



UNAP



FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

**ESCUELA PROFESIONAL DE INGENIERÍA DE
SISTEMAS E INFORMÁTICA**

TESIS

**DESARROLLO DE UNA RED NEURONAL PARA ESTIMAR LA DEMANDA
DE ENERGÍA ELÉCTRICA EN LA CIUDAD DE NAUTA**

**PARA OPTAR EL TÍTULO PROFESIONAL DE
INGENIERO DE SISTEMAS E INFORMÁTICA**

PRESENTADO POR:

**LUIS ENRIQUE FLORES ECHEVARRIA
MARTIN ALONSO OCMIN MORALES**

ASESOR:

Ing. CARLOS ALBERTO GARCIA CORTEGANO, Dr.

IQUITOS, PERÚ

2022

ACTA DE SUSTENTACIÓN



FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

ACTA DE SUSTENTACIÓN DE TESIS – 2022

En Iquitos, en la modalidad presencial, a los 24 días del mes de octubre del 2022, a horas 6:00pm, se dio inicio a la sustentación de la Tesis titulada: "DESARROLLO DE UNA RED NEURONAL PARA ESTIMAR LA DEMANDA DE ENERGIA ELÉCTRICA EN LA CIUDAD DE NAUTA", presentado por los bachilleres: Martin Alonso Ocmin Morales y Luis Enrique Flores Echevarría, para optar el Título Profesional de Ingeniero de Sistemas e Informática, que otorga la Universidad de acuerdo a Ley y Estatuto.

El Jurado calificador y dictaminador designado mediante Resolución Decanal N° 206-D-FISI-UNAP-2022, está integrado por:

- | | |
|---|------------|
| ✓ Ing. Alejandro Reátegui Pezo, Dr. | Presidente |
| ✓ Ing. José Edgar García Díaz, Mgr. | Miembro |
| ✓ Ing. Jimmy Max Ramirez Villacorta, Mgr. | Miembro |



Luego de haber el Jurado escuchado con atención y formulado las preguntas necesarias, las cuales fueron respondidas: CORRECTAMENTE

El jurado después de las deliberaciones correspondientes, llegó a las siguientes conclusiones:

La Sustentación de la Tesis ha sido: APROBADA con la calificación de: 18

Estando los Bachilleres aptos para obtener el Título Profesional de **Ingeniero de Sistemas e Informática**.

Siendo las 19:17 se dio por terminado el acto de sustentación.

Ing. Alejandro Reátegui Pezo, Dr.
Presidente

Ing. José Edgar García Díaz, Mgr.
Miembro

Ing. Jimmy Max Ramirez Villacorta, Mgr.
Miembro

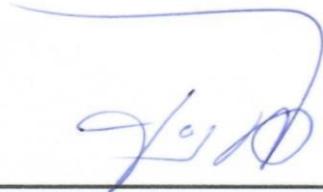
Ing. Carlos Alberto García Cortegano, Dr.
ASESOR

**TESIS APROBADA EN SUSTENTACIÓN PÚBLICA EL DÍA LUNES 24 DE
OCTUBRE DEL 2022**

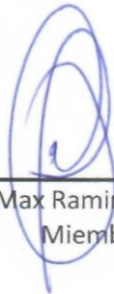
**“DESARROLLO DE UNA RED NEURONAL PARA ESTIMAR LA DEMANDA
DE ENERGÍA ELÉCTRICA EN LA CIUDAD DE NAUTA”**



Ing^o Alejandro Reátegui Pezo, Dr.
Presidente



Ing^o José Edgar García Díaz, Mgr.
Miembro



Ing^o Jimmy Max Ramírez Villacorta, Mgr.
Miembro



Ing^o Carlos Alberto García Cortegano, Dr.
Asesor

DEDICATORIA

La presente tesis va dedicada a la mujer que me dio la vida, quien me forjo como hombre y gracias a ella logre mis sueños y objetivos personales, tan solo le pido a Dios muchos años más de vida para poder seguir disfrutándola.

Sonia.

A la niña de mis ojos, ya que es mi motor y motivo, siempre sacándome una sonrisa y dándome muchas satisfacciones, me siento muy feliz y orgulloso de ser tu papá.

Adriana Suney.

A todas las personas que contribuyeron para la elaboración y culminación de la presente investigación. Ya que fueron piezas de vital importancia para el propósito del mismo el cual contribuirá con la sociedad.

Los Autores.

AGRADECIMIENTO

A nuestra alma mater que nos dio la bienvenida al mundo profesional como tal, las oportunidades que nos ha brindado son incomparables y antes de todo esto ni siquiera pensábamos que fuera posible el lograr nuestras metas y sueños personales como profesionales. Agradecemos mucho a nuestros catedráticos, personal administrativo, compañeros y a toda la universidad en general, ya que con sus apoyos, consejos y convivencias forjaron nuestra personalidad y desarrollo profesional, el cual conllevaron al logro de nuestras metas y objetivos. A nuestros padres ya que cada día confiaron en nosotros como hijos y estudiantes los cuales fueron testigos de nuestro sacrificio y lucha para lograr nuestros objetivos personales y profesionales.

Martin Alonso Ocmin Morales y Luis Enrique Flores Echevarría

ÍNDICE DE CONTENIDO

	Pág.
PORTADA	i
ACTA DE SUSTENTACION	ii
FIRMAS DE JURADO	iii
DEDICATORIA	iv
AGRADECIMIENTO	v
ÍNDICE DE CONTENIDO	vi
ÍNDICE DE TABLAS	vii
ÍNDICE DE FIGURAS	viii
RESUMEN	ix
ABSTRACT	x
INTRODUCCIÓN	1
CAPÍTULO I: MARCO TEÓRICO	3
1.1. Antecedentes.	3
1.2. Bases teóricas.	5
1.3. Definición de términos básicos	12
CAPÍTULO II: HIPOTESIS Y VARIABLES	13
2.1. Formulación de hipótesis.	13
CAPÍTULO III: METODOLOGÍA	16
3.1. Diseño metodológico.	16
3.2. Diseño muestral.	17
3.3. Procedimientos de recolección de datos.	17
3.4. Procesamiento y análisis de la información.	17
3.5. Aspectos éticos.	18
3.6. Diseño de la solución.	18
CAPÍTULO IV: RESULTADOS	28
CAPÍTULO V: DISCUSIONES	35
CAPÍTULO VI: CONCLUSIONES	37
CAPÍTULO VII: RECOMENDACIONES	38
CAPÍTULO VIII: REFERENCIAS BIBLIORÁFICAS	39
ANEXOS	42
ANEXO 1. MATRIZ DE CONSISTENCIA	43
ANEXO 2: INSTRUMENTOS DE RECOLECCION DE DATOS	44
Anexo 3: CÓDIGO FUENTE.	45

ÍNDICE DE TABLAS

	Pág.
Tabla 1. Operacionalización de las variables.	15
Tabla 2. Mediciones realizadas	17
Tabla 3. Consumo de Energía eléctrica en Nauta.	20
Tabla 4. Datos de entrada en la red neuronal.	21
Tabla 5. DATASET normalizado.	22
Tabla 6. Valores predichos de consumo de energía eléctrica (Kilowatts/hora).	33

ÍNDICE DE FIGURAS

	Pág.
Figura 1. Métodos de pronóstico de demanda de Energía Eléctrica	6
Figura 2. Resumen de la clasificación de varios métodos de inteligencia artificial encontrados para la predicción de la demanda eléctrica.	7
Figura 3. Relación entre una neurona biológica y artificial.	10
Figura 4. Estructura de una neurona biológica y una neurona artificial mediante un modelo matemático	11
Figura 5. Metodología del diseño de la investigación.	16
Figura 6. Selección de los datos.	24
Figura 7. Entrenamiento, validación y prueba.	25
Figura 8. Arquitectura de la red.	26
Figura 9. Algoritmo de entrenamiento.	27
Figura 10. Interfaz de los parámetros.	27
Figura 11. Creación de la red neuronal artificial.	28
Figura 12. Arquitectura de la red neuronal artificial.	30
Figura 13. Muestra del error cuadrático medio en función del número de iteraciones.	31
Figura 14. Coeficiente de correlación del entrenamiento, validación y prueba.	32
Figura 15. Grafica de valores reales versus valores simulados	33

RESUMEN

Este trabajo de investigación tiene como objetivo principal Desarrollar una herramienta computacional para la predicción de la demanda de energía eléctrica basado en redes neuronales artificiales mediante el programa computacional Matlab. La investigación fue de tipo aplicada, nivel predictivo y diseño de la solución y como muestra de estudio los datos de consumo en kilowatts/ hora de energía eléctrica de los archivos digitales de la empresa ELECTRO ORIENTE, con esta información se construyó un dataset, se utilizó como técnica las Redes Neuronales Artificiales y como Instrumento el software MATLAB; para el procesamiento y análisis de datos usamos el MATLAB Neural Network Tools y MS Excel. El Coeficiente de Correlación del modelo de predicción en el consumo de energía eléctrica en la Ciudad de Nautas fue $R= 0.99978$, con un error cuadrático medio de 0.0000047813 . también se puede evidenciar que existe una alta correlación entre los valores reales y los valores pronosticados de la demanda de consumo eléctrico en la ciudad de Nauta, tanto en el entrenamiento (training: $R=0.99995$), validación (validation: $R = 0.9989$) y Prueba (Test: $R = 0.99936$). Finalmente se acepta la hipótesis de investigación: Si se desarrolla una herramienta computacional mediante el programa computacional Matlab, entonces se podrá hacer predicciones de la demanda de energía eléctrica en la Ciudad de Nauta.

