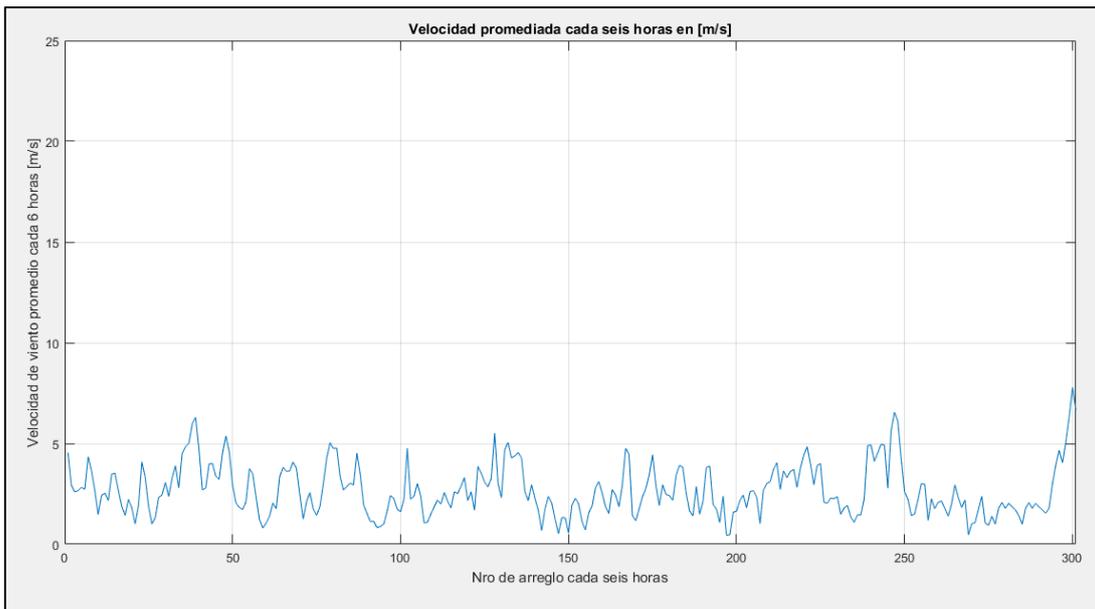


Gráfico 8-3: Velocidad promedio cada 6 horas – periodo 2014

Realizado por: Paulina F. Bolaños L

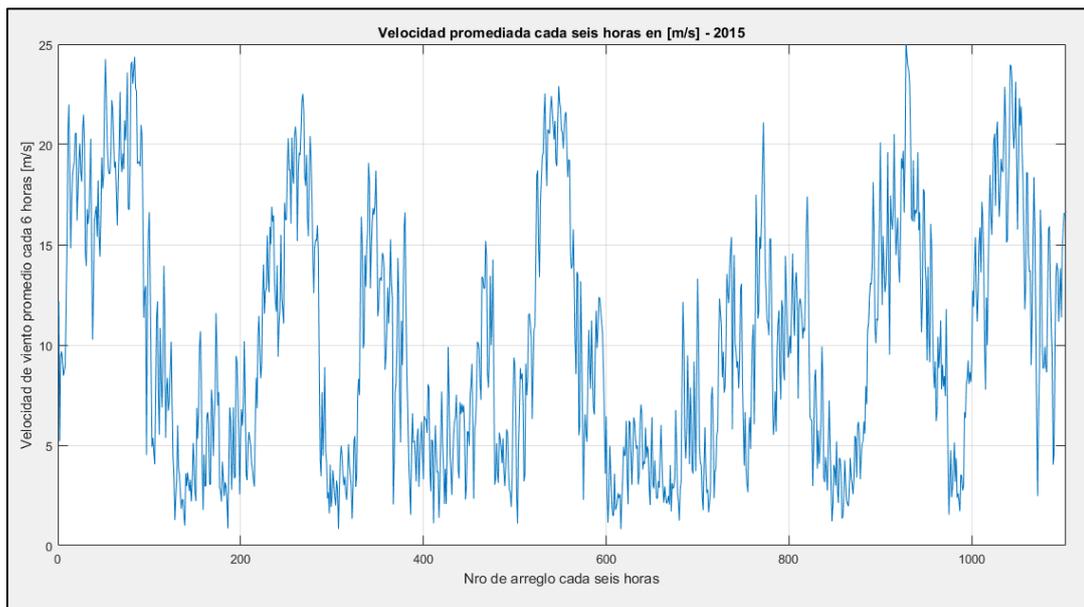


Gráfico 9-3: Velocidad promedio cada 6 horas – periodo 2015

Realizado por: Paulina F. Bolaños L

Para efectos de análisis y manejo de datos se va a utilizar el vector generado con las velocidades promedio cada tres horas, ya que existe gran variación de velocidades y con el fin de garantizar el aprendizaje correcto de la red neuronal.

3.5. 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 6-3:

Tabla 6-3. 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

Realizado por: Paulina F. Bolaños L

Donde:

Vv=velocidad del viento (m/s)

Dv=dirección de viento (grados)

Temp= temperatura

Pres=presión

En la tabla 7-3, 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.

Estos datos son obtenidos desde el sensor (anemómetro), los mismos son almacenados en una base de datos primaria, que almacena todas las variables meteorológicas medidas en la estación Chimborazo, para luego ser procesadas, la base de datos tiene extensión .dat que luego es convertida a Excel.

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.

1. Variables entrada= año, mes, día y hora

Variable salida=velocidad de viento

2. Variable entrada=dirección de viento

Variable salida=velocidad de viento

3.5.1. 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.

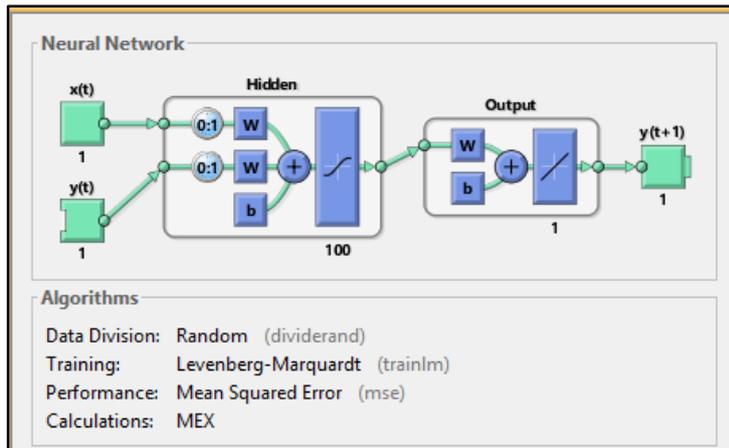


Gráfico 10-3: Número de capas ocultas y neuronas por capa
Realizado por: Paulina F. Bolaños L

En el gráfico 10-3, 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.

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.

3.5.2. 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 el gráfico 3-13, 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.

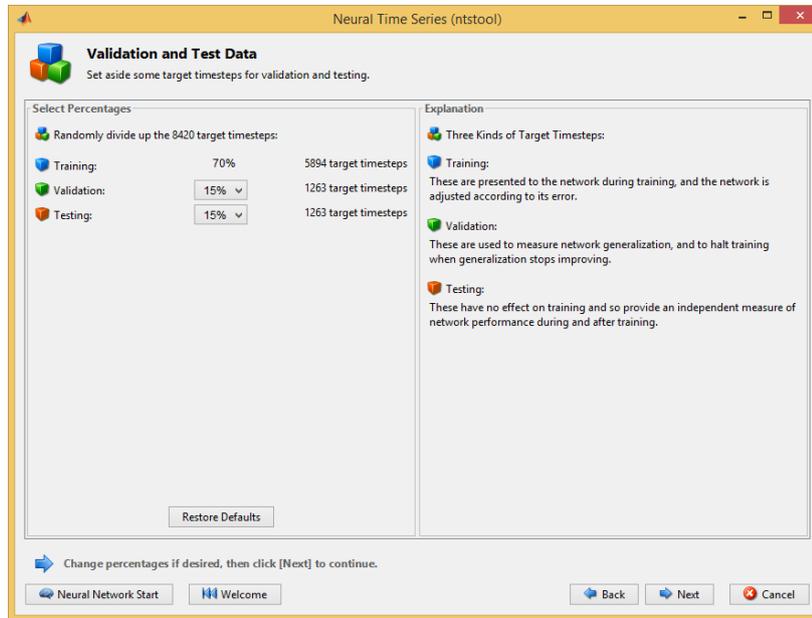
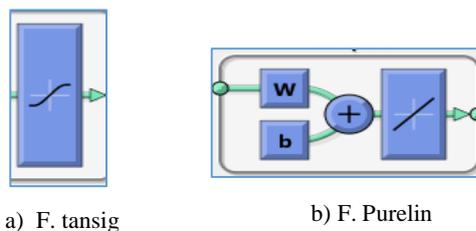


Gráfico 11-3: División de datos, en sus diferentes etapas
Realizado por: Paulina F. Bolaños L

3.5.3. 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.



a) F. tansig

b) F. Purelin

Gráfico 12-3: Funciones de transferencia
capa en la red neuronal

Realizado por: Paulina F. Bolaños L

3.5.4. *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.

De acuerdo con las necesidades de nuestra red, se aplica un aprendizaje supervisado, ya que se cuenta con un conjunto de datos o patrones de entrada, como se vio en la descripción del capítulo anterior.

3.5.5. *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.

3.5.6. *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:

$$e(t + k|t) = V(t + k|t) - V'(t + k|t) \quad (\text{Ecuación. 4})$$

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.

3.5.7. *Error Cuadrático Medio (MSE)*

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

$$MSE(k) = \frac{1}{k} \sum_{i=1}^k e(t+k|t)^2 \quad (\text{Ecuación. 5})$$

$$MSE(k) = \frac{1}{k} \sum_{i=1}^k V(t+k|t) - V'(t+k|t) \quad (\text{Ecuación. 6})$$

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 .

3.6. Preproceso y Postproceso

Con la finalidad de alcanzar una red neuronal más eficaz se realizan ciertos pasos en el pre-proceso 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] = 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 $\max t$ 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 t_n de las salidas normalizadas. El rendimiento de la red in-normalizado está en las mismas unidades como los objetivos originales t .

3.7. Implementación

Datos a utilizar

Desde Matlab se importa el archivo en Excel con el conjunto de entradas y salidas a utilizar, en este caso tenemos dos archivos: `entradas_3` y `salidas_3`, los mismos que deben ser importados como Matriz Numérica, ver en gráfico 13-3.

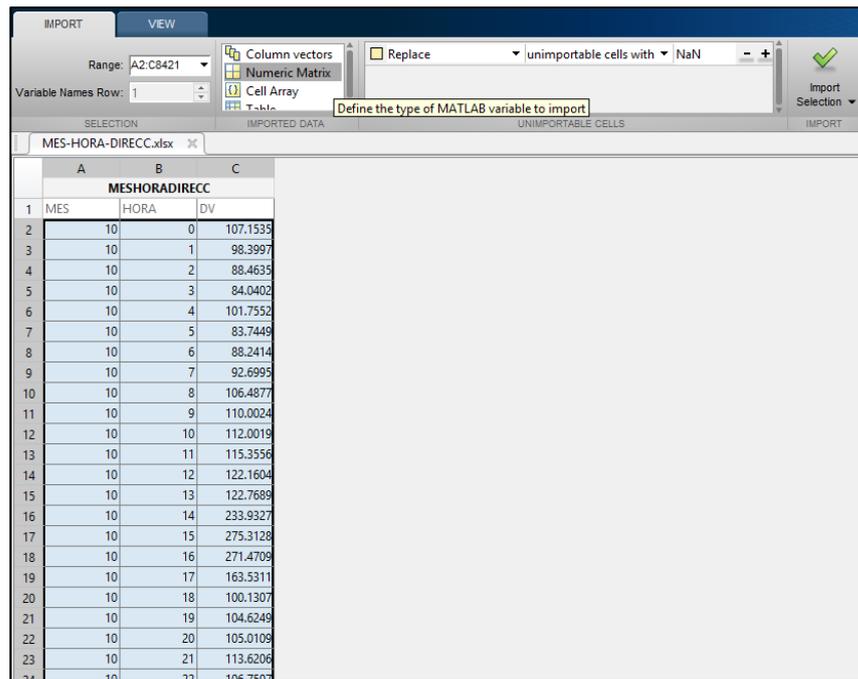


Gráfico 13-3: Importación de datos desde Matlab
Realizado por: Paulina F. Bolaños L

Ya con los archivos generados en el Workspace, indicamos el rango de datos a utilizar.

```
xx = entradas_3 (1:8420,3); %vector entrada
```

```
tt = salidas_3 (1:8420,1); %vector salida
```

Estos datos se generan como matrices de 8420 filas x 3 columnas en el caso de las entradas y en el caso del vector salida 8420 x 1, datos de tipo numérico o double.

