



**UNIVERSIDAD TÉCNICA DE COTOPAXI
FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS
INGENIERÍA ELÉCTRICA EN SISTEMAS ELÉCTRICOS DE
POTENCIA**

PROYECTO DE INVESTIGACIÓN

**PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO
PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES.**

Proyecto de titulación presentado previo a la obtención del Título de Ingeniero Eléctrico en
Sistemas Eléctricos de Potencia

Autores:

Naula Saquina Henry Sebastián
Oscurio Ordoñez Darwin Stalin

Tutor Académico:

Ing. MSc. Carlos Iván Quinatoa Caiza

LATACUNGA – ECUADOR

2021

DECLARACIÓN DE AUTORÍA

Nosotros, **Naula Saquina Henry Sebastián** con C.I. N°: **185060119-4** y **Oscuro Ordoñez Darwin Stalin** con C.I. N°: **110553609-6**, declaramos ser autores del presente proyecto de investigación: **“PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES”**, siendo el **Ing. MSc. Carlos Iván Quinatoa Caiza** tutor del presente trabajo; eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

Además, certificamos que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo, son de nuestra exclusiva responsabilidad.



Naula Saquina Henry Sebastián
C.C: 185060119-4



Oscuro Ordoñez Darwin Stalin
C.C: 110553609-6

AVAL DEL TUTOR DE PROYECTO DE TITULACIÓN

En calidad de Tutor del Trabajo de Investigación sobre el título: “**PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES**”, de **Naula Saquina Henry Sebastián y Oscurio Ordoñez Darwin Stalin**, de la carrera de **Ingeniería Eléctrica**, considero que dicho Informe Investigativo cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos a la evaluación del Tribunal de Validación de Proyecto que el Consejo Directivo de la Facultad de **Ciencias de la Ingeniería y Aplicadas** de la Universidad Técnica de Cotopaxi designe, para su correspondiente estudio y calificación.

Latacunga, agosto 2021



Firmado electrónicamente por:
**CARLOS IVAN
QUINATO
CAIZA**

Ing. MSc. Carlos Iván Quinatoa Caiza

CC: 0503287864

APROBACIÓN DEL TRIBUNAL DE TITULACIÓN

En calidad de Tribunal de Lectores, aprueban el presente Informe de Investigación de acuerdo a las disposiciones reglamentarias emitidas por la Universidad Técnica de Cotopaxi, y por la Facultad de Ciencias de la Ingeniería y Aplicadas; por cuanto, los postulantes: **Naula Saquinga Henry Sebastián y Oscuro Ordoñez Darwin Stalin**, con el título de Proyecto de titulación: “**PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES**”, han considerado las recomendaciones emitidas oportunamente y reúne los méritos suficientes para ser sometido al acto de Sustentación de Proyecto.

Por lo antes expuesto, se autoriza realizar los empastados correspondientes, según la normativa institucional.

Latacunga, agosto 2021

Para constancia firman:

Atentamente,



Firmado electrónicamente por:
**GABRIEL NAPOLEON
PESANTEZ PALACIOS**

Lector 1 (Presidente)

Nombre: Gabriel Napoleón Pesantes Palacios
CC: 0301893889

Edgar Roberto Salazar Achig Firmado digitalmente por
Edgar Roberto Salazar Achig
Fecha: 2021.07.29 16:18:31
-05'00'

Lector 2

Nombre: Edgar Roberto Salazar Achig
CC: 0502847619

José Efrén Barbosa Galarza Firmado digitalmente por
José Efrén Barbosa Galarza
Fecha: 2021.07.29 22:00:30
-05'00'

Lector 3:

Nombre: José Efrén Barbosa Galarza
CC: 0501420723

AGRADECIMIENTO

Agradezco a Dios por cuidarme por su bondad, amor y darme la fuerza para permitir cumplir mis metas porque su presencia nunca me dejó solo en cada paso que di, a pesar de las adversidades siempre estuvo dándome aliento, "Quiero alabarte, Señor con todo el corazón, y contar todas tus maravillas".