Palabras claves: Predicción, redes neuronales artificiales, energía eléctrica

ABSTRACT

The objective of this work was to develop a computational tool for the prediction of electrical energy demand based on artificial neural networks using the Matlab computer program. The research was of an application type, predictive level and design of the solution and as a study sample the consumption data in kilowatts / hour of electrical energy from the digital files of the company ELECTRO ORIENTE, with this information a dataset was built, it was used Artificial Neural Networks as a technique and MATLAB software as an Instrument; For data processing and analysis we use MATLAB, MS Excel. The Correlation Coefficient of the prediction model in the consumption of electrical energy in the City of Nautas was $R= 0.99978$, with a mean square error of 0.0000047813 . It can also be evidenced that there is a high correlation between the real values and the predicted values of the demand for electricity consumption in the city of Nauta, both in the training (training: $R=0.99995$), validation (validation: $R = 0.9989$) and Test (Test: $R = 0.99936$). Finally, the research hypothesis is accepted: The development of a neural network in Matlab will allow predicting the electricity demand of the city of Nauta with a correlation coefficient greater than 0.90.

Keywords: Prediction, artificial neural networks, electrical energy

INTRODUCCIÓN

Este trabajo de investigación tiene como objetivo principal el realizar un análisis predictivo de datos, mediante el uso de redes neuronales artificiales, con la ayuda de estas es posible llegar a predecir resultados mediante el uso software MATLAB. El caso de estudio que llegara a desarrollar con datos obtenidos de la empresa ELECTRO ORIENTE de la ciudad de Nauta sobre la base de los consumidores de energía por mes.

Las redes neuronales artificiales tienden a utilizar su capacidad de aprendizaje adaptativo con el fin de autoorganizar la información que reciben durante el aprendizaje y / o la operación, que se basa en modificar la red neuronal completa para poder cumplir un el determinado objetivo de esta investigación.

El análisis predictivo de los datos se llevará en el software MATLAB, debido a que este software nos da la opción de entrenar redes neuronales con un algoritmo de propagación hacia atrás feedforward, llegando así a resolver problemas específicos. Además, nos permite crear y entrenar su propia red neuronal artificial desde cero o usar un modelo previamente entrenado con el fin de realizar la transferencia de aprendizaje. Para la predicción de esta investigación se propone una red neuronal con tres entradas, que son el consumo de energía eléctrica mensual, número de meses y los años de data histórico y la salida es el consumo de energía eléctrica. En primera instancia se genera un archivo con información de la demanda en kilovatios, cabe destacar que los datos deben estar debidamente normalizados, para que la salida de la información se pueda ajustar a los valores comprendidos entre 0 y 1.

Generalmente, si la energía que ha sido distribuida no es suficiente para satisfacer la demanda del consumidor, el abastecimiento se torna errático y si existe un exceso de generación, la empresa tendrá que soportar pérdidas. Esto se convierte en el principal reto, es decir, la creación de un modelo que otorgue

una predicción más eficiente y precisa para poder realizar de manera correcta la toma de decisiones, por eso nos planteamos la siguiente interrogante. ¿De qué manera el desarrollo de una herramienta computacional puede hacer predicciones de la demanda de energía eléctrica en la Ciudad de Nauta?

Bajo ese criterio nos planteamos como Objetivo general desarrollar una herramienta computacional para la predicción de la demanda de energía eléctrica basado en redes neuronales artificiales mediante el programa computacional Matlab, el cual se hará realidad si cumplimos con sus objetivos específicos: Determinar el Coeficiente de Correlación del modelo de predicción en el consumo de energía eléctrica y determinar el Error cuadrático medio de la red neuronal artificial en la predicción de consumo de electricidad en la Ciudad de Nauta

Se recolecta los datos de los archivos digitales de reportes de consumo de energía eléctrica de la empresa Electro Oriente, para que posteriormente crear un DATASET, utilizando como técnica las Redes Neuronales Artificiales e instrumento MATLAB.

A continuación, se enuncia brevemente cada uno de los capítulos que forman parte de la investigación:

Capítulo I: Marco teórico

Capitulo II: Hipótesis y variables

Capitulo III: Metodología de la investigación

Capitulo IV: Resultados

Capítulo V: Discusiones

Capítulo VI: Conclusiones

Capitulo VII: Recomendaciones

Capitulo VIII: Bibliografía

CAPÍTULO I: MARCO TEÓRICO

1.1. Antecedentes.

Morillo (2020), quien, en su tesis desarrollada en el Ecuador, utilizó técnicas Redes Neuronales Artificiales con MATLAB Neuronal Network Toolbox , En esta investigación se encontró que los resultados obtenidos por subestación se ajustan al comportamiento real del sistema de distribución eléctrica, aun considerando que presentan un alto grado de dispersión e inclusive se tuvo que trabajar con demandas negativas, esto es debido a que en el entrenamiento de la red realizado en MATLAB se utilizó el algoritmo de regulación Bayesiana, el cual permitió que las previsiones cuenten con un mayor grado de confiabilidad, precisión e incidiendo así de forma positiva en la obtención de datos para la toma de decisiones en la Dirección de Planificación de la empresa. **Morillo** (2020, P. 81)

Sinaluisa (2017), quien, en su tesis desarrollada en el Ecuador con una investigación tipo descriptiva y diseño experimental, donde se realizó la observación de campo a las subestaciones y medidores de las tres salidas, donde se obtuvieron 70128 observaciones de los cuales 61344 se utilizó para el entrenamiento de la red y 8784 para las pruebas del modelo. En esta investigación se encontró que el preprocesamiento de datos obtenidos detectó y corrigió 406 datos perdidos y 320 datos atípicos, la mayoría de los cuales corresponden al año 2009 y 2014, se llegó a determinar que el porcentaje del error medio absoluto (MAPE) del modelo para la predicción en la demanda de energía eléctrica basado en la red neuronal FeedForward Backpropagation fue del 2,63%, mientras que el basado en regresión lineal múltiple fue del 4,56%. Se

llego a la conclusión que el modelo de predicción de la demanda de energía eléctrica basado en la red neuronal FeedForward Backpropagation es el que posee un mejor rendimiento de predicción. **Sinaluisa** (2017, p.90)

Garzón y Marulanda (2017), quienes, en su tesis utilizaron métodos basados en inteligencia artificial y paramétricos, en esta investigación se encontró que la precisión del modelo por regresión multivariable dependía directamente de la cantidad de variables que fueran utilizadas, para esta investigación las tres variables permitieron obtener errores bajos en los pronósticos a corto plazo, mientras que para el largo plazo el modelo presentaba un error aproximado del 55% respecto a la estimación dada por la UPME debido a la inconsistencia entre las variables que se tuvieron en cuenta para el análisis de largo plazo. Sin embargo, este error puede llegar a ser poco relevante con respecto al consumo real. **Garzón y Marulanda** (2017, p.14)

Naula y Oscurio (2021), quienes, en su tesis de tipo aplicada con nivel descriptiva y diagnóstica, cuya Técnicas es la observación e instrumentos la simulación y programación, en esta investigación se encontró que el método basadas a la predicción de la demanda de energía eléctrica a corto plazo se determinó que la red neuronal artificial es una red diseñada para predecir series de tiempo en base a los valores históricos de la variable a predecir. Finalmente se logró el desarrollo de una herramienta computacional en el Software MATLAB, por medio de la interfaz gráfica (GUIDE) que nos permite llegar a predecir la demanda de energía eléctrica a corto plazo, utilizando una red neuronal artificial aprovechando el algoritmo de entrenamiento levenberg marquardt, con 288 números de retrasos, 10 neuronas, el 80 % de datos de entrenamiento, 10 % datos de validación y 10 % datos de prueba, logrando un buen desempeño del

1.01×10^{-7} , a través de los resultados logrando una aproximación a los datos reales. **Naula y Oscurio** (2021, p.78)

1.2. Bases teóricas.

1.2.1. Demanda eléctrica

Para Gönen (2014) (como se citó Naula y Oscurio, 2021), es la cantidad de potencia que un consumidor utiliza en cualquier momento. Dicho de otra forma: la demanda de una instalación eléctrica en los terminales receptores, tomada como un valor medio en un intervalo determinado, el período durante el cual se toma el valor medio se denomina intervalo de demanda (p. 11).

Ramírez (2004) (como se citó Naula y Oscurio, 2021), menciona que la duración que se fije en este intervalo dependerá del valor de demanda que se desee conocer, si se quiere encontrar la demanda para aplicarla a un transformador o cable, que será de 10 o 15 minutos (p. 11).

1.2.1.1. Predicción de la demanda eléctrica.

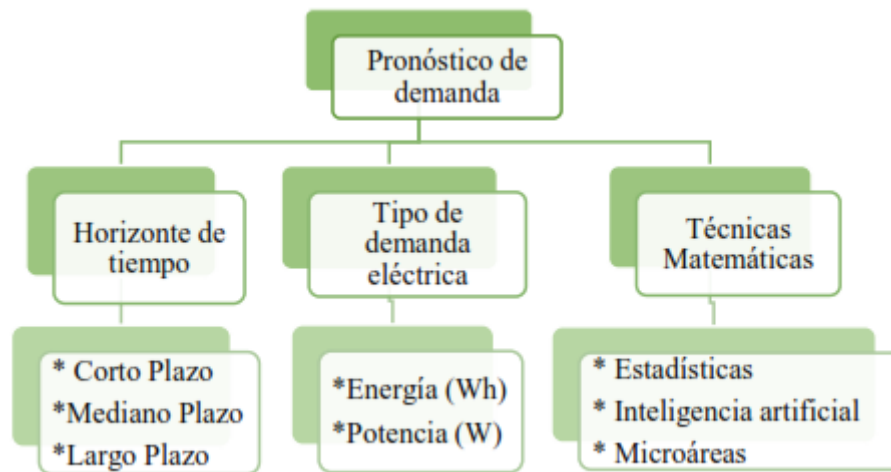
La problemática principal es llegar a determinar los valores futuros de la demanda de electricidad proporcionando la base de datos histórica de energía eléctrica y algunas entradas imprevistas Según Ringwood (como se citó Naula y Oscurio, 2021), las entradas imprevistas deben ser apropiadas para la escala de tiempo a determinar, por ejemplo:

- A.** Cada hora: entradas de carácter meteorológico (temperatura, velocidad, humedad y dirección del viento, etc.), eventos especiales (festivos, eventos deportivos, etc.)
- B.** Semanalmente: Entradas de carácter meteorológico (grados en días de calefacción, grados en días de refrigeración), actividad económica

C. Anualmente: Insumos económicos (PIB, salario industrial promedio, índice de precios al consumidor, etc.), variables demográficas (números de población, inmigración, emigración, distribución, etc.) (p.16).