3.7.1. Pre- procesamiento de datos

```
[pn, minp,maxp,tn,mint,maxt] = premnmx (xx,tt);
```

Como se explicó en el apartado anterior necesitamos escalar o normalizar los datos de entrada y salida, como se puede ver en la tabla 7-3 un resumen de los datos originales vs los datos normalizados.

Tabla 7-3. Conjunto de datos pre procesados con función *premnmx*

Valores reales de entrada y salida		Valores normalizados de entrada y salida		Parámetros de salida de la función <i>premnmx</i>			
xx	tt	Pn	tn	maxp	minp	maxt	mint
107,1535	5,7628	-0,4378	-0,6294	353,4643	10,8470	30,6086	0,1133
98,3996	6,0277	-0,4889	-0,6121				
88,4634	5,6863	-0,5469	-0,6345				
84,0402	5,2297	-0,5727	-0,6644				
101,7552	4,6391	-0,4693	-0,7031				
83,7448	6,1423	-0,5744	-0,6045				
88,2414	5,5633	-0,5482	-0,6425				
92,6994	6,8062	-0,5221	-0,5610				
106,4877	10,1566	-0,4417	-0,3413				
110,0024	9,0905	-0,4211	-0,4112				
112,0018	7,4824	-0,4095	-0,5167				
115,3556	7,1249	-0,3899	-0,5401				
122,1603	7,31768	-0,3502	-0,5275				
122,7688	7,1988	-0,3466	-0,5353				
233,9326	4,4566	0,3022	-0,7158				
275,3127	4,3692	0,5437	-0,7208				
271,4708	1,8403	0,5219	-0,8867				
163,5310	2,5205	-0,1087	-0,8421				
100,1307	4,4360	-0,4788	-0,7165				
104,6249	4,81774	-0,4525	-0,6914				

Realizado por: Paulina F. Bolaños L

Ya que nuestra red es de tipo NARX, es necesario preparar los datos de la red creada para proceder con el entrenamiento, para ello utilizamos los siguientes comandos:

3.7.2. Creación de la red

Con dos tiempos de retraso y 100 neuronas en la capa oculta, mediante el comando `narxnet` creamos la red.

```
net = narxnet (1:2,1:2,100);
```

3.7.3. Distribución del conjunto de datos

Como se mencionó anteriormente es necesario separar en tres grupos de información: entrenamiento, validación y test.

```
net.divideFcn = 'dividerand';
```

```
net.divideMode = 'value';  
net.divideParam.trainRatio = 70/100;  
net.divideParam.valRatio = 15/100;  
net.divideParam.testRatio = 15/100;
```

3.7.4. Pesos y Bias

Es necesario indicar a la red neuronal los pesos de inicio, los mismos que generan aleatoriamente con la función `initlay`.

```
net.initFcn = 'initlay';  
pesosEntrada=net.IW{1,1};  
pesosCapa=net.LW{2,1};  
bias_capa_oculta=net.b{1};  
bias_capa_salida=net.b{2};
```

3.7.5. Aprendizaje

En esta fase es necesario identificar el algoritmo de aprendizaje de la red y también la tasa de aprendizaje de la misma, por defecto en este caso vamos a utilizar el algoritmo de *LEVENBERG MARQUART BACK PROPAGATION* a través de la función `trainlm` y una tasa de aprendizaje de 0.8%.

```
net.trainFcn = 'trainlm';  
net.trainParam.lr=0.8;
```

3.7.6. Desempeño de la red

A través de la medida del *MSE (ERROR CUADRADO MEDIO)*, se puede calcular el desempeño efectivo de la red.

```
net.performFcn = 'mse';
```

3.7.7. Épocas y momento

Parámetros necesarios antes de entrenar la red, vamos a trabajar con 1000 iteraciones o épocas y un factor de momento de 0.95 cercano a 1.

```
net.trainParam.epochs=1000;
```

```
net.trainParam.mc=0.95;
```

Con todos los parámetros establecidos y normalizados, utilizamos el comando `preparets`, el mismo que genera las matrices propias del algoritmo de aprendizaje: Jacobianos y Hesianos, almacenados en las variables declaradas, tanto de los datos de simulación como de entrenamiento.

```
[Xs, Xi, Ai, Ts] = preparets (net3, entrada, {}, salida);
```

Xs consistirá en la entrada y la serie de destino que se van a presentar a la red. Xi son los estados de demora de entrada iniciales. Ai estados de retardo de capa (vacío en este caso, ya que no hay retardos de capa a capa), y Ts es la serie de retroalimentación cambiada. Cabe mencionar que para realizar este procedimiento se debe transformar el tipo de datos a tipo *cell*.

3.8. Entrenamiento de la red

Con los parámetros de la preparación se entrena la red, dependiendo de la cantidad de información y del tipo de computador, dependerá el tiempo que demore.

```
[net3, tr] = train (net3, Xs, Ts, Xi, Ai);
```

3.8.1. Cálculo de error

Luego del entrenamiento se generan las estimaciones que se almacenan en la variable Y, luego en una variable aplicamos la función *mse* que calcula el error con los datos de salida de la red y las salidas deseadas o targets.

```
Y = net3 (Xs, Xi, Ai);
```

```
perf = mse (net3,Ts,Y)
```

3.8.2. Entrenamiento

En el entrenamiento el objetivo es que la red aprenda los patrones de generación de nuestra red neuronal, para lo cual podemos ir visualizando como mejora el rendimiento

de la red a través de la herramienta performance que permite ver cómo mejoró el rendimiento de la red durante el entrenamiento.

Rendimiento que se mide en términos de error medio cuadrado, y se muestra en la escala de registro, por lo tanto es mejor mientras más se acerca a cero. Performance se muestra para cada uno de los conjuntos de entrenamiento, validación y prueba.

La versión de la red que mejor hizo en el conjunto de validación es el que se muestra en el gráfico 14-3.

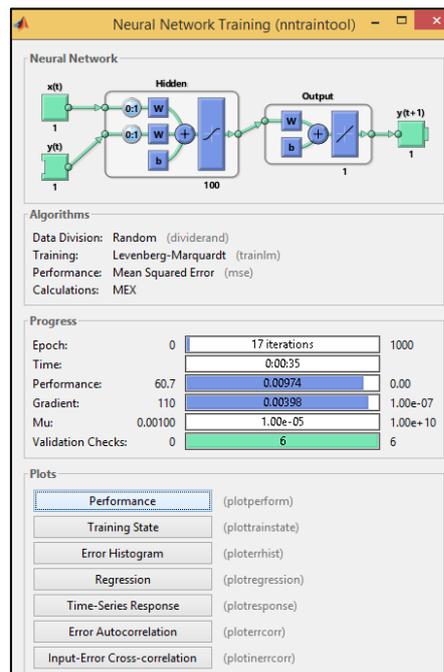


Gráfico 14-3: Parámetros de entrenamiento
Realizado por: Paulina F. Bolaños L

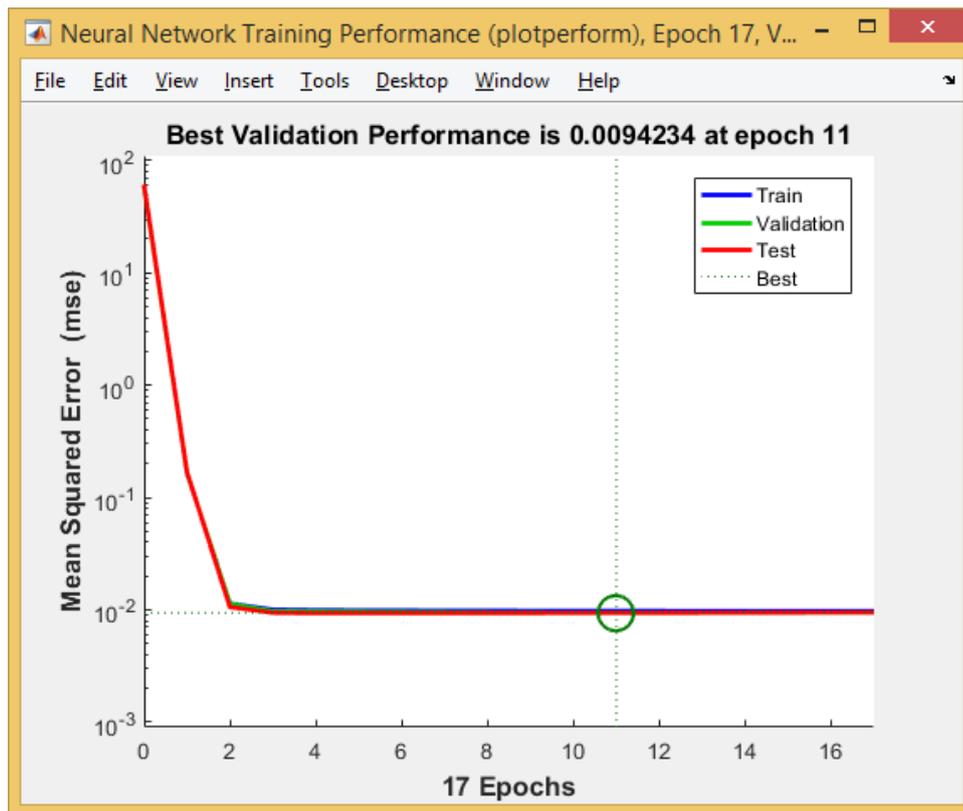


Gráfico 15-3: Mejor performance de validación
Realizado por: Paulina F. Bolaños L

En el gráfico 15-3, se puede observar que el valor del performance es de 0.094, lo que se confirma que es el mejor valor de rendimiento entre los valores de entrenamiento, validación y test, que se produce apenas en la iteración 11 de 17, es decir que no hizo falta llegar a ejecutar las 1000 épocas. Por lo tanto se consideró luego de varias pruebas el mejor resultado de la red.

Otro factor importante en el entrenamiento de la red es el valor de la regresión o R^2 que se genera en cada conjunto de datos, mientras R sea más cercano a 1, el modelo es más eficiente, ver gráfico 16-3.

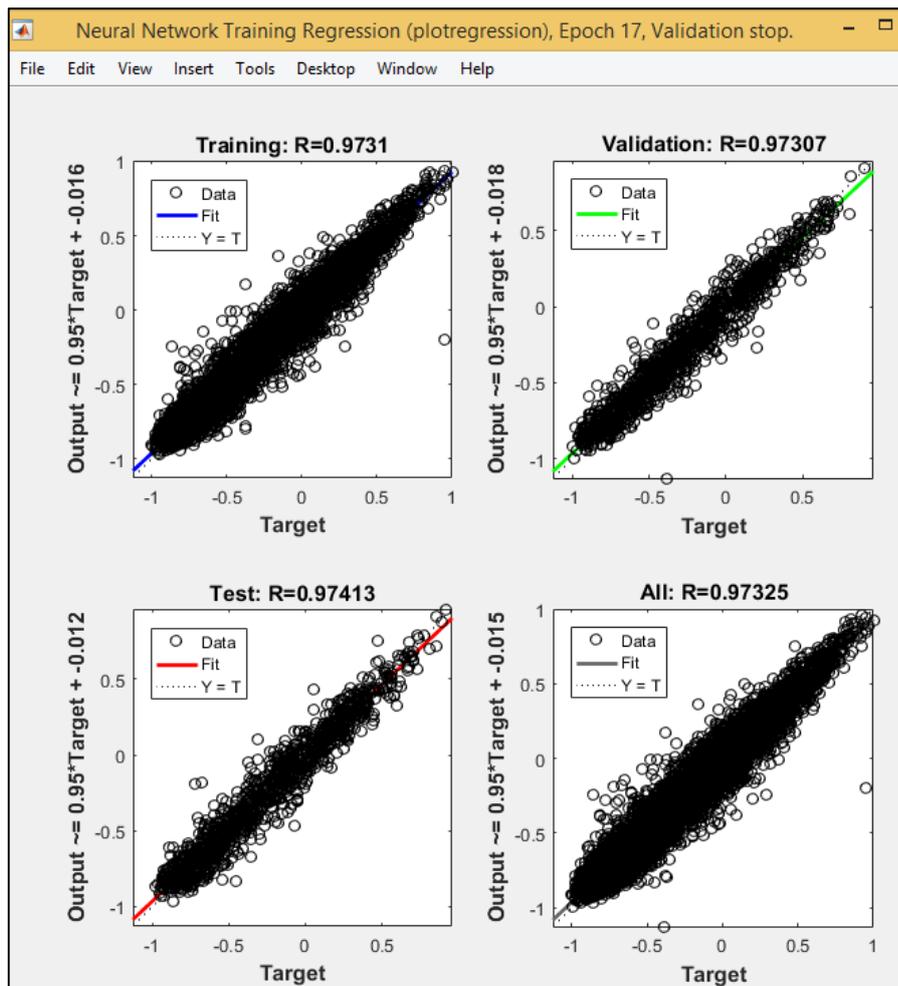


Gráfico 16-3: Valor de la regresión o R^2

Realizado por: Paulina F. Bolaños L

En la gráfica se puede observar que el conjunto de entrenamiento tiene una regresión de 0.973 que es un valor muy bueno considerando que los datos tomados por el sensor no tienen una distribución uniforme sino más bien estocástico. Con el conjunto de validación se puede observar que existe un valor similar de 0.97307, y con el conjunto de prueba o test un valor de 0.97413 es decir que en el test mejoro aún más este coeficiente, dando como resultado total un valor de 0.97325 que garantiza que la red tiene un buen nivel de aprendizaje.