"Pero gracias a Dios, que nos da la victoria por medio de nuestro Señor Jesucristo"

1 Corintios 15:57

Agradezco a mis abuelitos Ángel Saquina y Teresa de Jesús Cahahuishca, por todas sus palabras que me enseñaron el valor, respeto, responsabilidad y honestidad enseñándome que la palabra de una persona es su firma, por confiar en mí y estar conmigo en mis éxitos y fracasos, nunca perdiendo la fe en Dios y a mis tíos que fueron el apoyo y la columna que me apoyaron en todo, por su cariño y dulzura. A la Universidad Técnica de Cotopaxi por abrirme las puertas y permitirme cumplir una meta más en mi vida, que junto con sus maestros han logrado formarme profesionalmente, a mi compañero de tesis porque a pesar de las dificultades Dios nunca nos abandonó

Henry Sebastián Naula Saquina

AGRADECIMIENTO

En primera instancia quiero agradecer a Dios y la Virgen del Cisne por permitirme llegar a esta última etapa de mi carrera profesional, ya que con su amparo y protección he sabido salir adelante.

A mis Padres Rene Jumbo y Rosita Ordoñez mis viejitos, que nunca me dejaron solo, al contrario, me brindaron su apoyo, sus consejos de superación y a no desmayar. ¡Les debo mi vida entera, Gracias a ellos soy lo que soy!

Agradezco a mi esposa Belén Espinoza que ha sido un apoyo incondicional, por estar presente en todos mis momentos, durante mi etapa universitaria, y estar juntos con nuestra pequeña princesa Aitana Oscurio.

A mi tutor de Tesis el MSc. Carlos Quinatoa que con sus sabios consejos y experiencia nos ha sabido guiar de la mejor manera, para presentar un trabajo de calidad.

A mi compañero de tesis que gracias al trabajo mutuo podemos culminar con esta etapa final de nuestra carrera universitaria.

A mis maestros de la prestigiosa Universidad Técnica de Cotopaxi, por compartir sus enseñanzas y experiencias que dan fruto para nuestro bien y la sociedad.

Darwin Stalin Oscurio Ordoñez

DEDICATORIA

Dedico este trabajo a Dios por su amor infinito e incomparable y que me dio fuerzas para seguir en la batalla de la vida y encontrar el éxito.

A mi abuelita Teresa de Jesús Cajahuishca por mostrarme que la vida no es nada fácil y que a pesar de los problemas y obstáculos que se presenten día a día hay que ser fuerte y salir con la frente en alto para poder cumplir los sueños que uno quiere.

A mi abuelito Ángel Saquina por guiarme, apoyarme y amarme, por enseñarme que la dedicación que se pone a algo algún día da frutos.

A mis tíos por ser amigos, confidentes, por estar junto a mí en todo lo bueno y en lo malo por ser parte de mis sueños y planes.

“Que nunca te abandonen el amor y la verdad: llévalos siempre alrededor de tu cuello y escríbelos en el libro de tu corazón. Contarás con el favor de Dios y tendrás buena fama entre la gente”

Proverbios 3:3-4

Henry Sebastián Naula Saquina

DEDICATORIA

Dedico este trabajo de investigación primeramente al Padre Celestial que nunca me soltó de sus benditas manos, por haberme dado la vida y bendecirme con el don de entendimiento para así finalizar con éxito mi carrera profesional.

Con mucho amor a mi madre Rosita por ser mi pilar fundamental, por creer en mí y siempre estar a mi lado, tus sacrificios no fueron en vano, aquí está el regalo que anhelas y que hoy por hoy se ven plasmados al culminar mi carrera universitaria. ¡Un Dios le pague mi viejita!

Con aprecio y respeto a ti mi viejo Rene, por enseñarme los caminos de la vida, a trabajar con honradez y humildad, a no mirar hacia atrás ante una dificultad sino un ¡sigue adelante mijo!

A mi amada esposa Belén, por ser mi compañera confidente, en todo lo que me he planteado usted ha estado conmigo, amor mío una muestra de que usted también lo puede lograr y ser lo que usted sueña.

Sin duda dedico todo mi esfuerzo y trabajo a mi adorada hija Aitana, mi pequeño amor, la niña que se robó mi corazón, esto va por ti mi princesa.

A toda mi familia, amigos que de una u otra manera me han apoyado y han creído en mí, ¡desde el fondo de mi corazón muchas gracias!