1.2.1.2. Clasificación de los métodos de pronóstico de demanda de Energía Eléctrica

Figura 1. Métodos de pronóstico de demanda de Energía Eléctrica.



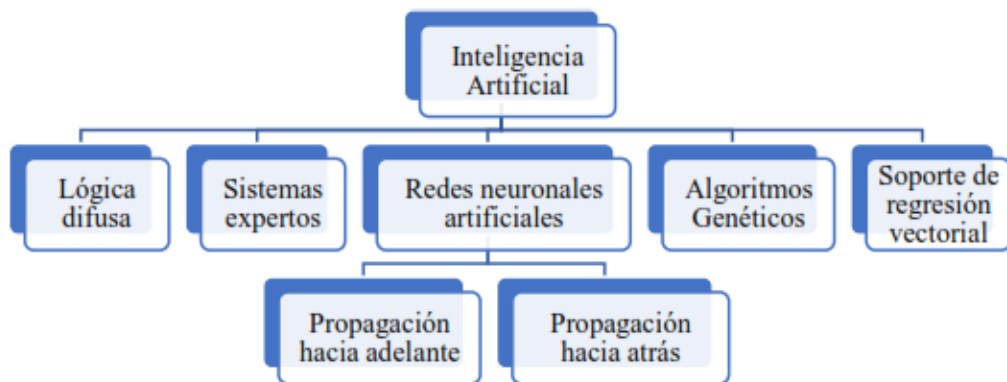
Fuente: “Pronósticos, series de tiempo y pronósticos, enfoque aplicado», por Bowerman y Commell, 2007.

1.2.2. Métodos de Inteligencia Artificial

Según **Russell y Norving** (2004) (como se citó Naula y Oscurio, 2021), la inteligencia artificial es el arte de desarrollar máquinas con capacidad para realizar tareas que por el momento los humanos hacen mejor (p. 23).

Para **Monobanda** (2020) (como se citó Naula y Oscuro, 2021), los métodos de inteligencia artificial para predicciones son algoritmos que mediante matemáticas avanzadas permiten modelar el comportamiento de las variables dependientes en función de algunas variables independientes con la diferencia de permitir trabajar con sistemas más complejos que presentan comportamientos no lineales (p. 24).

Figura 2. Resumen de la clasificación de varios métodos de inteligencia artificial encontrados para la predicción de la demanda eléctrica.



Fuente: «Predicción de la demanda de energía eléctrica en la producción de petróleo de los campos de Petroamazonas Ep utilizando redes neuronales artificiales», por F. Monobanda (2020).

1.2.2.1. Red neuronal

Cortina Januchs, nos señala que, las RNA son modelos matemático-computacionales que tienen una alta capacidad de generalización y tratamiento de diversos problemas tanto lineales como no lineales, no se necesita un conocimiento extenso de la distribución de las variables que se aplicaran en el estudio. Las RNA hacen el intento de emular el sistema nervioso, de tal manera que son capaces de llegar a reproducir algunas de las principales funciones que desarrolla el cerebro humano, al poder reflejar las múltiples características

fundamentales de comportamiento del mismo. La meta principal de modelizar las redes neuronales, es crear una de las estructuras fisiológicas de soporte del cerebro, la neurona y los grupos estructurados e interconectados de entre varias de ellas, siendo conocidos como redes de neuronas. De esta manera, se pueden construir sistemas que presentan un cierto nivel de inteligencia. Matamoros (2021, p.46)

1.2.2.1.1. Ventajas de las redes neuronales artificiales

Las principales ventajas de las RNA son:

- A.** Aprendizaje Adaptativo. - Las RNA tiene una gran capacidad de aprender tareas basadas en el entrenamiento (datos de entrenamiento). Es decir, las RNA pueden cambiar su estructura dependiendo de los datos que estos hayan entrenado. Villacis, (2017) (como se citó Naula y Oscurio, 2021, p. 25).
- B.** Autoorganización. - Las RNA llegar a desarrollar su propia organización o representación de la información que estas reciben en la etapa de aprendizaje (Naula y Oscurio, 2021, p. 25).
- C.** Tolerancia a fallos. - Las RNA tienen la ventaja de preservar las diversas capacidades que posee la red en caso de una destrucción parcial de la red. Sin olvidar que esta toleración será mayor o menor dependiendo de la aplicación en la que se utilice la RNA. (Naula y Oscurio, 2021, p. 25).
- D.** Modelación no lineal. - Las RNA, permiten aproximar funciones no lineales (elimina la hipótesis de reducción de linealidad) y permite modelar fenómenos complejos donde las variables no están correlacionadas (Naula y Oscurio, 2021, p. 25).

Adicionalmente damos a conocer las ventajas de las redes neuronales artificiales (RNA):

- Se obtiene un mejor redimiendo en el trato con las funciones no lineales, no requieren formulaciones matemáticas complejas o de correlación cuantitativa entre entradas y salidas.
- Los modelos son sencillos y permiten obtener bajos errores en el pronóstico, estando dentro como fuera de la muestra
- El software posee varias funciones de preprocesamiento y post-procesamiento de datos implícitas en las funciones de entrenamiento haciendo innecesario el uso de manera individual.
- Proporciona una reducción de costos operacionales y económicos, esto es debido a la disminución del error.
- Son una solución sencilla, eficaz y confiable para la las tareas de predicción de demanda de energía eléctrica con una precisión superior al 95%.

También se detallan las diversas desventajas que poseen las redes neuronales artificiales (RNA):


- a. Los paquetes computacionales en el mercado se encuentran limitados en su adaptación al problema, varios poseen una restricción en tamaño de la muestra.
- b. La programación de la red puede llegar a ser tediosa pero muy acertada en sus resultados.

1.2.2.1.2. Elementos de una red neuronal

1.2.2.1.2.1. Neurona artificial.

Son elementos computacionales de cálculo que, al contar con un vector de entrada procedente del mundo exterior, y/o a través del estímulo recibido de otras neuronas llegan a proporcionar una respuesta única (salida).

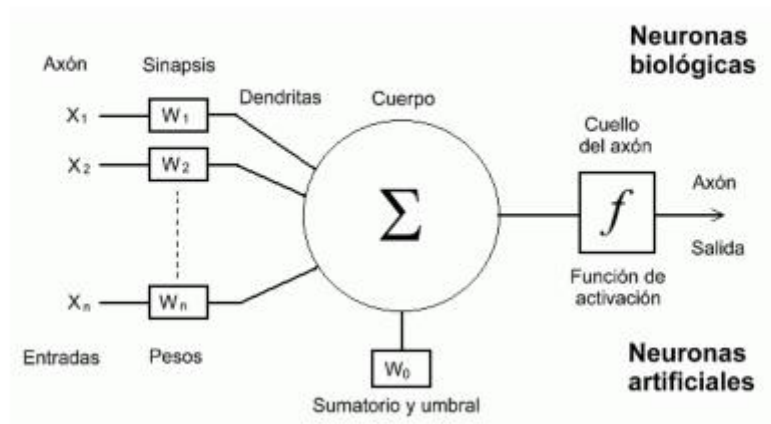
Figura 3. Relación entre una neurona biológica y artificial.



Fuente: «Redes neuronales y sistemas difusos, Ciudad de México», por Del Brío y Sanz, 2020.

Las neuronas artificiales están constituidas por estructuras llamadas capas. Una red RNA consta de múltiples capas. Por ende, la información se va distribuyendo a lo largo de las sinapsis de la red, otorgándole al sistema una buena tolerancia a fallos. Las redes neuronales artificiales son capaces de adaptar su funcionamiento a múltiples entornos al modificar las conexiones entre neuronas, lo anterior se traduce en que puedan aprender de la experiencia y generalizar conceptos **Naula & Oscuro** (2021, p. 26).

Figura 4: Estructura de una neurona biológica y una neurona artificial mediante un modelo matemático



Fuente: Naula y Oscurio, (2021)

Las neuronas artificiales tienen diferentes cantidades de entradas (externas o salidas de neuronas anteriores). A cada entrada ya se le asigna un peso que representa el grado en el que se ve afectada la entrada a la neurona (sinapsis). La neurona trabaja procesando la información, sumando las entradas y valor umbral (Es muy recomendable tener un valor umbral, debido a que esta mejora el procesamiento de la señal), para después de eso, llegar a pasar por una función de activación que permite generar la señal de salida de la neurona. Las RNA se adaptan al funcionamiento de múltiples entornos modificando las conexiones entre neuronas **Naula & Oscurio** (2021, p. 27).

Algoritmo de Levenberg Marquardt.

El Algoritmo de Levenberg Marquardt, también es denominado, métodos de mínimos cuadrados amortiguados. Consiste en una técnica iterativa que localiza el mínimo de una función, se utiliza en problemas de mínimos cuadrados con funciones no lineales Lourakis (2005).

Fue diseñado para estar cerca del segundo orden con entrenamientos rápidos sin necesidad de calcular la matriz Hessiana.

1.3. Definición de términos básicos

Dato.

Es el flujo de elementos que representan los tipos de eventos que ocurren en las organizaciones o en el entorno físico mucho antes de ordenarlos e interpretarlos en una forma que los usuarios puedan comprender y usar. **Laudon & Laudon** (2012, p.15)

Dataset.

Es una tabla que guarda información histórica y actualizada, la cual llega a ser potencialmente relevantes al querer realizar: análisis para búsqueda de patrones. **Laudon & Laudon** (2012, p.222)

Información.