El error de auto correlación que se visualiza en la gráfica 17-3, también nos indica que los valores están dentro de los límites de considerados como confiables, es decir que el margen de error es aceptable.

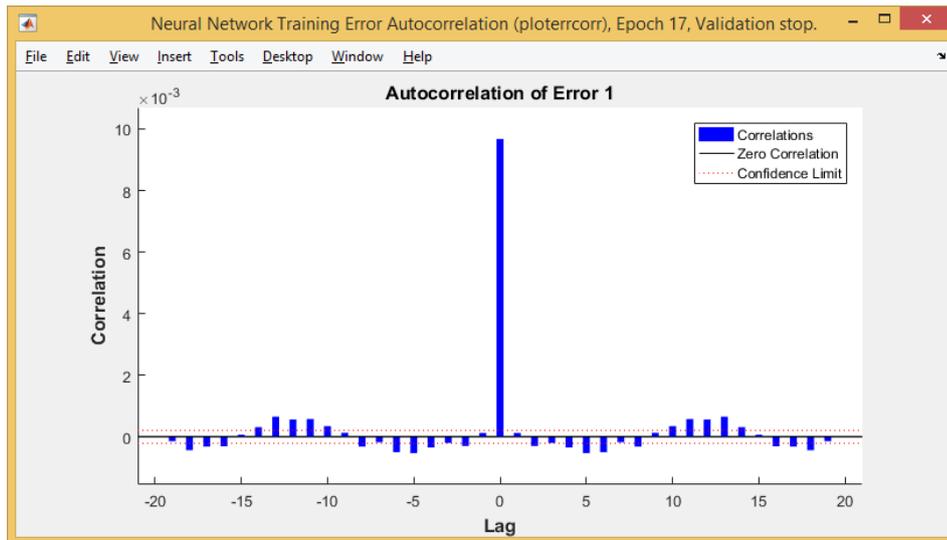


Gráfico 17-3: Valor de auto correlación del error cuadrático medio
 Realizado por: Paulina F. Bolaños L

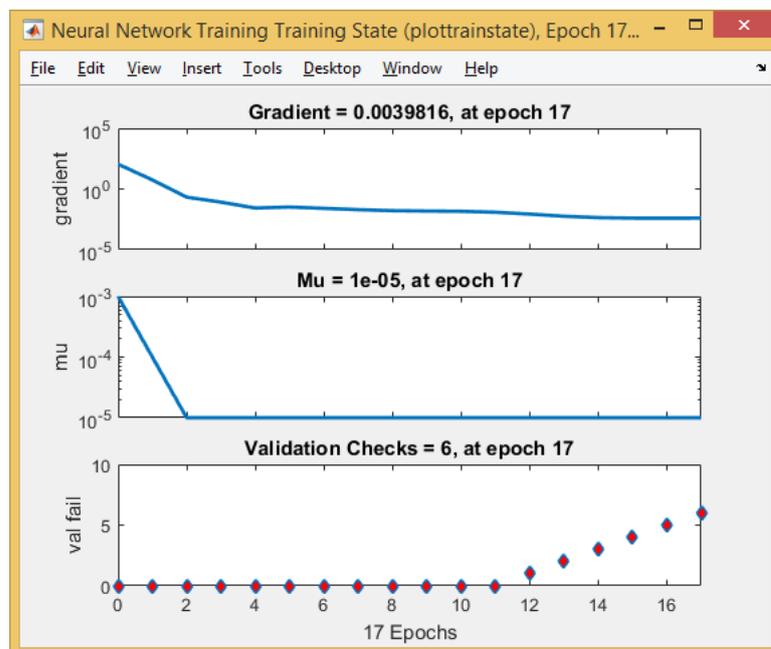


Gráfico 18-3: Parámetros del estado de entrenamiento
 Realizado por: Paulina F. Bolaños L

El estado de entrenamiento nos indica los valores tomados por el gradiente, μ y el mejor de validación que se produce en la época 6 de 17 realizadas.

Considerando estos factores y además de ver el valor del error cálculo en el código que es de: $\text{perf} = 0.0097$, lo que indica un error cuadrático aproximado del 2%, que es considerado como el mejor resultado y por ende se da como red entrenada.

Por último y para garantizar que la red tiene un buen entrenamiento, se puede observar la gráfica que relaciona las salidas deseadas o targets vs las salidas de la red, mediante el comando: `plotresponse (Ts, Y)`, ver gráfica 19-3.

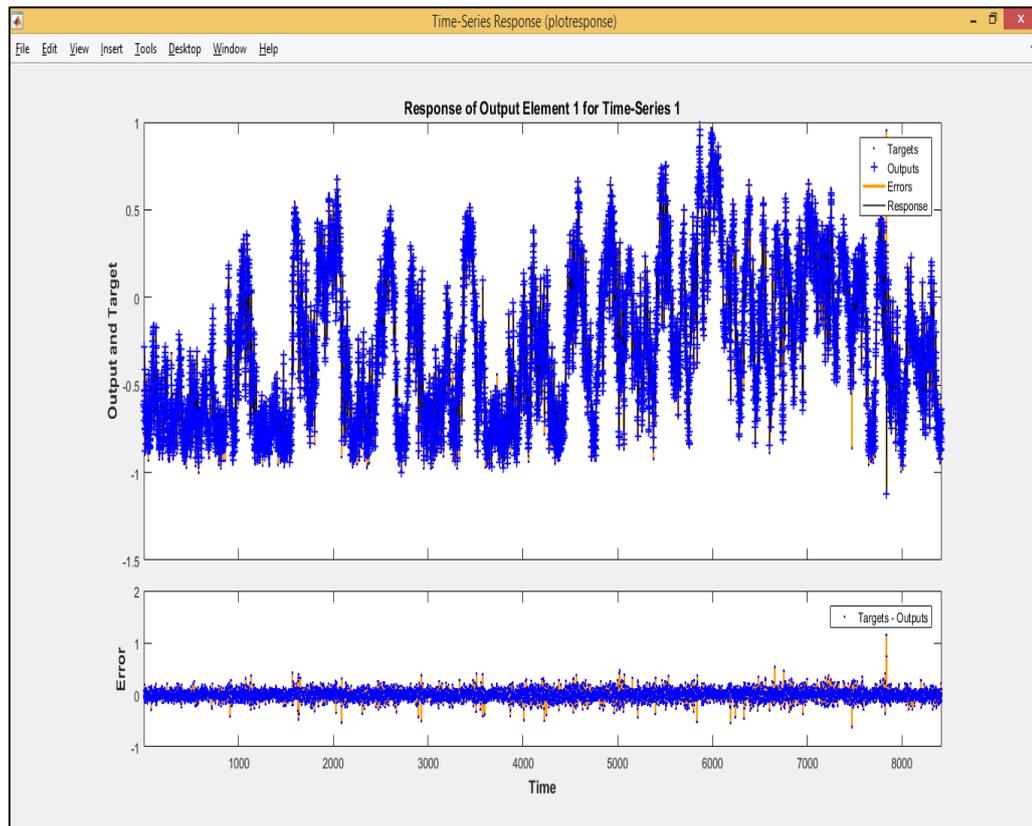


Gráfico 19-3: Relación entre los targets y output de la red
Realizado por: Paulina F. Bolaños L

Donde, los puntos representan los targets y los + representas las salidas de la red, pudiendo observar que la gran mayoría de datos están sobrepuestos, es decir que las salidas pronosticadas son confiables y con un error mínimo que es lógico en un proceso de pronóstico.

En la gráfica 20-3, se puede ver la relación entre todo el conjunto de datos, donde se puede apreciar y comprobar los resultados de regresión.

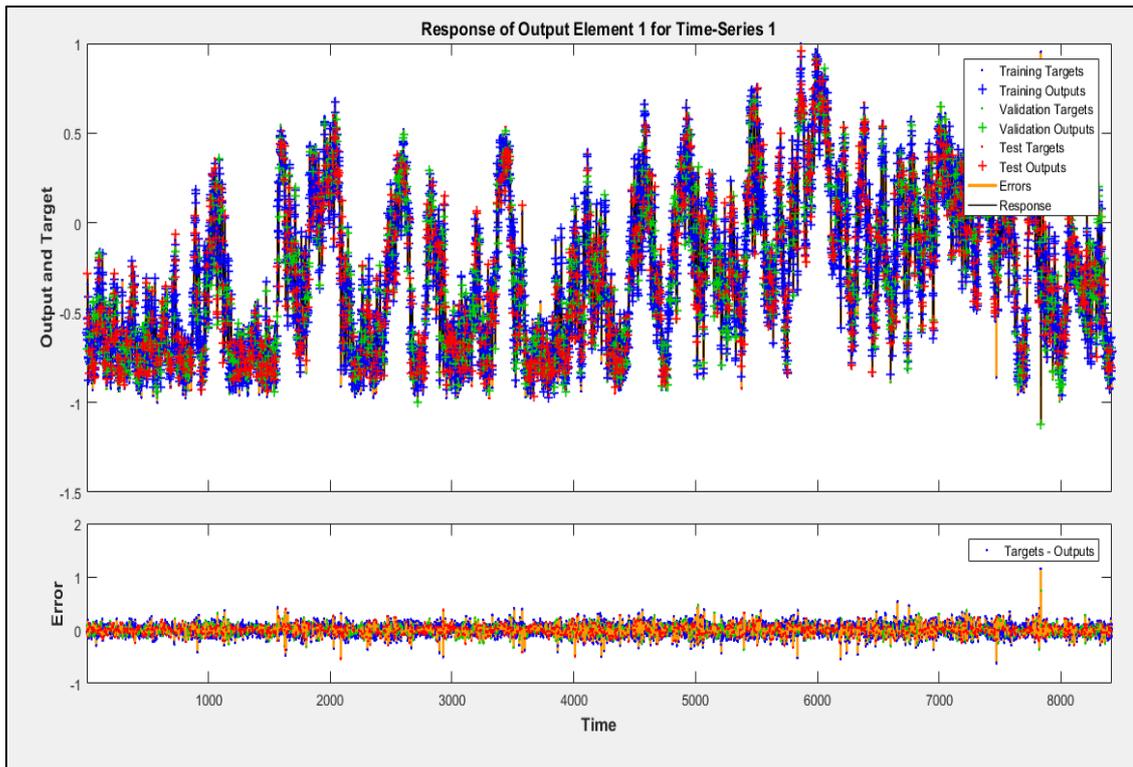


Gráfico 20-3: Relación entre los targets y output etapas de entrenamiento, validación y test.
 Realizado por: Paulina F. Bolaños L

3.9. Simulación

Cuando la red ha sido entrenada satisfactoriamente, se procede a simular la misma con datos que no han sido utilizados, lo que permitirá verificar la eficacia de la red neuronal y más brindar garantía de los valores estimados en cuanto a la velocidad de viento.

CAPITULO IV

4. RESULTADOS Y DISCUSIÓN

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 optimo 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.