Son los datos que han sido transformados de una manera reveladora y útil para los analistas, Esto conlleva al primer paso para obtener conocimiento. **Laudon & Laudon** (2012, p.15)

Algoritmo.

Son aquellas que indican exactamente el orden (relación de instrucciones) a aplicar para llegar a una solución de manera automatizada, muy estructurada y rápida, como resultado de trabajar la información contenida en el dataset, de la capacidad de los procesadores y del software, utilizado en la resolución de este trabajo. **Laudon & Laudon** (2012, p.461)

Redes Neuronales Artificiales.

Son las redes neuronales que se utilizan en la resolución de problemas complejos y malentendidos, para aquellos que han recolectado grandes cantidades de datos. **Laudon & Laudon** (2012, p.436)

CAPÍTULO II: HIPOTESIS Y VARIABLES

2.1. Formulación de hipótesis.

2.1.1. Hipótesis general.

Hi: Si se desarrolla una herramienta computacional mediante el programa computacional Matlab, entonces se podrá hacer predicciones de la demanda de energía eléctrica en la Ciudad de Nauta.

2.1.2. Hipótesis nula.

H0: Si se desarrolla una herramienta computacional mediante el programa computacional Matlab, entonces no se podrá hacer predicciones de la demanda de energía eléctrica en la Ciudad de Nauta

2.1.3. Hipótesis específicas

HE1. El desarrollo de una red neuronal en MATLAB, permitirá predecir la demanda eléctrica de la ciudad de Nauta con un coeficiente de correlación mayor de 0.90.

HE2. El desarrollo de una red neuronal, permitirá predecir la demanda eléctrica de la Ciudad de Nauta con un error cuadrático medio menor del 5%

2.2. Variables y operacionalización.

2.2.1. Variables

Variable independiente: Redes neuronales.

Variable dependiente: Predicción de la demanda de energía eléctrica.

2.2.2. Operacionalización de las variables

Tabla 1. Operacionalización de las variables.

Variable	Definición	Tipo	Indicadores	Escala de medición	Categoría	Valores de categorías	Instrumento
Redes neuronales artificiales	Se refiere a los procesos, técnicas, algoritmos y operaciones utilizados para obtener mejor la calidad de los resultados de predicción.	Cuantitativa	-Entrenamiento -Prueba -Validación	Numérico	-----	70% 15% 15%	Matlab, Excel, otros
Predicción de la demanda de energía eléctrica	Es un procedimiento sistemático que permite definir de manera cuantitativamente la demanda futura y por ser de vital importancia debe procurarse que dicha información sea lo más exacta y verídica posible, evitando futuros fallos, sin olvidar la presencia de incertidumbres (ARCONEL, 2014).	Cuantitativa	Error cuadrático medio	Numérico	Menor error	[0 - 100]%	DATASET (elaborado por el tesista)
			Coeficiente de Correlación	Numérico	Excelente	[100 – 97 ≥ %	
					Regular	< 97 – 90 ≥ %	
Deficiente	< 90 – 0] %						

Fuente: Elaboración propia

CAPÍTULO III: METODOLOGÍA

3.1. Diseño metodológico.

3.1.1. Tipo de investigación.

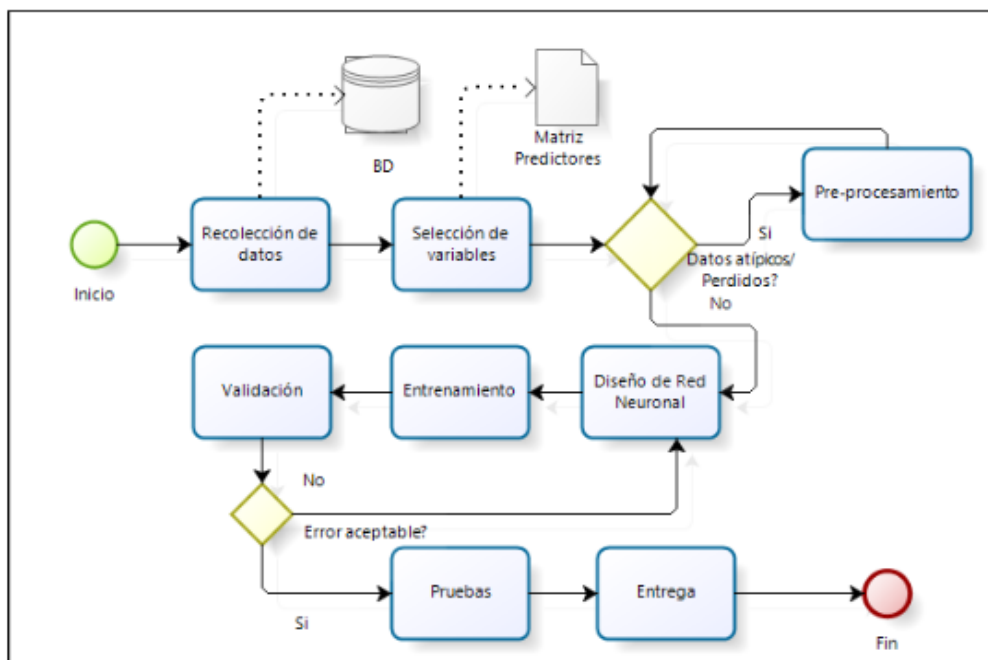
Esta investigación es de tipo Aplicada porque tiene como propósito transformar los conocimientos existentes o modelos en objetos útiles a la sociedad y eso implica que buscará resolver un problema puntual utilizando un modelo de red neuronal artificial, Buscando que las soluciones que generen efectividad. Espinoza M C (2014)

El nivel o alcance de la investigación es el predictivo: porque se pretende predecir la demanda de energía eléctrica de la Ciudad de Nauta.

3.1.2. Diseño de la investigación.

El diseño de la investigación es el diseño de la Solución.

Figura 5. Metodología del diseño de la investigación.



Fuente: Iván Sinaluisa a partir de (Hanke & Wichem, 2006)

3.2. Diseño muestral.

Mediciones de consumo de energía eléctrica en kilowatts/ hora (agrupados por los meses (enero 2016 – diciembre 2021), haciendo un total de 72 meses. en esta investigación se trabajó con 60 meses distribuidos de la siguiente manera:

Tabla 2. Mediciones realizadas.

Entrenamiento	42	70%
Validación	9	15%
Prueba	9	15%

Fuente: Elaboración propia.

Los datos de consumo de energía eléctrica de los 12 meses restantes se utilizaron para validar la predicción de la red neuronal artificial y hacer comparaciones entre el consumo real y el consumo predicho por la red.

3.3. Procedimientos de recolección de datos.

Se recolectó los datos históricos de los archivos digitales de la empresa Electro Oriente, y con ello se creó un dataset.

Técnica

Redes Neuronales Artificiales.

Instrumento

MATLAB

3.4. Procesamiento y análisis de la información.

El procesamiento y análisis de datos fue hecho con MATLAB Neural Network Tolos y MS Excel.

3.5. Aspectos éticos.

Los datos empleados para esta investigación fueron manejados con confidencialidad, eso implica que estará regido por la normativa vigente del reglamento de grados y títulos de la de la Universidad Nacional de la Amazonia Peruana.

3.6. Diseño de la solución.

3.6.1. Desarrollo del modelo para el pronóstico.

El desarrollo de este modelo fue ajustada a los requerimientos existentes de esta predicción de la demanda de energía eléctrica en la ciudad de Nauta. Por lo tanto, se muestran y detallan todos los elementos del proceso de modelado con el empleo de redes neuronales artificiales.

3.6.1.1. Diseño del Modelo.

Selección de variables

Variable a pronosticar: Cantidad mensual de demanda de energía eléctrica en la ciudad de Nauta.

Tipo de variable: Cuantitativa

Unidad: kilowatts/ hora

Recolección de datos

La información y/o datos técnicos que fueron usados para el desarrollo de esta investigación fueron proporcionados por la empresa ELECTRO ORIENTE.

Se contó con información desde el año 2016 hasta el 2021, Para un adecuado desarrollo del modelo se requería un mínimo de 60 meses dentro de los datos de entrada.

Preprocesamiento

Para poder trabajar eficientemente con el software a utilizar, es necesario que se identifique y preparen todos los datos. En el caso de MATLAB se requiere la correcta distribución en base de su interfaz matricial.

Para este modelo se utilizó la matriz de columnas para ajustar los datos de entrada y salida, también está por mes y año. Como se muestra en la Tabla 3 de consumo doméstico medido.

Tabla 3. Consumo de Energía eléctrica en Nauta.(KWatts/hora)

MES	1	2	3	4	5	6	7	8	9	10	11	12
AÑO	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SETIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
2016	1550.578	1436.592	1567.287	1551.543	1566.974	1467.312	1410.785	1616.941	1435.763	1480.641	1514.098	1452.717
2017	1437.936	1338.167	1693.723	1671.206	1697.953	1596.709	1632.363	1810.238	1701.758	1735.908	1694.628	1734.693
2018	1697.659	1548.681	1758.508	1750.758	1662.132	1408.976	1381.408	1377.755	1380.997	1766.700	1586.311	1550.308
2019	1501.841	1380.373	1497.642	1672.202	1666.613	1612.682	1572.345	1530.423	1767.037	1789.761	1871.253	1641.305
2020	1861.956	1651.818	1760.267	1592.208	1728.880	1219.003	1655.622	1891.760	1898.536	2177.635	1913.883	2144.136
2021	2323.420	1998.220	1676.504	1969.851	2081.612	2236.055	2143.206	2004.007	2633.816	1964.853	1912.994	1885.606

Fuente: Electro Oriente S.A.

Tabla 4. Datos de entrada en la red neuronal.

AÑOS			MESES			CONSUMO			
AÑOS	MESES	CONSUMO	AÑOS	MESES	CONSUMO				
1	2016	1	Enero	1550.578	3	2018	1	Enero	1697.659
1	2016	2	Febrero	1436.592	3	2018	2	Febrero	1548.681
1	2016	3	Marzo	1567.287	3	2018	3	Marzo	1758.508
1	2016	4	Abril	1551.543	3	2018	4	Abril	1750.758
1	2016	5	Mayo	1566.974	3	2018	5	Mayo	1662.132
1	2016	6	Junio	1467.312	3	2018	6	Junio	1408.976
1	2016	7	Julio	1410.785	3	2018	7	Julio	1381.408
1	2016	8	Agosto	1616.941	3	2018	8	Agosto	1377.755
1	2016	9	Setiembre	1435.763	3	2018	9	Setiembre	1380.997
1	2016	10	Octubre	1480.641	3	2018	10	Octubre	1766.700
1	2016	11	Noviembre	1514.098	3	2018	11	Noviembre	1586.311
1	2016	12	Diciembre	1452.717	3	2018	12	Diciembre	1550.308
2	2017	1	Enero	1437.936	4	2019	1	Enero	1501.841
2	2017	2	Febrero	1338.167	4	2019	2	Febrero	1380.373
2	2017	3	Marzo	1693.723	4	2019	3	Marzo	1497.642
2	2017	4	Abril	1671.206	4	2019	4	Abril	1672.202
2	2017	5	Mayo	1697.953	4	2019	5	Mayo	1666.613
2	2017	6	Junio	1596.709	4	2019	6	Junio	1612.682
2	2017	7	Julio	1632.363	4	2019	7	Julio	1572.345
2	2017	8	Agosto	1810.238	4	2019	8	Agosto	1530.423
2	2017	9	Setiembre	1701.758	4	2019	9	Setiembre	1767.037
2	2017	10	Octubre	1735.908	4	2019	10	Octubre	1789.761
2	2017	11	Noviembre	1694.628	4	2019	11	Noviembre	1871.253
2	2017	12	Diciembre	1734.693	4	2019	12	Diciembre	1641.305

Fuente: Electro Oriente S.A.

NORMALIZACION DE DATOS

se procedió a acondicionar los valores mediante la normalización que consiste en representar estos valores en otra escala, que está comprendida en el intervalo 0 y 1, este procedimiento es muy necesario para mejorar el proceso de entrenamiento de la red neuronal.

Existe muchas formas de normalizar los datos, sin embargo, para la investigación se utilizó la siguiente formula:

$$Ri = \frac{Yi}{max}$$

donde:

R_i = Dato con nueva escala

Y_i = Dato con escala original

max=mayor dato de la serie

Por lo tanto la serie de tiempo de la demanda de energía eléctrica normalizada se muestra en la tabla 6.

Para normalizar los datos se procedió a dividir todos los datos de la tabla 4 entre el máximo valor que se encuentra en dicha tabla: 2633.82 kilowatts /hora,

Tabla 5. DATASET NORMALIZADO.

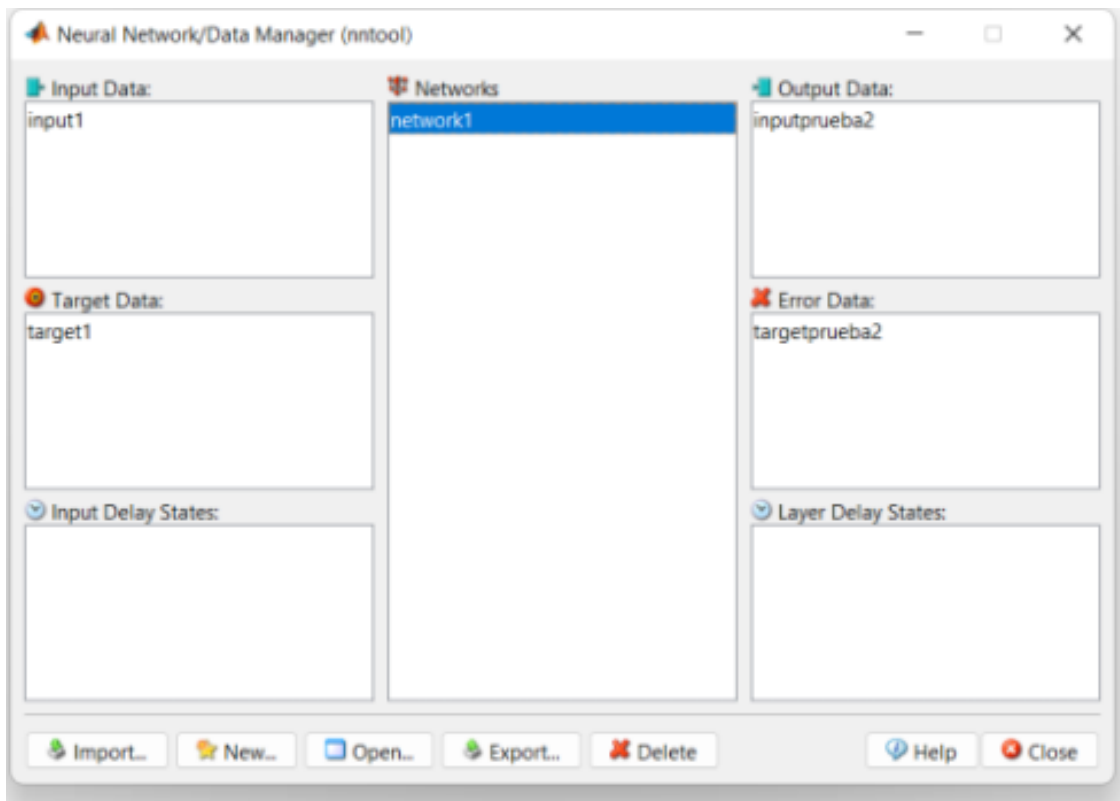
INPUT		TARGET	
0.00037968	0.00037968	0.58871842	0.58871842
0.58871842	0.00075935	0.54544037	0.54544037
0.54544037	0.00113903	0.59506242	0.59506242
0.59506242	0.00151871	0.58908458	0.58908458
0.58908458	0.00189838	0.59494346	0.59494346
0.59494346	0.00227806	0.55710423	0.55710423
0.55710423	0.00265774	0.53564214	0.53564214
0.53564214	0.00303741	0.61391475	0.61391475
0.61391475	0.00341709	0.54512560	0.54512560
0.54512560	0.00379677	0.56216472	0.56216472
0.56216472	0.00417644	0.57486767	0.57486767
0.57486767	0.00455612	0.55156281	0.55156281
0.55156281	0.00037968	0.54595084	0.54595084
0.54595084	0.00075935	0.50807087	0.50807087
0.50807087	0.00113903	0.64306697	0.64306697
0.64306697	0.00151871	0.63451801	0.63451801
0.63451801	0.00189838	0.64467332	0.64467332
0.64467332	0.00227806	0.60623327	0.60623327
0.60623327	0.00265774	0.61977012	0.61977012
0.61977012	0.00303741	0.68730531	0.68730531
0.68730531	0.00341709	0.64611769	0.64611769
0.64611769	0.00379677	0.65908365	0.65908365
0.65908365	0.00417644	0.64341085	0.64341085
0.64341085	0.00455612	0.65862264	0.65862264
0.65862264	0.00037968	0.64456151	0.64456151
0.64456151	0.00075935	0.58799789	0.58799789
0.58799789	0.00113903	0.66766430	0.66766430
0.66766430	0.00151871	0.66472215	0.66472215
0.66472215	0.00189838	0.63107258	0.63107258
0.63107258	0.00227806	0.53495516	0.53495516
0.53495516	0.00265774	0.52448852	0.52448852

0.52448852	0.00303741	0.52310137	0.52310137
0.52310137	0.00341709	0.52433225	0.52433225
0.52433225	0.00379677	0.67077491	0.67077491
0.67077491	0.00417644	0.60228543	0.60228543
0.60228543	0.00455612	0.58861576	0.58861576
0.58861576	0.00037968	0.57021413	0.57021413
0.57021413	0.00075935	0.52409553	0.52409553
0.52409553	0.00113903	0.56861959	0.56861959
0.56861959	0.00151871	0.63489610	0.63489610
0.63489610	0.00189838	0.63277407	0.63277407
0.63277407	0.00227806	0.61229754	0.61229754
0.61229754	0.00265774	0.59698260	0.59698260
0.59698260	0.00303741	0.58106598	0.58106598
0.58106598	0.00341709	0.67090263	0.67090263
0.67090263	0.00379677	0.67953050	0.67953050
0.67953050	0.00417644	0.71047101	0.71047101
0.71047101	0.00455612	0.62316524	0.62316524
0.62316524	0.00037968	0.70694133	0.70694133
0.70694133	0.00075935	0.62715659	0.62715659
0.62715659	0.00113903	0.66833246	0.66833246
0.66833246	0.00151871	0.60452430	0.60452430
0.60452430	0.00189838	0.65641529	0.65641529
0.65641529	0.00227806	0.46282704	0.46282704
0.46282704	0.00265774	0.62860090	0.62860090
0.62860090	0.00303741	0.71825713	0.71825713
0.71825713	0.00341709	0.72083001	0.72083001
0.72083001	0.00379677	0.82679731	0.82679731
0.82679731	0.00417644	0.72665682	0.72665682
0.72665682	0.00455612	0.81407848	0.81407848

Fuente: Elaboración propia

Del mismo modo en la Tabla 5 está muestra un ejemplo de cómo ingresar las hojas de cálculo de Excel preparadas en el software MATLAB. Los inputs representan a las x en función de la serie de tiempo. Los targets están definiendo la forma de las salidas deseadas en este caso y .

Figura 6. Selección de los datos.