Tabla 1-4. Valores óptimos de entrenamiento

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

Realizado por: Paulina F. Bolaños L

4.1. 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:

- a) Con datos conocidos por la red, es decir datos que fueron utilizados en el entrenamiento.
- b) Con datos desconocidos por la red, nunca utilizados en el entrenamiento.

4.1.1. 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 2-4 y gráfica 1-4.

Tabla 2-4. Valores óptimos de entrenamiento horizonte de tres días

Valores óptimos de los parámetros del entrenamiento.	
Observaciones	72
Iteraciones o épocas	21
Neuronas ocultas	100
Tasa de aprendizaje	0.8
Momento	0.95
Algoritmo de aprendizaje	trainlm
Error cuadrático medio o performance	0.0098

Realizado por: Paulina F. Bolaños L

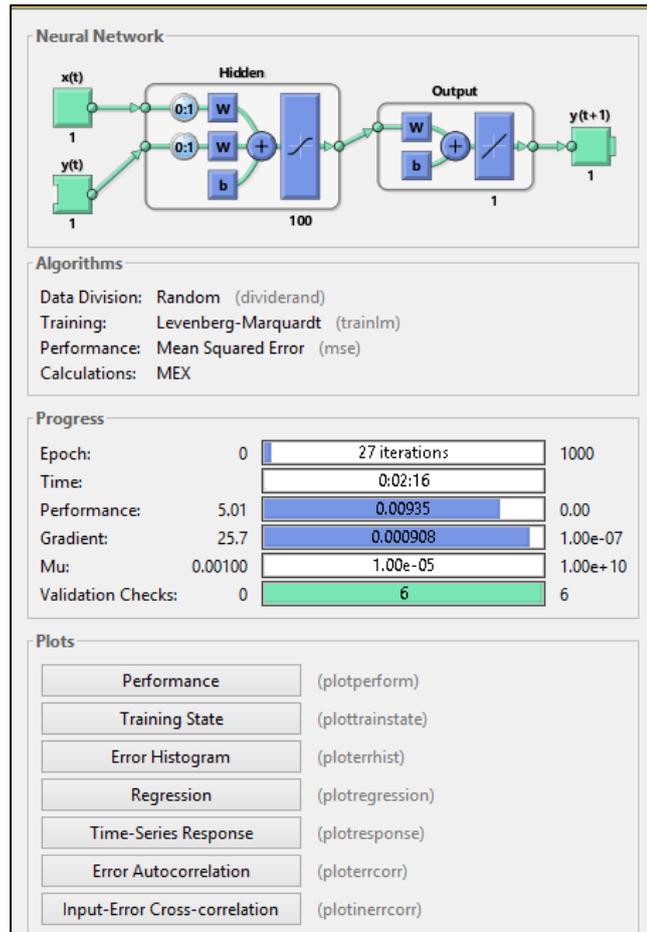


Gráfico 1-4: Entrenamiento de la red – horizonte de tres días.
Realizado por: Paulina F. Bolaños L

En la gráfica 2-4, 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.

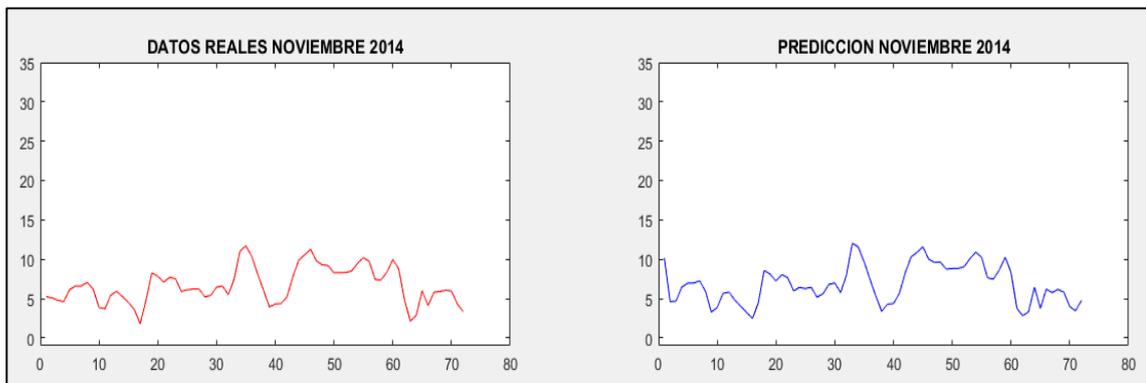


Gráfico 2-4: Curva de carga original vs curva de predicción, tres primeros días noviembre 2014- datos conocidos
Realizado por: Paulina F. Bolaños L

Esto se puede corroborar en la gráfica 1-4, 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 3-4, se puede observar que el mejor valor del performance en la etapa de entrenamiento, validación y test se da en la época 21.

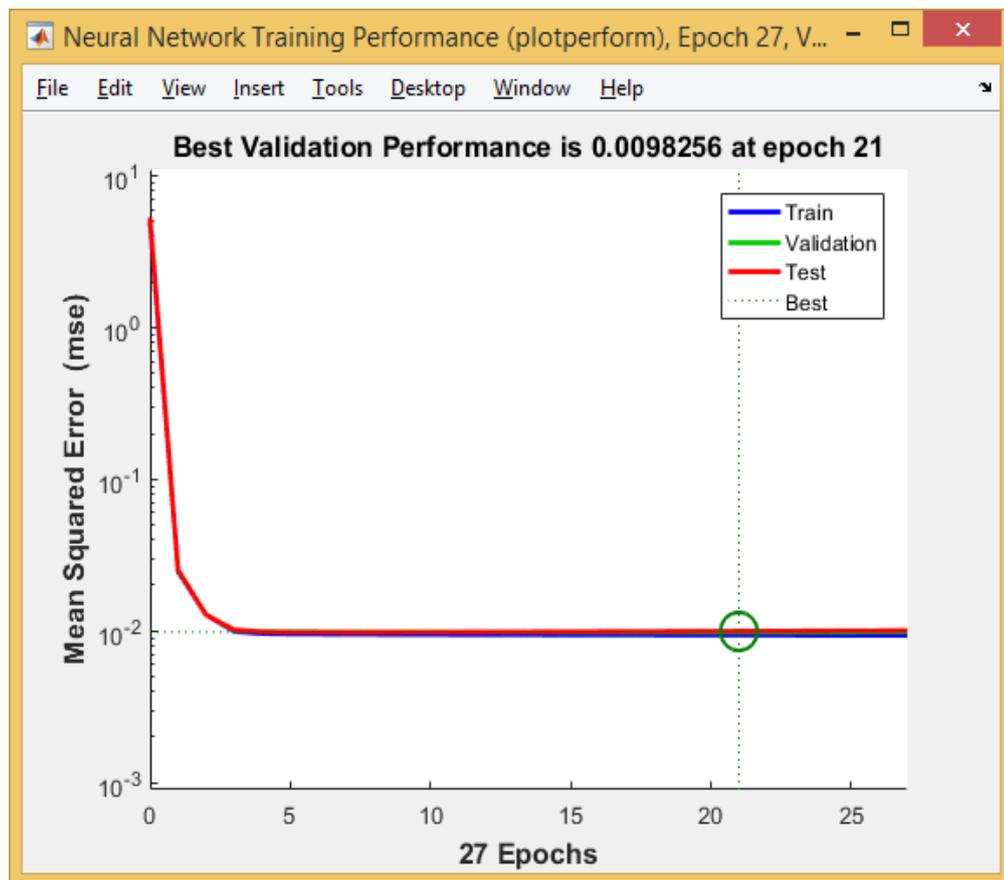


Gráfico 3-4: Mejor performance entrenamiento, validación y test.
Realizado por: Paulina F. Bolaños L

4.1.2. 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 4-4, 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.

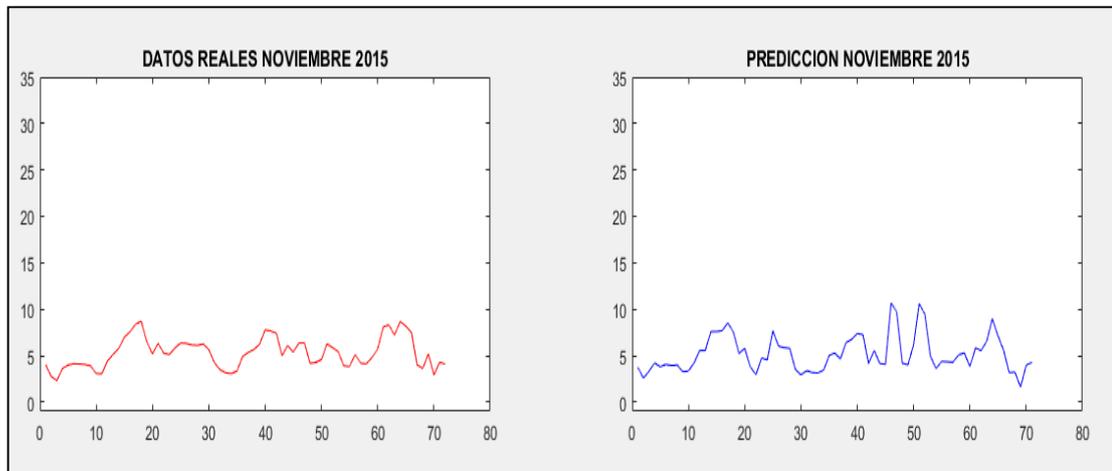


Gráfico 4-4: Curva de carga original vs curva de predicción, 1-3 noviembre 2015 – datos desconocidos por la red.

Realizado por: Paulina F. Bolaños L

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.

4.1.3. 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 3-4. Valores óptimos de entrenamiento, horizonte 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

Realizado por: Paulina F. Bolaños L

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:

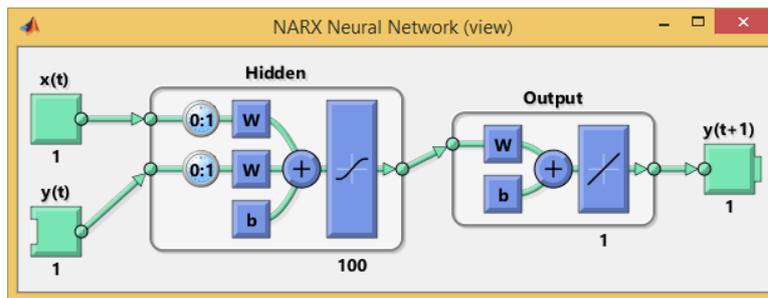


Gráfico 5-4: Modelo de red utilizado

Realizado por: Paulina F. Bolaños L

La gráfica 5-4, muestra el modelo de red utilizada, misma en el caso anterior.

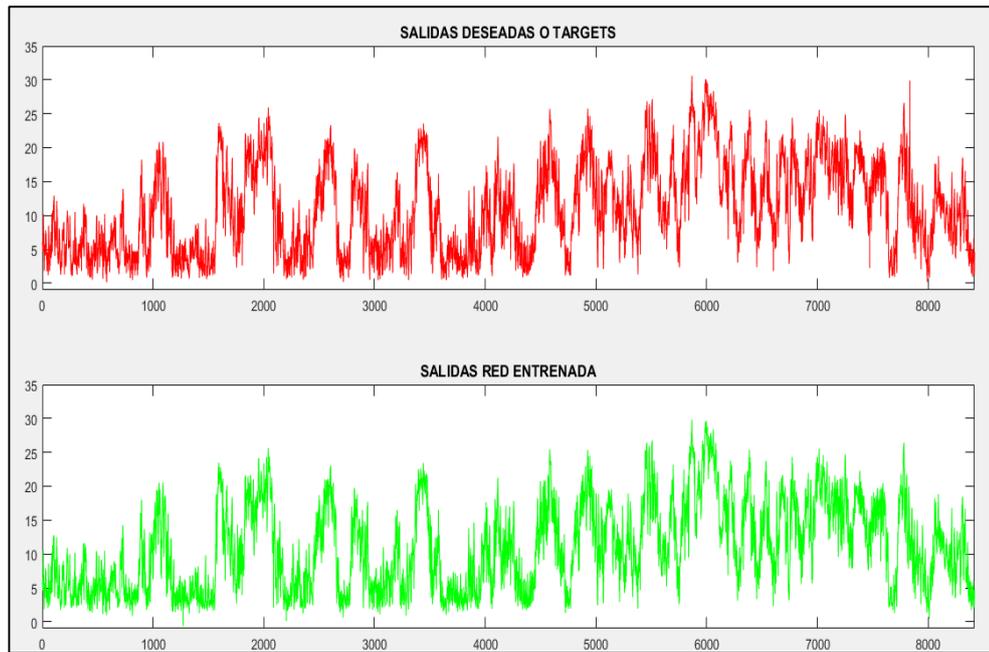


Gráfico 6-4: Datos originales vs datos estimados etapa entrenamiento
Realizado por: Paulina F. Bolaños L

En referencia al gráfico 6-4, 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 7-4.