Fuente: MATLAB

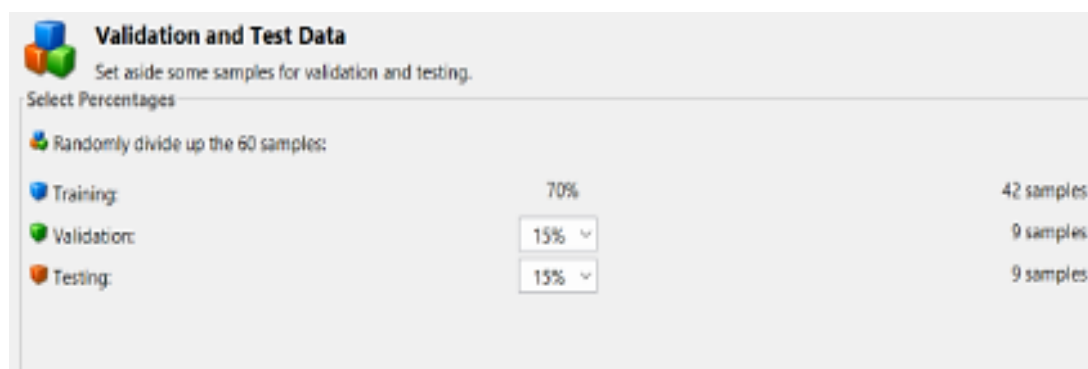
Tanto para inputs como targets que se visualizan en el software nombra a los datos como input1 y target 1 de esta manera estos comienzan a ser parte dentro del área de trabajo de MATLAB. Es necesario, seleccionar el formato con el cual se desea trabajar.

Además, toda la información que fue trabajada no presenta algún valor nulo ni tampoco valores perdidos, por este motivo no es necesario llegar a emplear un tratamiento especial a la información.

Entrenamiento, validación y prueba

Buscamos de esta forma la existencia de algunos parámetros iguales de entrenamiento, validación y prueba dentro del desarrollo del modelo. En la Figura 7 se presenta el interfaz existente en la que se trabajó dentro del software utilizado, para definir estos conjuntos.

Figura 7. Entrenamiento, validación y prueba.



Fuente: MATLAB

Conjunto de entrenamiento

El conjunto que se trata dentro del desarrollo del modelo presenta un total de 60 mediciones haciendo función a los 5 años.

En la Figura 7 se muestra como este conjunto representa el 70% de los datos ingresados dentro de la selección de datos, que equivale a 42 mediciones.

Conjunto de validación

Como se está mostrando en la Figura 7 este conjunto representa el 15% de las mediciones empleadas, esto indica 9 de las mediciones que fueron ingresadas. Este conjunto debe ser definido, ya que este es utilizado para medir la generalización de la red y para detener el entrenamiento cuando la generalización ya no presenta más valores con mejores resultados.

De esta manera se logró que la red dentro del proceso de entrenamiento aprenda de forma general en el procesamiento de los datos y obteniendo así que el aprendizaje sea evite ser de forma individual.

Conjunto de prueba


Representando el 15% el conjunto de prueba también equivale a 9 mediciones sobre la demanda de agua potable, como se observa en la Figura 7. Este conjunto no afecto al momento de la realización del entrenamiento.

Esto permite que el rendimiento al iniciar y terminar el entrenamiento de la red adquiera una medida independiente.

Arquitectura de la red neuronal

MATLAB determinar de automática el número de neuronas con las cuales la información va a generar los resultados más eficientes. En la Figura 8, se muestra a detalladamente la estructura que está definida para el número de capas ocultas como el retardo que presenta la red neuronal. Además, se observa la red neuronal en función de la estructura que esta previamente definida.

Figura 8. Arquitectura de la red.

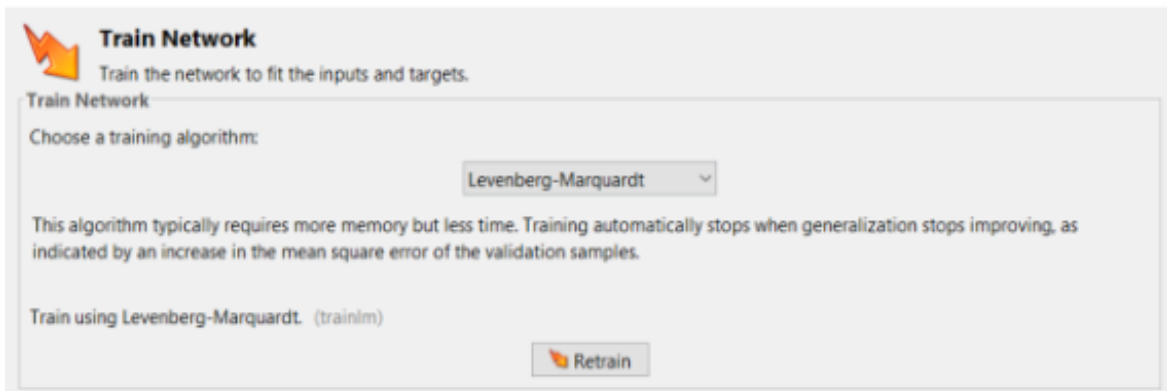


Fuente: MATLAB

Algoritmo de entrenamiento

En la Figura 9 se está mostrando el algoritmo que fue utilizado en el entrenamiento de este modelo es el LEVENBERG-MARQUARDT ya que las mediciones de que fueron utilizadas presentan un alto nivel de dispersión.

Figura 9. Algoritmo de entrenamiento.



Fuente: MATLAB

Criterios de evaluación

Al momento de llegar a realizar el entrenamiento los primeros valores o métricas de evaluación que se deben considerar, son el error cuadrático y el coeficiente de correlación, en la Figura 10 se muestra el que interfaz utiliza estos parámetros.

Figura 10. Interfaz de los parámetros.

	Samples	MSE	R
Training:	42	5.54980e-9	9.99999e-1
Validation:	9	4.38905e-8	9.99997e-1
Testing:	9	6.70620e-7	9.99987e-1

Plot Fit Plot Error Histogram Plot Regression

Mean Squared Error is the average squared difference between outputs and targets. Lower values are better. Zero means no error.

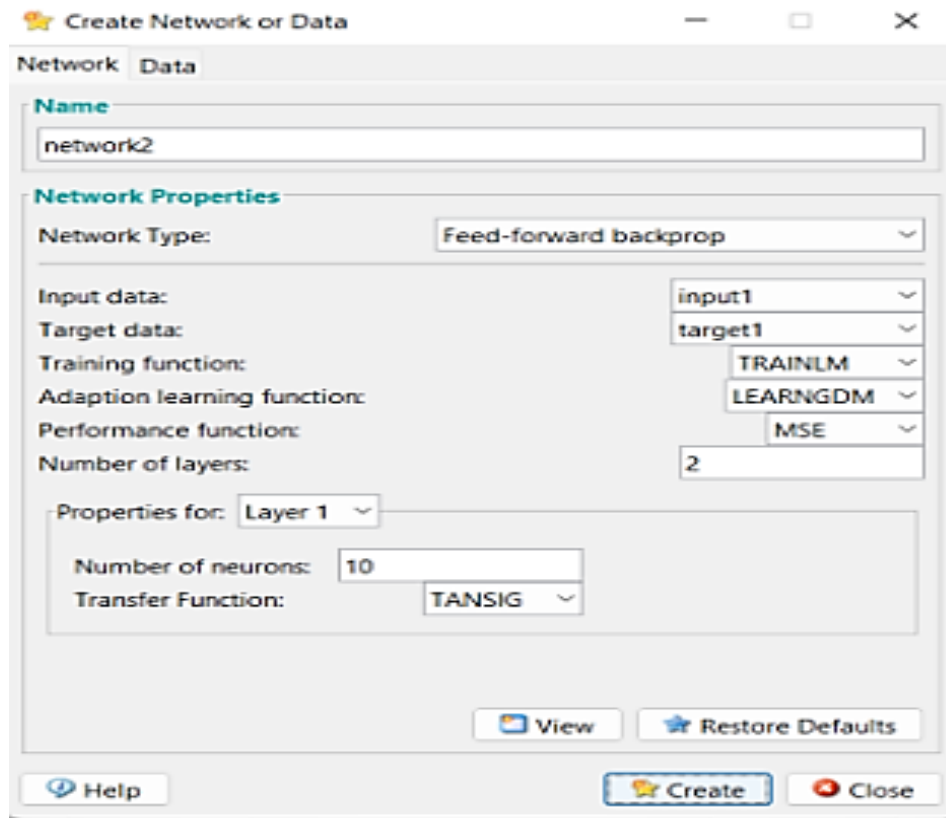
Regression R Values measure the correlation between outputs and targets. An R value of 1 means a close relationship, 0 a random relationship.

Fuente: MATLAB

CAPÍTULO IV: RESULTADOS

En este capítulo se analizará los resultados obtenidos en las pruebas aplicadas al Modelo de predicción de demanda de energía eléctrica en la ciudad de Iquitos con redes neuronales.

Figura 11. Creación de la red neuronal artificial.



Fuente: MATLAB.

Entrenamiento

En la figura 12 se observa que existen diversos tipos de parámetros de seguimiento, igual que en el caso de las iteraciones (epoch), según el tipo de estudio, el entrenamiento o reentrenamiento puede parar en una dependencia al aprendizaje generado por la red.