Para luego observar la gráfica 8-4, 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.

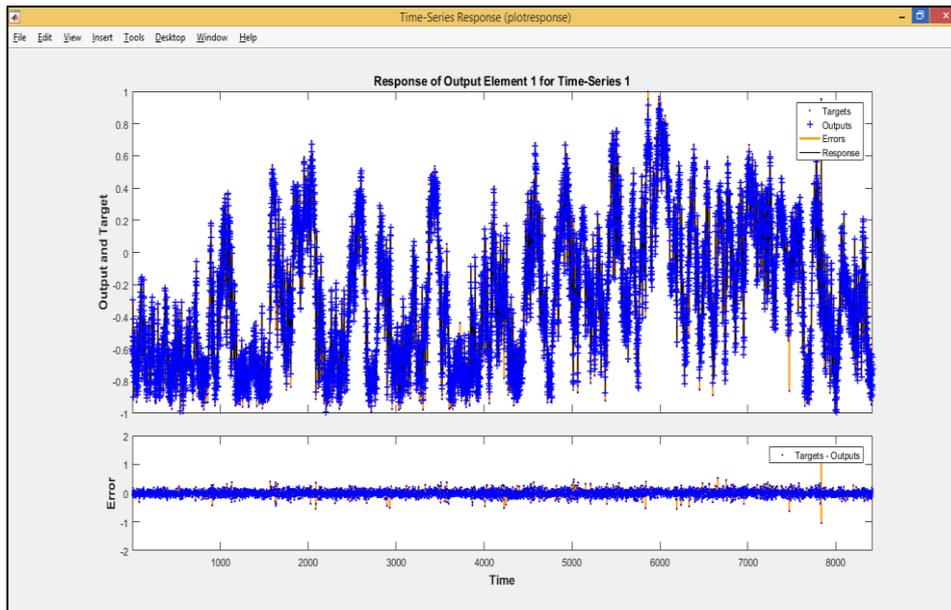


Gráfico 7-4: Plotresponse targets vs output
 Realizado por: Paulina F. Bolaños L

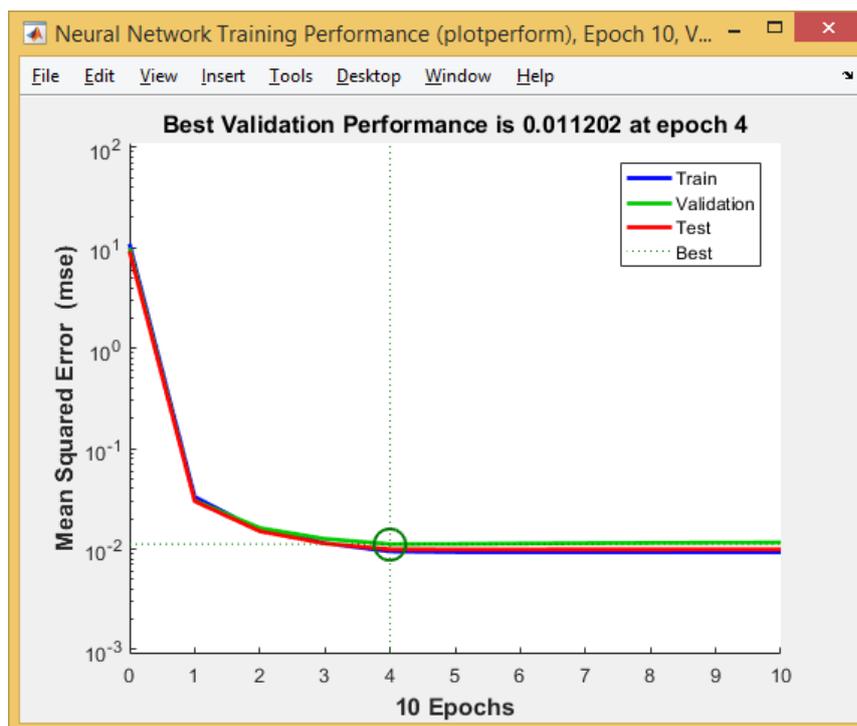


Gráfico 8-4: Plotperform entrenamiento, validación y test.
 Realizado por: Paulina F. Bolaños L

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 9-4.

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.

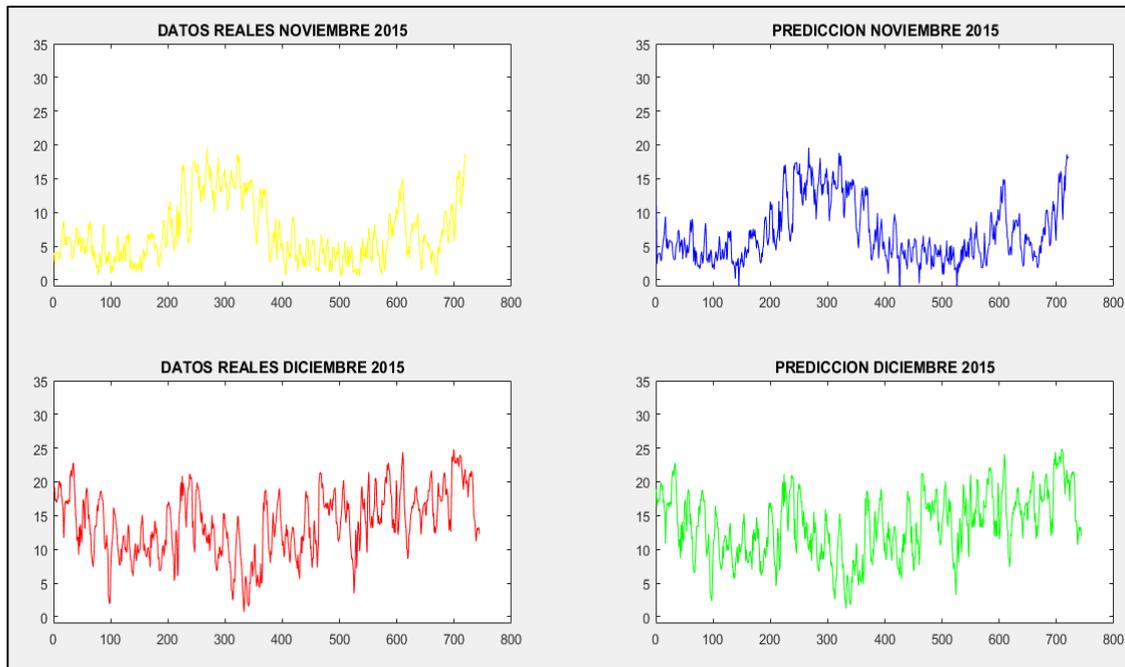


Gráfico 9-4: Curvas de carga originales vs curvas de predicción datos desconocidos
Realizado por: Paulina F. Bolaños L

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 10-4.

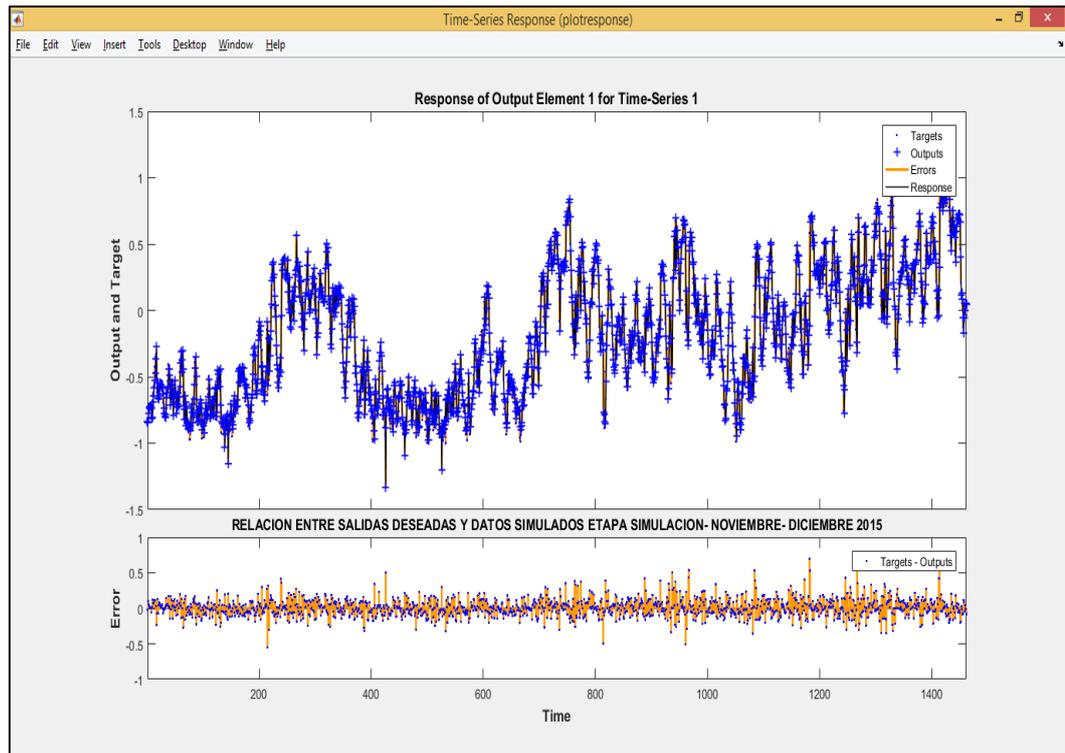


Gráfico 10-4: Respuesta de relación entre los targets y las salidas estimadas
 Realizado por: Paulina F. Bolaños L

4.2. Comparación con otros modelos

4.2.1. Algoritmos de aprendizaje

En el transcurso de la investigación se realizaron pruebas con el mismo modelo de red pero con diferente algoritmo de aprendizaje: como trainlm y trainbr.

La diferencia se puede ver en el error (mse), al momento de simular la red ya que se refleja tanto en sus curvas de datos como el error.

Tabla 4-4. Comparación entre dos algoritmos de aprendizaje

Algoritmo de aprendizaje	Error en datos simulados desconocidos para la red- horizonte de tres días
Algoritmo trainlm	0.38
Algoritmo trainbr	0.68

Realizado por: Paulina F. Bolaños L

Son errores demasiado altos, pero con el algoritmo de trainbr (regularización bayesiana) se presenta más alto el error a diferencia del algoritmo de trainlm (levenberg-Marquardt), por lo tanto, se define para nuestra red como mejor algoritmo trainlm.

Como se puede observar en las gráficas 11-4 y 12-4, el crecimiento del performance con el algoritmo de regularización bayesiana es 1.10 en la época 144 de 524 realizadas. Lo que significa que a más de elevar el valor del error cuadrático este algoritmo toma más tiempo entrenamiento de datos y por ende implica el consumo de recursos del equipo informático que se esté utilizando.

Con los resultados generados con un algoritmo de aprendizaje “trainbr”, no se puede garantizar que las estimaciones sean confiables, eficientes y por lo tanto el modelo de red no sería el más óptimo.

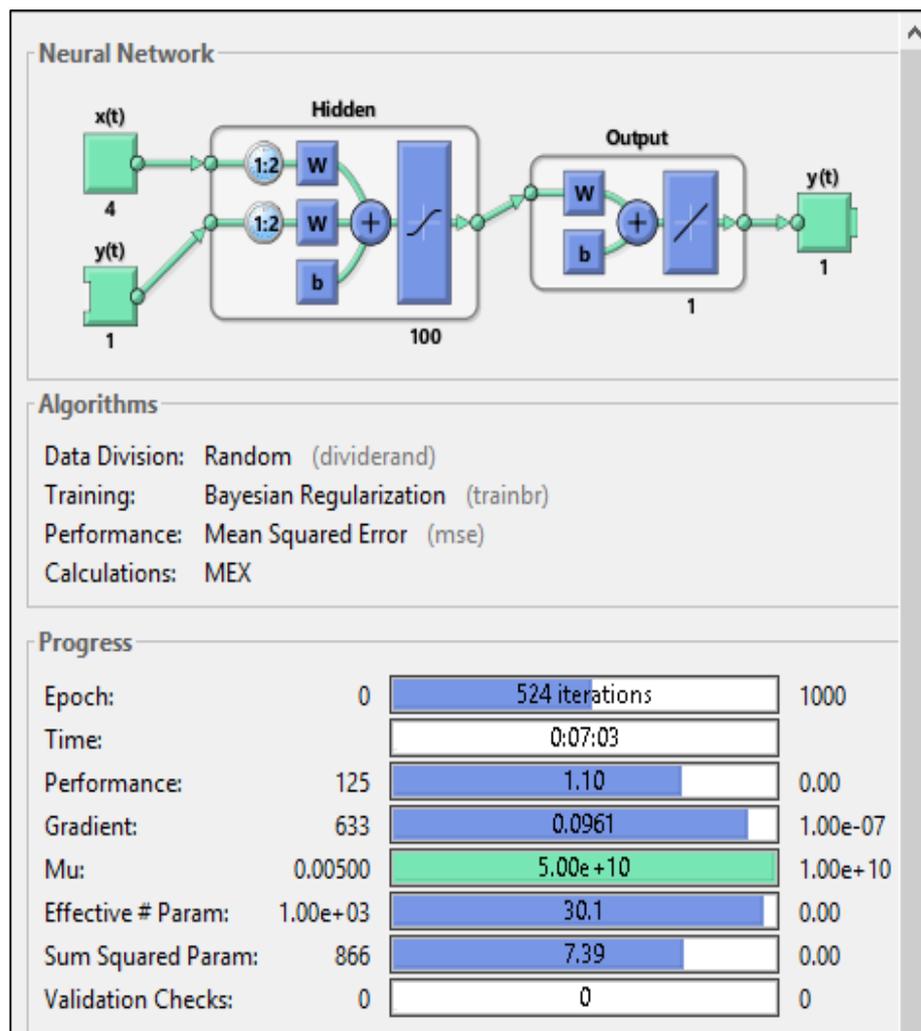


Gráfico 11-4: Entrenamiento con algoritmo de aprendizaje Bayesiano
Realizado por: Paulina F. Bolaños L

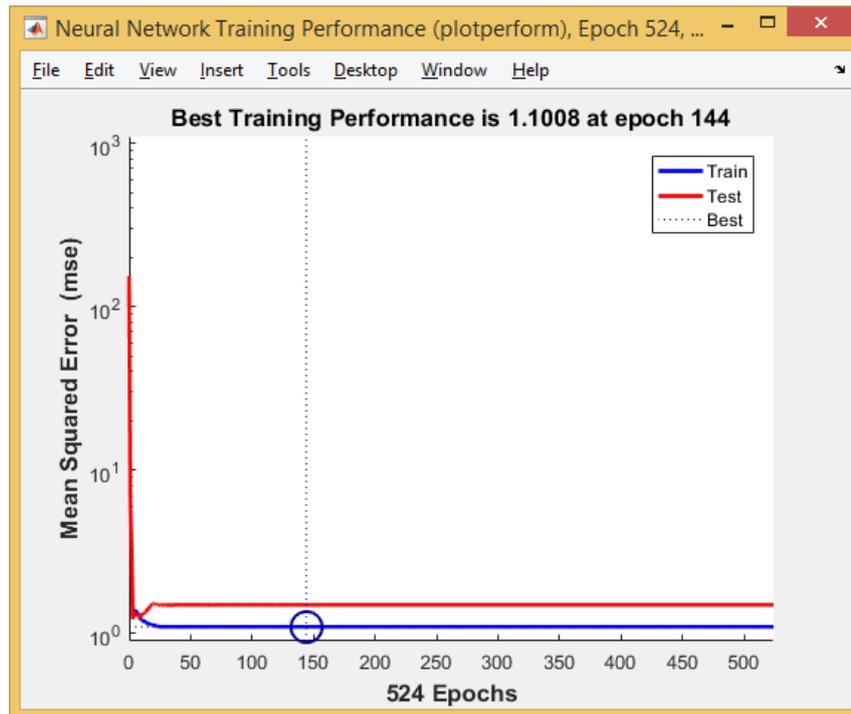


Gráfico 12-4: Entrenamiento con algoritmo de aprendizaje Bayesiano
Realizado por: Paulina F. Bolaños L

4.2.2. Modelos de red neuronal

Para poder seleccionar los mejores parámetros en nuestra red neuronal, también se realizaron pruebas con otros modelos de red, como es el modelo newff (feed forward), el mismo que arrojó los siguientes resultados:

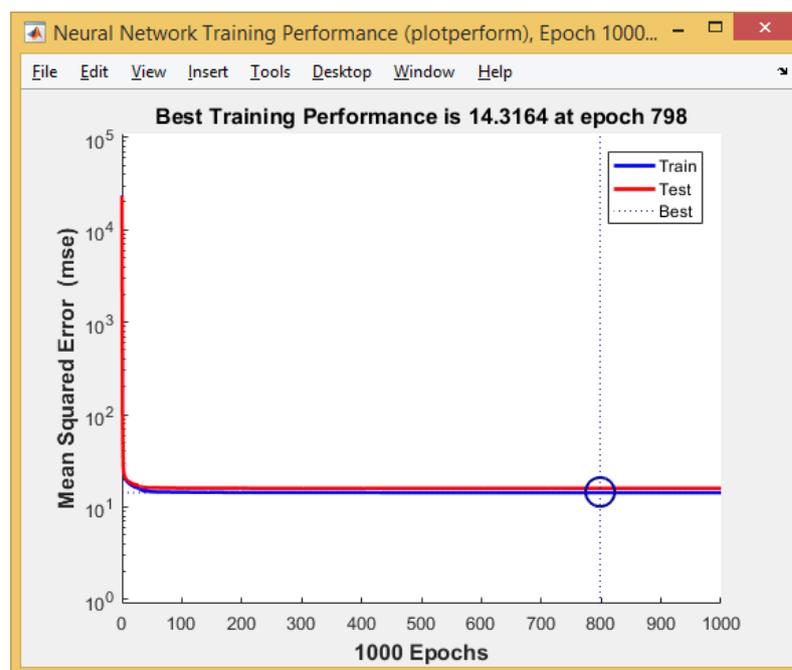


Gráfico 13-4: Entrenamiento con red modelo newff
Realizado por: Paulina F. Bolaños L

El performance que genera es demasiado alto en el entrenamiento de la red, un valor de 14.3, con 798 épocas realizadas, ver gráfica 13-4, es decir el mse o performance crece y toma demasiado tiempo en su ejecución, por lo tanto, este modelo de red se descarta, puesto que el objetivo es alcanzar un nivel de error cuadrático tendiente a cero.

Para asegurarnos de que este modelo no es el adecuado generamos la gráfica de R^2 o regresión, donde se puede observar que los datos están demasiado dispersos y alejados de la realidad, tanto es así que la etapa de validación no presenta coincidencias y la etapa de test tiene un valor de 0.79, que implica pocas coincidencias entre los valores originales y los de predicción en la etapa de entrenamiento, ver gráfico 14-4.

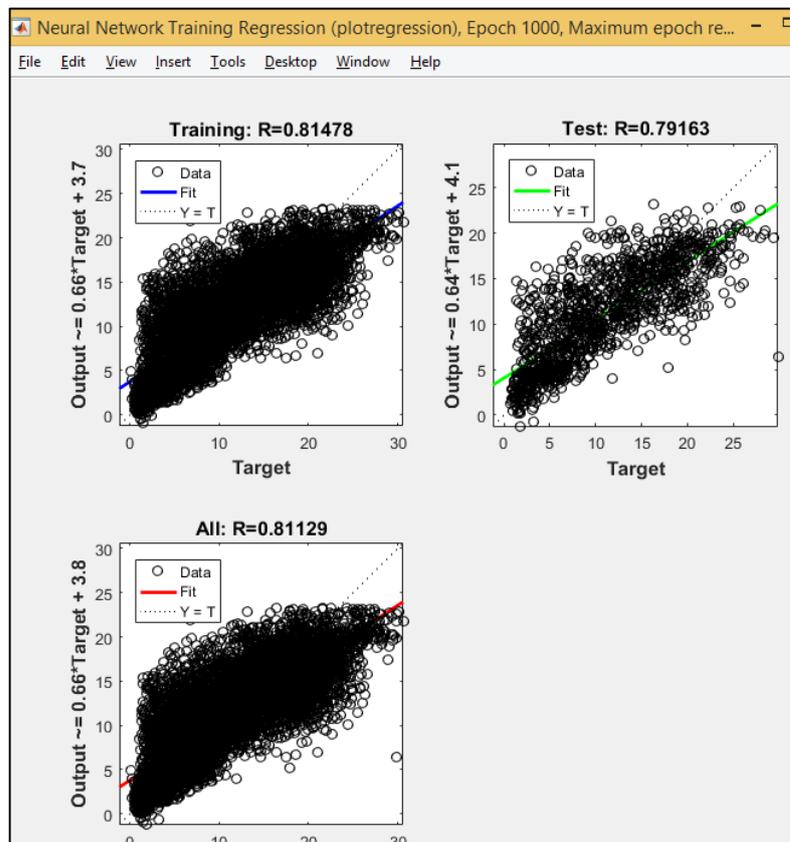


Gráfico 14-4: Regresión o R^2 , con una red modelo newff
Realizado por: Paulina F. Bolaños L

Debido a los resultados generados, esta comparación nos da la seguridad de que el modelo más adecuado para la estimación de la velocidad de viento es el de NARX, modelo dinámico no lineal autoregresivo.

4.7. Comprobación de la Hipótesis de investigación

Para realizar la comprobación de la hipótesis de investigación es necesario primero verificar si los datos estimados por la RNA y los de promedios móviles cumplen con la condición de normalidad, esta condición nos permitirá determinar si es necesario utilizar una prueba estadística paramétrica o no paramétrica.

Para realizar la prueba de normalidad se utilizó el software estadístico SPSS versión 22, estableciendo dos hipótesis la nula y la alternativa, tal como se muestra en la tabla 5-4.

Tabla 5-4. Hipótesis de normalidad

Hipótesis	Enunciado
H0 (nula)	Los datos de las estimaciones de los dos métodos provienen de una distribución normal.
H1(alternativa)	Los datos de las estimaciones de los dos métodos NO provienen de una distribución normal.

Realizado por: Paulina F. Bolaños L

Generándose la prueba de normalidad con un valor de 0.0 mucho menor que la medida establecida que es de 0.05 para el estadístico de Kolmogorov – Smirnov, como se muestra en la tabla 6-4.

Tabla 6-4. Prueba de normalidad, Kolmogorov

Prueba de normalidad			
	Kolmogorov-Smirnov ^a		
	Estadístico	gl	Sig.
Pred_RNA	,040	71	,000
Pred_MP	,040	71	,000

Realizado por: Paulina F. Bolaños L

Esto significa que los datos no cumplen con la condición de normalidad, por lo tanto la hipótesis nula se rechaza y se acepta la alternativa. Lo que indica que se debe utilizar pruebas no paramétricas para la comprobación de la hipótesis.

Dado existe el método de transformación de datos que permite reducir la distancia entre los mismos, y lograr que se cumpla la normalidad de los datos. Para lo cual hemos utilizado la función del logaritmo natural, que según varios expertos estadistas es la función que más aporte tiene para garantizar la normalidad de los datos.

En la tabla 7-4 se muestra los resultados de la transformación de datos utilizando el Ln (logaritmo natural), para luego volver a realizar las pruebas de normalidad.

Tabla 7-4: Transformación de datos función logaritmo natural.