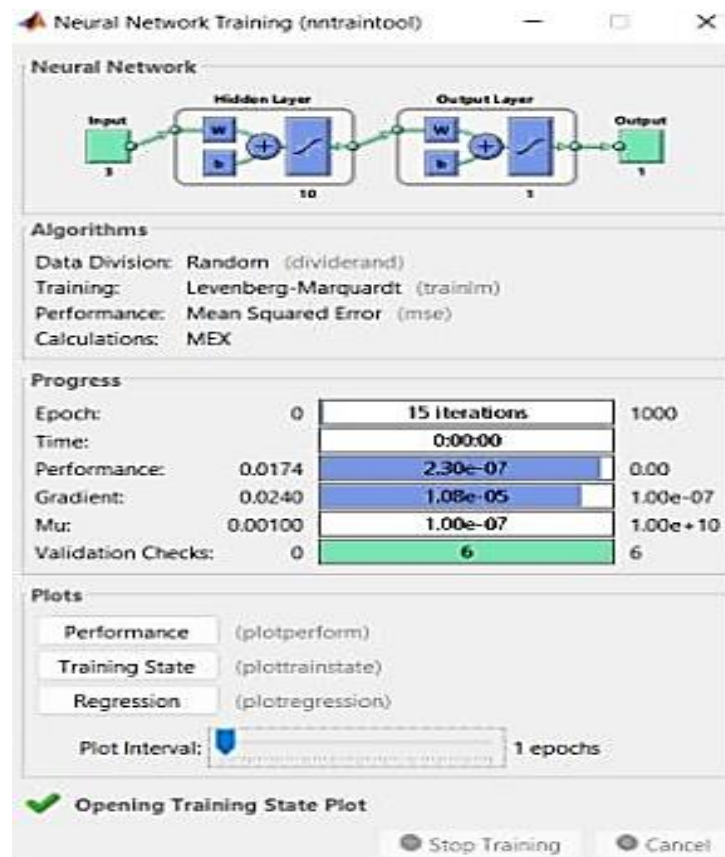
En cada una de las iteraciones realizadas por el sistema, los resultados para MSE y R son diferentes, la valoración y aceptación de los resultados depende directamente del análisis realizado por el especialista y también del desarrollador del trabajo de investigación.

El Mu nos muestra cual es el máximo valor de aprendizaje que existe a través la red neuronal, hasta el momento que el ajuste en las series de demanda y tiempo comiencen a disminuir en su nivel de confiabilidad.

Existen otras variables como el tiempo de iteración, el entrenamiento, el numero efectivo de parámetros y la suma cuadrada de la misma, son valores que pueden ayudar a obtener los resultados finales.

El reentrenamiento como se está mostrando en la Figura 12 se adapta al algoritmo seleccionado para funcionar, en este caso cuando se realiza un entrenamiento y no obtener los resultados requeridos medidos por los criterios de evaluación, se debe reentrenar la red en función de las entradas y objetivos de este proceso.

Figura 12. Arquitectura de la red neuronal artificial.




Fuente: MATLAB.

Una vez finalizado el entrenamiento se puede observar que hay 15 iteraciones, transcurrido los cero segundos, donde el error de validación no ha disminuido dando por finalizado el entrenamiento. Se pueden dibujar las siguientes gráficas:

Performance: Muestra el error cuadrático medio en función del número de iteraciones que para este caso fueron cero iteraciones con un Mean Squared Error (mse) de **0.0000047813**

Figura 13. Muestra del error cuadrático medio en función del número de iteraciones.

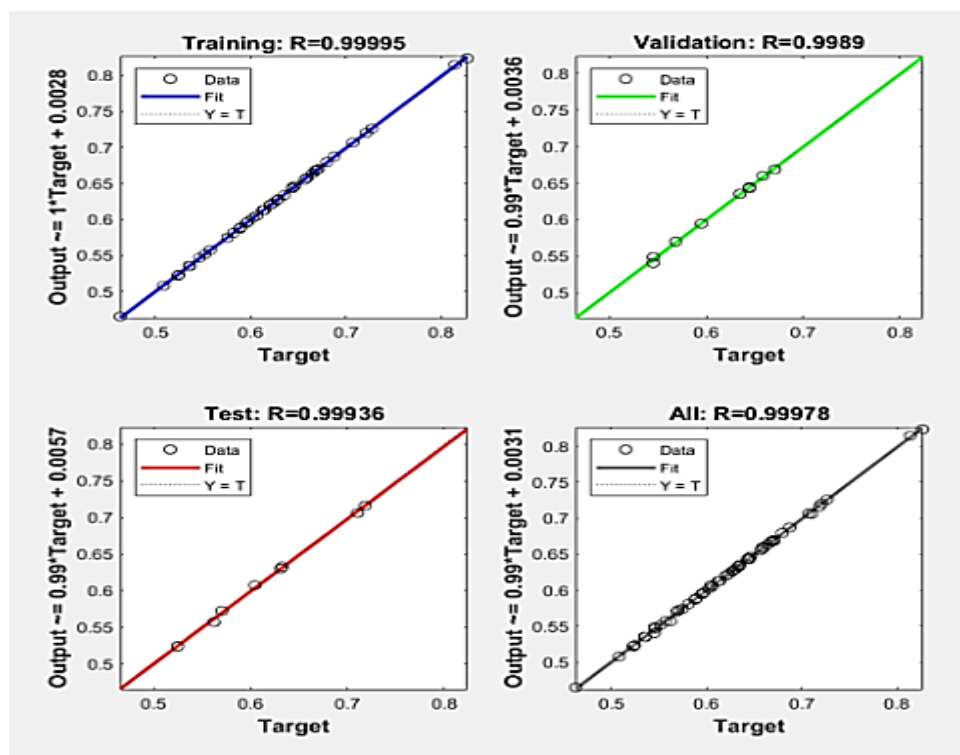


Fuente: MATLAB.

En la gráfica siguiente se muestra el gradiente, μ y la validación de fallo en función de las iteraciones.

Concluyendo que el error cuadrático medio en función de las épocas tanto en la etapa de entrenamiento, validación y prueba es de **0.0000047813**, de esta manera damos respuesta al objetivo específico de la investigación:” **Determinar** el Error cuadrático medio de la red neuronal artificial al predecir el consumo de energía eléctrica en la Ciudad de Nauta”.

Figura 14. Coeficiente de correlación del entrenamiento, validación y prueba.



Fuente: MATLAB.

En la Figura 14 podemos apreciar, que los coeficientes de correlación son bastante elevados con valores muy cercano a 1, lo cual significa la existencia de una alta correlación entre los valores reales y los valores pronosticados de la demanda de consumo eléctrico en la ciudad de Nauta, tanto en el entrenamiento (training: R=0.99995), validación (validation: R = 0.9989) y Prueba (Test: R = 0.99936)

Todo ello significa que podemos predecir mediante el desarrollo de redes neuronales artificiales el consumo de energía eléctrica de la ciudad de Nauta.

De esta manera damos respuesta al objetivo específico de la investigación:” Determinar el Coeficiente de Correlación del modelo de predicción en el consumo de energía eléctrica en la Ciudad de Nauta”.


Contrastación de Hipótesis.

Tabla 6. Valores predichos de consumo de energía eléctrica (Kilowatts/hora).

Meses	Consumo real	Consumo Predecido
1	2323.42	2178.169
2	1998.22	2043.844
3	1676.504	1669.842
4	1969.851	1993.802
5	2081.612	2143.929
6	2236.055	2175.535
7	2143.206	2167.634
8	2004.007	2025.408
9	2633.816	2678.169
10	1964.853	1962.196
11	1912.994	1898.984
12	1885.606	1872.646

Fuente: Elaboración propia.

Figura 15. Grafica de valores reales versus valores simulados



Fuente: Elaboración propia.

Con los datos de la tabla 6 se grafica la figura adjunta y se determina el Error cuadrático medio (MSE) y el coeficiente de correlación de Pearson (R^2) con las siguientes formulas:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{ic} - y_{im})^2$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{ic} - y_{im})^2}{\sum_{i=1}^n (y_{ic} - y_m)^2}$$

Dónde “n” es el número de observaciones, y_{ic} es el i-ésimo valor calculado, y_{im} y es el i-ésimo valor medido, finalmente m y es el valor medio de los valores calculados.

Se calculo en el MS Excel teniendo los siguientes resultados:

MSE= 1.0991

$R^2 = 0.94705$

Con estos resultados se acepta las hipótesis específicas de la investigación:

“El desarrollo de una red neuronal en MATLAB, permitirá predecir la demanda eléctrica de la ciudad de Nauta con un coeficiente de correlación mayor de 0.90”

“El desarrollo de una red neuronal, permitirá predecir la demanda eléctrica de la Ciudad de Nauta con un error cuadrático medio menor del 5%”

CAPÍTULO V: DISCUSIONES

El trabajo ejecutado tuvo como propósito el desarrollo de una herramienta computacional, que se utilizara para la predicción en la demanda de energía eléctrica basado en redes neuronales artificiales utilizando el software informático MATLAB, cuyos resultados obtenidos fue que el Error cuadrático medio de la red neuronal artificial al predecir el consumo de energía eléctrica en la Ciudad de Nauta es de **0.0000047813** y se aprecia, que el coeficiente de correlación en la prueba de la red neuronal artificial es bastante elevado (**R= 0.99978**) y muy cercano a 1, lo cual significa que existe una alta correlación entre los valores reales y los valores pronosticados, eso significa que el modelo de red neuronal propuesto es muy eficiente.

En su investigación, sin embargo, **Sinaluisa** concluyo que el porcentaje del error medio absoluto (MAPE) del modelo de predicción de la demanda de energía eléctrica la cual está basada en la red neuronal Feed Forward Backpropagation fue del 2,63%, mientras el que fue basado en regresión lineal múltiple fue del 4,56%, en comparación con los resultados de nuestra investigación que es mucho menor donde el Error cuadrático medio de la red neuronal artificial al predecir el consumo de energía eléctrica en la mencionada Ciudad de Nauta.

También Naula y Oscurio , desarrolló una herramienta computacional en Matlab, utilizando la interfaz gráfica (GUIDE) la cual permite predecir la demanda de energía eléctrica a corto plazo, utilizando la red neuronal artificial, utilizando el algoritmo de entrenamiento Levenberg Marquardt, con 288 números de retrasos, 10 neuronas, el 80 % de datos de entrenamiento, 10 % datos de validación y 10 % datos de prueba, donde obtuvieron un rendimiento del 1.11061×10^{-7} .

mediante los resultados que fueron pronosticados, proporcionando así, un acercamiento a los datos reales. Lo presentado por Naula y Oscurio tiene mucha coincidencia con nuestra investigación tanto en el algoritmo utilizado que es el Levenberg Marquardt y el error cuadrático medio que es 1.11061×10^{-7} .

CAPÍTULO VI: CONCLUSIONES

- El Coeficiente de Correlación del modelo de predicción en el consumo de energía eléctrica en la Ciudad de Nauta es $R= 0.99978$.
- El Error cuadrático medio de la red neuronal FeedForward Backpropagation al predecir el consumo de energía eléctrica en la Ciudad de Nauta es de **0.0000047813**.
- Existe una alta correlación entre los valores reales y aquellos valores que fueron pronosticados de la demanda de consumo eléctrico en la ciudad de Nauta, tanto en el entrenamiento (training: $R=0.99995$), validación (validation: $R = 0.9989$) y Prueba (Test: $R = 0.99936$).
- Se acepta la hipótesis de investigación: El desarrollo de una red neuronal en Matlab, permitirá la predicción de la demanda eléctrica de la ciudad de Nauta con un coeficiente de correlación mayor de 0.90.

CAPÍTULO VII: RECOMENDACIONES

- Se recomienda implementar el DATASET con más variables de entrada a fin de tener mejores resultados de predicción.
- Se recomienda desarrollar modelos a largo plazo, toda vez que se necesiten las aplicaciones de modelos basados en redes neuronales están demostrado de manera eficiente el pronóstico de demanda eléctrica.
- Se recomienda realizar una lectura de datos desde una base de datos para almacenarlos debidamente.

CAPÍTULO VIII: REFERENCIAS BIBLIORÁFICAS

- BOWERMAN B, Y OTROS (2007). Pronósticos, series de tiempo y regresión: un enfoque aplicado, México: Cengage Learning.
- CORTINA, M. (2012). Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos. Madrid: McGraw-Hill.
- BRUNER, J. (2001). El proceso mental en el aprendizaje. Madrid: Narcea, S. A.
- GARZÓN Y, MARULANDA G. (2017). Estimación del consumo eléctrico colombiano en el corto y largo plazo empleando regresión multivariable y series temporales. Colombia, 14.pp.
- GÖNEN, T. (2014). Electric Power Distribution Engineering,» Taylor & Francis Group, LLC, New York.
- MATICH, D. (2001.) Redes Neuronales: Conceptos Básicos y Aplicaciones,» Universidad Tecnológica Nacional, Rosario.
- MONOBANDA F. (2020). Predicción de la demanda de energía eléctrica en la producción de petróleo de los campos de Petroamazonas Ep utilizando redes neuronales artificiales. Escuela Politécnica Nacional, Quito.
- MARTÍN DEL BRIO B; SANZ MOLINA A. (2020.) Redes neuronales y sistemas difusos, Ciudad de México: Alfaomega.
- MORENO, A. ET AL. (1994). Aprendizaje automático. Barcelona, España: Ediciones UPC.
- MORILLO, F. Modelo para el pronóstico de la demanda de energía eléctrica de EMELNORTE S. A. Ibarra aplicando redes neuronales artificiales (Título de ingeniero industrial). Ecuador. Universidad Técnica

del Norte, 2020. 81 pp.

- NAULA, S Y OSCURIO, D. Predicción de la demanda de energía eléctrica a corto plazo utilizando redes neuronales artificiales. (Título de Ingeniero Eléctrico en Sistemas Eléctricos de Potencia) (2021). Ecuador. Universidad Técnica de Cotopaxi, 2021 .78 .pp.
- LAUDON, K, & LAUDON, J. (2012). Sistemas de Información Gerencial. 12va. Ed. México D.F., México: Prentice Hall.
- PLAZA, E. (1992). Tendencias en Inteligencia Artificial (pág. 379). Universidad de Deusto.
- PONCE, P. (2010) Inteligencia Artificial con Aplicaciones a la Ingeniería, México: Alfaomega.
- RAMÍREZ CASTAÑO, S. (2004). Redes de Distribución de Energía, Colombia: Centro de Publicaciones Universidad Nacional de Colombia.
- REQUENA A, *et al.* (2019). Equivalencia entre redes artificiales y biológicas, Nuevas Tecnologías y Contaminación de Atmósferas, para PYMEs. vol. VI, nº 4, p. 3, 2.
- RINGWOOD, J. «Intelligent Forecasting of Electricity Demand,» Department of Electronic Engineering, Maynooth, Department of Electronic Engineering NUI Maynooth.
- RUSSELL S; NORVING P. (2004). Inteligencia Artificial un Enfoque Moderno. Madrid: PEARSON Prentice Hall.
- SINALUISA, I. (2017) Aplicación de la red neuronal artificial feedforward backpropagation para la predicción de demanda de energía eléctrica en la empresa eléctrica RIOBAMBA S.A. (Grado de magister en sistemas de control y automatización industrial). Ecuador. Escuela Superior

Politécnica de Chimborazo. 90. pp.

- VILLACÍS, L. (2017). Predicción de la demanda eléctrica en barra de 69 kV del sistema eléctrico de subtransmisión de la empresa eléctrica Riobamba S.A.,» Universidad Politécnica Nacional, Quito.

ANEXOS

ANEXO 1. MATRIZ DE CONSISTENCIA

PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES	INDICADORES	METODOLOGÍA
<p>PROBLEMA GENERAL ¿De qué manera el desarrollo de una herramienta computacional puede hacer predicciones de la demanda de energía eléctrica en la Ciudad de Nauta?</p> <p>Preguntas específicas</p> <p>- ¿De qué manera el desarrollo de una red neuronal, permitirá predecir la demanda eléctrica de la Ciudad de Nauta con un coeficiente de correlación mayor de 0,90?</p> <p>- ¿De qué manera el desarrollo de una red neuronal, permitirá predecir la demanda eléctrica de la Ciudad de Nauta con un error cuadrático medio menor del 5%?</p>	<p>OBJETIVO GENERAL Desarrollar una herramienta computacional para la predicción de la demanda de energía eléctrica basado en redes neuronales artificiales mediante el programa computacional Matlab.</p> <p>Objetivos específicos OE1. Determinar el Coeficiente de Correlación del modelo de predicción en el consumo de energía eléctrica en la Ciudad de Nauta. OE2. Determinar el Error cuadrático medio de la red neuronal artificial al predecir el consumo de energía eléctrica en la Ciudad de Nauta.</p>	<p>HIPÓTESIS GENERAL Si se desarrolla una herramienta computacional mediante el programa computacional Matlab, entonces se podrá hacer predicciones de la demanda de energía eléctrica en la Ciudad de Nauta.</p> <p>Hipótesis específicas</p> <p>-El desarrollo de una red neuronal en MATLAB, permitirá predecir la demanda eléctrica de la ciudad de Nauta con un coeficiente de correlación mayor de 0.90.</p> <p>- El desarrollo de una red neuronal, permitirá predecir la demanda eléctrica de la Ciudad de Nauta con un error cuadrático medio menor del 5%</p>	<p>VARIABLE INDEPENDIENTE: Redes neuronales artificiales</p> <p>VARIABLE DEPENDIENTE: Predicción de la demanda de energía eléctrica.</p>	<p>INDEPENDIENTE -Entrenamiento -Prueba -Validación</p> <p>DEPENDIENTE -Coeficiente de Correlación del modelo de predicción. -Error absoluto porcentual promedio (MAPE).</p>	<p>Tipo de investigación: Aplicada Nivel de la investigación: Predictiva. Diseño de la investigación: Diseño de la solución:</p>

Fuente: Elaboración propia

ANEXO 2: INSTRUMENTOS DE RECOLECCION DE DATOS
Consumo de energía eléctrica (kilowatts / hora)

	2016	2017	2018	2019	2020	2021
Enero						
Febrero						
Marzo						
Abril						
Mayo						
Junio						
Julio						
Agosto						
Setiembre						
Octubre						
Noviembre						
Diciembre						

Fuente. ELECTRO ORIENTE

Anexo 3: CÓDIGO FUENTE.

```
% Solve an Input-Output Fitting problem with a Neural Network
% Script generated by Neural Fitting app
% Created 31-Aug-2022 13:48:31
%
% This script assumes these variables are defined:
%
%   data - input data.
%   data_1 - target data.

x = data;
t = data_1;

% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging
problems.
% 'trainscg' uses less memory. Suitable in low memory
situations.
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

% Create a Fitting Network
hiddenLayerSize = 10;
net = fitnet(hiddenLayerSize,trainFcn);

% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nnprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help
nndivision
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
% For a list of all performance functions type: help
nnperformance
net.performFcn = 'mse'; % Mean Squared Error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
net.plotFcns = {'plotperform','plottrainstate','ploterrhist',
...
'plotregression','plotfit'};

% Train the Network
[net,tr] = train(net,x,t);

% Test the Network
```

```

y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y)

% Recalculate Training, Validation and Test Performance
trainTargets = t .* tr.trainMask{1};
valTargets = t .* tr.valMask{1};
testTargets = t .* tr.testMask{1};
trainPerformance = perform(net,trainTargets,y)
valPerformance = perform(net,valTargets,y)
testPerformance = perform(net,testTargets,y)

% View the Network
view(net)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, ploterrhist(e)
%figure, plotregression(t,y)
%figure, plotfit(net,x,t)

% Deployment
% Change the (false) values to (true) to enable the following
code blocks.
% See the help for each generation function for more
information.
if (false)
    % Generate MATLAB function for neural network for
application
    % deployment in MATLAB scripts or with MATLAB Compiler and
Builder
    % tools, or simply to examine the calculations your trained
neural
    % network performs.
    genFunction(net,'myNeuralNetworkFunction');
    y = myNeuralNetworkFunction(x);
end
if (false)
    % Generate a matrix-only MATLAB function for neural network
code
    % generation with MATLAB Coder tools.

genFunction(net,'myNeuralNetworkFunction','MatrixOnly','yes');
    y = myNeuralNetworkFunction(x);
end
if (false)
    % Generate a Simulink diagram for simulation or deployment
with.
    % Simulink Coder tools.
    gensim(net);
end

```