LN-DATOREAL	LN-DATO-RNA	LN-DATO-MP
1,398264104	2,022572096	
1,015834362	0,859204321	
1,286750231	1,336354046	1,112825614
1,38174235	1,353066754	1,06490229
1,416419346	1,336099141	1,196125427
1,411677792	1,329147147	1,36312524
1,396945766	1,282836191	1,403397269
1,361232931	1,016008145	1,408381958
1,121025884	1,084438713	1,390175708
1,117543076	1,482219121	1,300358163
1,487157278	1,599951339	1,206602677
1,635657813	1,696576541	1,257497773
1,756448879	1,889057857	1,43624787
1,944409023	1,956750162	1,632448895
2,023554378	2,083879502	1,786979545
2,127417883	2,155968844	1,914296618
2,162633133	1,779526718	2,034611235
1,869209074	1,522007964	2,106259266
1,647504113	1,786904617	2,06137657
1,84729929	1,548600059	1,915508214
1,656703105	1,598504691	1,792860714
1,634683218	1,705074607	1,72149595
1,763817138	1,808598016	1,717544654
1,84992355	1,765967043	1,686676693
1,843560968	1,743932875	1,75335546
Continuará		

Continúa		
1,815557373	1,735546472	1,819860899
1,810035878	1,766008704	1,836458383
1,833834012	1,660835977	1,823159438
1,733217746	1,358446592	1,819860899
1,443225897	1,147694814	1,793276836
1,246792802	1,073166218	1,683369679
1,149358211	1,076324937	1,494575607
1,118414916	1,17512507	1,287363747
1,201620039	1,585804458	1,173032381
1,588112126	1,617613195	1,157055885
1,674975934	1,656352349	1,324418957
1,734365734	1,76714642	1,508413661
1,826321914	1,984017598	1,667612476
2,051534916	1,974903101	1,747168808
2,036033742	1,938893898	1,879778826
2,0042689	1,436816444	1,976439354
1,606600558	1,786918714	2,030805532
1,807687498	1,606422546	1,900447775
1,681262327	1,810259117	1,819311585
1,84953035	1,754187003	1,701986707
1,851154577	1,26694496	1,782017728
1,424312428	1,398113513	1,797097051
1,452121115	1,500331599	1,727457957
1,519841379	1,769480516	1,595631936
1,836095283	1,655842752	1,466234499
1,767609071	1,600589654	1,617119445
1,688772677	1,264006387	1,716816391
1,358880341	1,299556216	1,765966715
1,341340579	1,558526708	1,620147031
1,632861427	1,287668901	1,476198541
1,430590314	1,336198661	1,453524569
1,4173892	1,526523138	1,475817627
1,569587668	1,713774772	1,498580837
1,744201878	2,031678768	1,474928264
2,091596536	2,07128596	1,585987306
2,117118596	1,883647334	1,825829834
1,975399601	2,089558972	1,998156164
2,159195746	2,080366058	2,063248641
2,102608601	1,952352504	2,08694802
2,013680051	1,166529815	2,081986911
1,070441412	1,396177768	1,453641435
1,452706127	1,320353182	1,363920932

Realizado por: Paulina F. Bolaños L

El resultado de volver a aplicar las pruebas de normalidad arrojaron los resultados, que se muestran en la tabla 8-4, mediante la prueba de Kolmogorov-Smirnov ya que los datos son mayores a 50.

Tabla 8-4. Prueba de normalidad

Prueba de NORMALIDAD			
	Kolmogorov-Smirnov^a		
	Estadístico	gl	Sig.
LN_DATO-RNA	,081	68	,200 [*]
LN_DATO-MP	,081	68	,200 [*]

Realizado por: Paulina F. Bolaños L

Estos resultados muestran una significancia de 0.2 para cada modelo en estudio que supera los 0.05 (medida estándar), luego de haberse transformado los datos estimados, lo que indica que estas series cumplen con la condición de normalidad.

Para luego realizar la comprobación de la hipótesis y poder establecer el mejor modelo para la estimación de velocidad de viento, tal como se muestra en la tabla 9-4.

Tabla 9-4. Hipótesis de comprobación

Hipótesis	Enunciado
H0 (nula)	$\mu_{RNA} = \mu_{MP}$
H1 (alternativa)	$\mu_{RNA} > \mu_{MP}$

Realizado por: Paulina F. Bolaños L

Comparando los promedios y varianzas de la tabla 10-4, da como resultado que el promedio de RNA es mayor que el de promedios móviles. Por lo tanto se da por comprobada la hipótesis de que el método de RNA es mejor que el método estadístico de promedios móviles, en la estimación de la velocidad de viento.

Tabla 10-4. Comparación de medias

Modelo de estimación	Promedio
Red neuronal	3.826
Promedio móvil	3.083

Realizado por: Paulina F. Bolaños L

CONCLUSIONES

1. La estación meteorológica Chimborazo, tiene equipos automatizados que permiten la toma de datos de las diferentes variables meteorológicas de manera remota, lo que ha permitido contar con la información necesaria en el menor tiempo posible.
2. 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.
3. 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).
4. En la implementación del modelo neuronal, mientras más datos se puedan disponer para el entrenamiento de la red, más eficiente será el aprendizaje y por ende la predicción será más cercana y con horizontes más amplios.
5. 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%.

RECOMENDACIONES

1. De acuerdo a las experiencias de esta investigación se puede recomendar, que los datos puedan ser tomados a diferentes alturas, ya que por defecto el sensor está ubicado a 10 m del suelo, pero a mayor altura, la velocidad del viento es mucho más fuerte, lo que podría contribuir a la mayor producción de energía eólica.
2. En futuros trabajos de predicción se recomienda, no dejar de lado el escalamiento o normalización ya que este proceso ayuda en el mejor aprendizaje de la red neuronal, y evita confusiones en la interpretación o aprendizaje del patrón.
3. Cuando se tiene gran cantidad de información, es recomendable realizar procesos de selección de información, con la finalidad de desechar datos que no aporten en el proceso de formación de patrones, uno podría ser la eliminación de mínimas y máximas velocidades de cada día, para así eliminar elementos demasiados dispersos o alejados.
4. Realizar pruebas con otros modelos de red y con diferentes horizontes de predicción con la finalidad de diseñar modelos de red más eficientes.

GLOSARIO

RNA	Red neuronal artificial
MSE	Mean Square Error
RMSE	Root Mean Square Error
NARX	Nonlinear Autoregressive Network with Exogenous
NEWFF	feedforward
NA	Neurona artificial
NB	Neurona Biológica
MLP	Perceptrón multicapa
BP	BackPropagation

BIBLIOGRAFÍA

- Álvarez , O., Montaña, T., Quentin, E., Maldonado, J., & Solano, J. (2013). Homogeneización de series de velocidad del viento mensuales en las estaciones meteorológicas del INAMHI en Loja, Ecuador. *Revista Climatológica*, 13, pp.35-44.
- Ariza, A. (2013). Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución. Pereira, Colombia: Universidad Tecnológica de Pereira.
- Benedetti, F., & Baigún, A. (2012). *Predicción de series de tiempo con Redes Neuronales: Trading usando el Índice Merval*. Argentina.
- Bruner, J. (2001). *El proceso mental en el aprendizaje*. Madrid: Narcea, S. A.
- Bunge, M. (2000). *La investigación científica*. México: Siglo xxi editores.
- Christos Stergiou & Dimitrios Siganos. (2016). *Imperial College London*. Obtenido de https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html
- Cortina Januchs, M. G. (2012). Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos. *Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos*. Madrid, España.
- Flórez López, R., & Fernández Fernández, M. (2008). *Las Redes Neuronales Artificiales*. España: Netbiblo.
- Hilera, J. (1995). *Redes neuronales artificiales. Fundamentos, modelos y aplicaciones*. Estados Unidos: Ra-Ma.
- Hilera, J. R., & Martínez, V. J. (2000). *Redes Neuronales Artificiales - Fundamentos, modelos y aplicaciones*. España: RA-MA.
- Hulshorst, W. (2015). *Leonardo ENERGY*. Recuperado el Septiembre de 2017, de www.leonardo-energy.org/espanol
- Infante, S., Ortega, J., & Cedeño, F. (2008). Estimación de datos faltantes en estaciones meteorológicas de Venezuela vía un modelo de redes neuronales. *Revista de Climatología*, 8, 51-70.
- Jansá Guardiola, J. M. (2015). *Manual del observador de meteorología*. España: INM.
- Llinàs, R. (2003). The contribution of Santiago Ramon y Cajal to functional neuroscience. *Nature Reviews Neuroscience*, 77-80.
- López Álvarez , P., Velo Sabín , R., & Maseda Eimil, F. (Septiembre de 2007). <http://www.aepro.com>. Obtenido de <http://www.aepro.com>: http://www.aepro.com/files/congresos/2007lugo/ciip07_1083_1092.501.pdf
- Malvé, B. (2014). *Foro climático Nacional Napo – Tena situación meteorológica*. Quito.

- Martínez Albaladejo. (2001). Evaluación de la predicción de heladas en el área de Lleida. *Scielo Chile*.
- MEER. (2012). *Ministerio de electricidad y energía renovable*. Obtenido de <http://www.energia.gob.ec/ministerio-de-electricidad-y-energia-renovable-presento-el-primer-atlas-eolico-del-ecuador/>
- Ministerio del Ambiente. (2016). *Senamhi*. (Senamhi, Ed.) Recuperado el 01 de Octubre de 2017, de www.senamhi.gob.pe/main_down.php?ub=mmt&id=cap7
- Moreno, A. (1994). *Aprendizaje automático*. Barcelona, España: Edicions UPC.
- Ouanani, M. (2015). Predicción de la energía eólica utilizando técnicas de aprendizaje automático. *Predicción de la energía eólica utilizando técnicas de aprendizaje automático*. Madrid, España.
- Pajares, G., & De la Cruz, J. (2011). *Aprendizaje automático*. Bogotá: Ra - ma.
- Parreño, J., & Gomez, A. (2004). Pronóstico de la Velocidad y Dirección del Viento mediante Redes Neuronales Artificiales. *ResearchGate*.
- Plaza, E. (1992). Tendencias en Inteligencia Artificial: hacia la cuarta decada. En *Nuevas tendencias en Inteligencia Arti* . Universidad de Deusto.p.379
- Rittenhouse, D. (1981). *La energía eólica*. Argentina: Fraterna.
- Sampieri, H. (2010). *Metodología de la Investigación*. México: McGraw-Hill.
- Tebelskis, J. (1995). *Speech recognition using neural networks*. Pennsylvania: Carnegie Mellon University.
- Unidad de ciencias de la atmósfera. (2014). *Departamento de Ciencias de la Atmósfera*. Obtenido de Departamento de Ciencias de la Atmósfera: www.meteo.fisica.edu.uy/Materias/climatologia/.../Instrumentos%20Meteorologicos.pdf
- Vaughn , N. (2013). *Wind Energy: Renewable Energy and the Environment, Second Edition*. NW: CRC Press.
- Villarrubia, M. (2012). *Ingeniería de la energía eólica*. Barcelona: Marcombo.
- Viñuela, P. I., & Galván León, I. (2004). *Redes de neuronas artificiales: un enfoque práctico*. Pearson Educación.

ANEXOS

Anexo A. Datos obtenidos de la estación meteorológica

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
12	18/10/2014	01/01/1900 11:00	7,12	115,36
13	18/10/2014	01/01/1900 12:00	7,32	122,16
14	18/10/2014	01/01/1900 13:00	7,20	122,77
15	18/10/2014	00/01/1900 14:00	4,46	233,93
16	18/10/2014	00/01/1900 15:00	4,37	275,31
17	18/10/2014	00/01/1900 16:00	1,84	271,47
18	18/10/2014	00/01/1900 17:00	2,52	163,53
19	18/10/2014	00/01/1900 18:00	4,44	100,13
20	18/10/2014	00/01/1900 19:00	4,82	104,62
21	18/10/2014	00/01/1900 20:00	5,69	105,01
22	18/10/2014	00/01/1900 21:00	4,06	113,62
23	18/10/2014	00/01/1900 22:00	5,11	106,75
24	18/10/2014	00/01/1900 23:00	4,63	101,76
25	19/10/2014	00/01/1900 0:00	5,50	107,38
26	19/10/2014	00/01/1900 1:00	4,12	138,24
27	19/10/2014	00/01/1900 2:00	4,07	109,19
28	19/10/2014	00/01/1900 3:00	4,79	107,65
29	19/10/2014	00/01/1900 4:00	6,88	109,32
30	19/10/2014	00/01/1900 5:00	7,79	101,72
31	19/10/2014	00/01/1900 6:00	6,20	101,01
32	19/10/2014	00/01/1900 7:00	6,77	100,96
33	19/10/2014	00/01/1900 8:00	7,42	96,03
34	19/10/2014	00/01/1900 9:00	6,98	108,94
35	19/10/2014	00/01/1900 10:00	5,79	115,33
162	24/10/2014	00/01/1900 17:00	2,17	277,49
163	24/10/2014	00/01/1900 18:00	1,78	270,85
164	24/10/2014	00/01/1900 19:00	1,79	103,29
165	24/10/2014	00/01/1900 20:00	1,81	92,41
166	24/10/2014	00/01/1900 21:00	1,24	253,77
167	24/10/2014	00/01/1900 22:00	1,55	100,22
168	24/10/2014	00/01/1900 23:00	1,80	245,68
169	25/10/2014	00/01/1900 0:00	2,99	267,95

170	25/10/2014	00/01/1900 1:00	3,12	265,26
171	25/10/2014	00/01/1900 2:00	3,05	267,46
172	25/10/2014	00/01/1900 3:00	2,22	274,73
173	25/10/2014	00/01/1900 4:00	3,98	242,34
174	25/10/2014	00/01/1900 5:00	4,91	226,15
175	25/10/2014	00/01/1900 6:00	3,41	233,74
176	25/10/2014	00/01/1900 7:00	2,42	238,49
177	25/10/2014	00/01/1900 8:00	3,10	232,71
178	25/10/2014	00/01/1900 9:00	5,08	216,39
179	25/10/2014	00/01/1900 10:00	5,23	247,15
180	25/10/2014	00/01/1900 11:00	6,90	284,04
181	25/10/2014	00/01/1900 12:00	7,94	260,23
182	25/10/2014	00/01/1900 13:00	7,79	251,23
190	25/10/2014	00/01/1900 21:00	8,09	238,32
191	25/10/2014	00/01/1900 22:00	8,29	239,09
192	25/10/2014	00/01/1900 23:00	8,96	294,90
193	26/10/2014	00/01/1900 0:00	7,28	291,92
194	26/10/2014	00/01/1900 1:00	6,18	282,16
195	26/10/2014	00/01/1900 2:00	7,45	284,62
196	26/10/2014	00/01/1900 3:00	9,00	279,09
197	26/10/2014	00/01/1900 4:00	6,93	277,60
198	26/10/2014	00/01/1900 5:00	5,38	277,73
199	26/10/2014	00/01/1900 6:00	2,54	287,73
200	26/10/2014	00/01/1900 7:00	1,30	240,55
201	26/10/2014	00/01/1900 8:00	3,28	193,73
202	26/10/2014	00/01/1900 9:00	2,94	215,96
203	26/10/2014	00/01/1900 10:00	3,12	244,78
204	26/10/2014	00/01/1900 11:00	4,75	223,46
205	26/10/2014	00/01/1900 12:00	4,75	258,15
206	26/10/2014	00/01/1900 13:00	4,51	247,64
207	26/10/2014	00/01/1900 14:00	5,09	237,17
208	26/10/2014	00/01/1900 15:00	5,81	264,06
209	26/10/2014	00/01/1900 16:00	5,30	284,61
210	26/10/2014	00/01/1900 17:00	2,58	249,54
211	26/10/2014	00/01/1900 18:00	2,68	207,70
212	26/10/2014	00/01/1900 19:00	2,94	214,58
213	26/10/2014	00/01/1900 20:00	2,43	181,60
214	26/10/2014	00/01/1900 21:00	3,22	107,28
215	26/10/2014	00/01/1900 22:00	2,80	133,26
216	26/10/2014	00/01/1900 23:00	4,01	127,60
217	27/10/2014	00/01/1900 0:00	4,44	113,30
218	27/10/2014	00/01/1900 1:00	5,24	120,86
219	27/10/2014	00/01/1900 2:00	6,52	109,74
1252	09/12/2014	00/01/1900 3:00	1,87	86,79
1253	09/12/2014	00/01/1900 4:00	2,26	162,54
1254	09/12/2014	00/01/1900 5:00	2,74	314,30
1255	09/12/2014	00/01/1900 6:00	1,98	137,59
1256	09/12/2014	00/01/1900 7:00	0,71	193,16
1257	09/12/2014	00/01/1900 8:00	1,56	249,80

1258	09/12/2014	00/01/1900 9:00	2,65	160,07
1259	09/12/2014	00/01/1900 10:00	3,99	253,62
1260	09/12/2014	00/01/1900 11:00	5,78	270,03
1261	09/12/2014	00/01/1900 12:00	5,06	271,58
1504	19/12/2014	00/01/1900 15:00	5,99	271,39697
1505	19/12/2014	00/01/1900 16:00	4,59	281,735859
1506	19/12/2014	00/01/1900 17:00	3,23	283,940236
1507	19/12/2014	00/01/1900 18:00	1,18	219,908838
1508	19/12/2014	00/01/1900 19:00	1,96	268,797811
1509	19/12/2014	00/01/1900 20:00	1,44	273,337542
1510	19/12/2014	00/01/1900 21:00	1,59	292,44133
1952	07/02/2015	06/02/1900 22:00	1,11288232	277,600421
1953	07/02/2015	06/02/1900 23:00	2,81261852	298,058838
1954	08/02/2015	07/02/1900 0:00	3,50184739	305,364141
1955	08/02/2015	07/02/1900 1:00	2,99830513	253,34032
1956	08/02/2015	07/02/1900 2:00	3,21706625	285,502862
1957	08/02/2015	07/02/1900 3:00	3,8197069	325,446212
1958	08/02/2015	07/02/1900 4:00	2,89829369	305,347054
1959	08/02/2015	07/02/1900 5:00	1,67035109	321,847727
1960	08/02/2015	07/02/1900 6:00	0,20058182	317,643939
1961	08/02/2015	07/02/1900 7:00	0,25720699	257,233249
1962	08/02/2015	07/02/1900 8:00	2,01593308	142,891414
1963	08/02/2015	07/02/1900 9:00	2,97917702	172,217845
2564	05/03/2015	03/03/1900 10:00	8,91346641	108,090825
2565	05/03/2015	03/03/1900 11:00	8,01971608	102,820118
2566	05/03/2015	03/03/1900 12:00	7,53018182	101,155135
2567	05/03/2015	03/03/1900 13:00	6,97165194	108,158333
2568	05/03/2015	03/03/1900 14:00	6,43136431	113,922222
2569	05/03/2015	03/03/1900 15:00	4,1605862	148,712121

Anexo B. Código fuente

```
clear all;
clear history;
load paupau_2_1.mat

%-----
% Variables de Referencia
%-----
% input = entradas_3(:,3) datos de DIRECCION DE VIENTO
% output = salidas_3(:,1) DATOS DE VELOCIDAD DE VIENTO

xx=entradas_3(1:8420,3);%vector entrada
tt=salidas_3(1:8420,1); %vector salida
ss=DIRECC(8421:9884,1); %vector de entrada a simular
ss1=SALIDASVELOCIDAD9885(8421:9884,1);%vector de salidas a predecir

%%NORMALIZACION DE DATOS
[pn,minp,maxp,tn,mint,maxt] = premmx(xx,tt);%%entradas y salidas
8420 datos
[pnS,minpS,maxpS,tnS,mintS,maxtS] = premmx(ss,ss1);%NORMALIZACION
DE ENTRADAS Y SALIDAS NOVIEMBRE - DICIEMBRE 2015
%TRANSPUESTAS DE LOS VECTORES DE ENTRADAS Y SALIDAS
PN1=pn';%transpuesta del vector entrada normalizado
TN1=tn';%transpuesta del vector target normalizado
PN2=pnS';%transpuesta del vector entrada a simular NOV-DIC 2015
normalizado
TN2=tnS';%transpuesta del vector target o salida a predecir NOV-DIC
2015 normalizado
%%CONVERSION DE DATOS NUMERICOS A TIPO CELL
entrada=num2cell(PN1); %vector entrada
salida=num2cell(TN1);%vector salida
entradaS=num2cell(PN2); %vector entrada simular
salidaS=num2cell(TN2);%vector salida a predecir

%%CREACION DE LA RED NARX
net = narxnet(1:2,1:2,100);%Creacion de la red NARX
net3 = removedelay(net); %Eliminacion de retardos
%view(net)%Visualizar el modelo mde red
%DISTRIBUCION DE INFORMACION
net.divideFcn = 'dividerand'; %OJO
net.divideMode = 'value'; %OJO
net.divideParam.trainRatio = 70/100;%DIVISION DATOS DE
ENTRENAMIENTO ALEATORIO (DATOS PARA EL ENTRENAMIENTO)
net.divideParam.valRatio = 15/100;%DIVISION DATOS DE ENTRENAMIENTO
ALEATORIO (DATOS PARA VALIDACION)
net.divideParam.testRatio = 15/100;%DIVISION DATOS DE ENTRENAMIENTO
ALEATORIO (DATOS PARA TEST O PRUEBA)
%PESOS Y BIAS
net.initFcn = 'initlay';%INICIALIZAR LOS PESOS (FUNCION POR
DEFECTO)
pesosEntrada=net.IW{1,1}%VISUALIZAR LOS PESOS QUE TOMAN AL
INICIALIZAR LA RED CAPA pesosEntrada
pesosCapa=net.LW{2,1}%VISUALIZAR LOS PESOS QUE TOMAN AL INICIALIZAR
LA RED CAPA pesosCapa
bias_capa_oculta=net.b{1}%VISUALIZAR LOS biases de cada neurona de
la capa oculta
bias_capa_salida=net.b{2}%VISUALIZAR LOS biases de cada neurona de
la capa salida
%DESEMPEÑO DE LA RED
```

```

net.performFcn = 'mse';%FUNCION DE CONTROL MSE (ERROR CUADRADO
MEDIO)
%APRENDIZAJE DE LA RED
net.trainFcn = 'trainlm';%FUNCION DE ENTRENAMIENTO
TRAINLM(ALGORITMO DE LEVENBERG MARQUART BACK PROPAGATION)
net.trainParam.lr=0.8;%tasa de aprendizaje
%EPOCAS Y MOMENTO
net.trainParam.epochs=1000;%numero de iteraciones
net.trainParam.mc=0.95;%factor momento
%PREPARACION DE DATOS Y ENTRENAMIENTO DE LA RED 8420 datos
[Xs,Xi,Ai,Ts] = preparets(net3,entrada,{},salida);
[net3,tr] = train(net3,Xs,Ts,Xi,Ai);
%PREPARACION DATOS A PREDECIR
[XsS,XiS,AiS,TsS] = preparets(net3,entradaS,{},salidaS);

%CALCULOS DE ERROR
view(net3)
Y = net3(Xs,Xi,Ai);
perf = mse(net3,Ts,Y)%CALCULO DE ERROR DATOS SIMULADOS
YS = net3(XsS,XiS,AiS);
perfS = mse(net3,TsS,YS)%CALCULO DE ERROR DATOS PREDICHOS

%GRAFICO DE COMPARACION TARGET VS OUTPUT
plotresponse(Ts,Y)%grafica relacionada entre las salidas deseadas y
los datos tomados del sensor ETAPA ENTRENAMIENTO
title('RELACION ENTRE SALIDAS DESEADAS Y DATOS SIMULADOS ETAPA
ENTRENAMIENTO');
figure
plotresponse(TsS,YS)%grafica relacionada entre las salidas
deseadas y los datos tomados del sensor NOVIEMBRE - DICIEMBRE 2015
title('RELACION ENTRE SALIDAS DESEADAS Y DATOS SIMULADOS ETAPA
SIMULACION- NOVIEMBRE- DICIEMBRE 2015');
qq=cell2mat(Y);%salida entrenamiento normalizado
G=postmnmx(qq,mint,maxt);%salida entrenamiento real
GG=G';
an = sim(net3,Xs);%simulacion red VALORES NORMALIZADOS
anS=sim(net3,XsS);%simulacion red valores noviembre y diciembre
2015
q=cell2mat(an);
qS=cell2mat(anS);%datos convertidos de cell a matematicos -
noviembre -diciembre 2015
A=postmnmx(q,mint,maxt);%salida simulacion valor REAL
AS=postmnmx(qS,mintS,maxtS);%SALIDA SIMULACION NOVIEMBRE -
DICIEMBRE 2015
AA=A';
AAS=AS';
%%%GRAFICOS DE SALIDAS DESEADAS VS SALIDA DE ENTRENAMIENTO
figure
subplot(2,1,1);
plot(tt, 'r')
title('SALIDAS DESEADAS O TARGETS');
axis ([ 0 8420 -1 35])
subplot(2,1,2);
plot(AA, 'g')
title('SALIDAS RED ENTRENADA');
axis ([ 0 8420 -1 35])
figure
% %%%%%%%%%%%
nov2015=ss1(1:720,1);%datos reales
dic2015=ss1(721:1464,1);%datos reales
nov2015S=AAS(1:720,1);%datos simulacion

```