Darwin Stalin Oscuro Ordoñez

INDICE DE CONTENIDO

1. INFORMACIÓN GENERAL	1
2. INTRODUCCIÓN.....	3
2.1. PROBLEMA DE INVESTIGACIÓN.....	3
2.1.1. Situación Problémica.....	3
2.1.2. Formulación del problema:.....	4
2.2. OBJETO Y CAMPO DE ACCIÓN	4
2.2.1. Objeto de Investigación	4
2.2.2. Campo de acción	4
2.3. BENEFICIARIOS DEL PROYECTO.....	4
2.3.1. Beneficiarios directos	4
2.3.2. Beneficiarios indirectos	5
2.4. JUSTIFICACIÓN.....	5
2.5. HIPÓTESIS.....	5
2.6. OBJETIVOS.....	6
2.6.1. Objetivo General:	6
2.6.2. Objetivos Específicos:	6
2.7. SISTEMA DE TAREAS.....	6
3. FUNDAMENTACIÓN CIENTÍFICO TÉCNICA.....	7
3.1. ANTECEDENTES DE LA INVESTIGACIÓN.....	7
3.2. MARCO TEÓRICO	8
3.2.1. Subestación San Rafael – Alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo.....	8
3.2.2. Demanda eléctrica en Ecuador	11
3.2.2.1. <i>Demanda eléctrica</i>	11
3.2.2.2. <i>Tipos de demanda eléctrica</i>	12

3.2.3.	Curva de Demanda	13
3.2.3.1.	<i>Curvas de carga diaria.</i>	15
3.2.3.2.	<i>Curvas de carga anual.</i>	15
3.2.3.3.	<i>Demanda Máxima o Carga Máxima</i>	16
3.2.3.4.	<i>Carga Instalada</i>	16
3.2.3.5.	<i>Capacidad Instalada</i>	16
3.2.4.	Predicción de la demanda eléctrica	16
3.2.4.1.	<i>Importancia del pronóstico de demanda de energía eléctrica</i>	17
3.2.4.2.	<i>La planificación estratégica y su relación con la predicción de la demanda eléctrica</i>	18
3.2.4.3.	<i>Horizontes para la predicción de la demanda eléctrica</i>	19
3.2.4.4.	<i>Factores que influyen en la predicción de la demanda eléctrica</i>	20
3.2.5.	Métodos para la predicción de la demanda eléctrica.....	21
3.2.6.	Procedimiento para realizar la predicción de la demanda eléctrica mediante redes neuronales artificiales.....	21
3.2.7.	Clasificación de los métodos de pronóstico de demanda de Energía Eléctrica..	23
3.2.7.1.	<i>Métodos de Inteligencia Artificial</i>	23
3.2.8.	Redes neuronales artificiales	24
3.2.8.1.	<i>Ventajas de las redes neuronales artificiales</i>	25
3.2.9.	Elementos de una red neuronal.....	26
3.2.9.1.	<i>Neurona artificial</i>	26
3.2.9.2.	<i>Unidad de proceso.</i>	27
3.2.9.3.	<i>Conexiones y pesos sinápticos.</i>	28
3.2.9.4.	<i>Función de activación.</i>	28
3.2.9.5.	<i>Función de salida o transferencia</i>	29
3.2.9.6.	<i>Regla de aprendizaje.</i>	30
3.2.10.	Topología o arquitectura de redes neuronales	30

3.2.10.1.	<i>Según la estructura en capas.</i>	30
3.2.10.2.	<i>Según el flujo de datos en la red</i>	31
3.2.10.3.	<i>Según el tipo de respuesta de la red o asociación entrada y salida.</i>	32
3.2.11.	Mecanismo de aprendizaje	32
3.2.11.1.	<i>Supervisado</i>	32
3.2.11.2.	<i>No supervisado.</i>	33
3.2.11.3.	<i>Algoritmo de aprendizaje de retro propagación.</i>	34
3.2.12.	Perceptor multicapa	35
3.2.13.	Problemas derivados del Entrenamiento	36
3.2.13.1.	<i>Underfitting</i>	37
3.2.13.2.	<i>Overfitting</i>	37
3.2.13.3.	<i>Normal fitting</i>	38
4.	METODOLOGÍA	39
4.1.	TIPO DE INVESTIGACIÓN	39
4.1.1.	Investigación descriptiva	39
4.1.2.	Investigación diagnóstica	39
4.1.3.	Investigación aplicada	40
4.2.	MÉTODO DE INVESTIGACIÓN	40
4.2.1.	Metodología de la investigación bibliográfica.	40
4.2.2.	Inductivo – deductivo	40
4.3.	TÉCNICAS E INSTRUMENTOS	40
4.3.1.	La observación	40
4.3.2.	Simulación	41
4.3.3.	Programación	41
5.	ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS	41

5.1. METODOLOGÍA DEL PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO.	41
5.2. ANÁLISIS DE LA BASE DE DATOS HISTÓRICOS	42
5.2.1. Análisis del comportamiento de la base de datos reales.....	42
5.2.2. Análisis del comportamiento de la demanda eléctrica pronosticada.....	47
5.3. COMPARACIÓN DE DATOS REALES Y PRONÓSTICO DE LA RED NEURONAL.....	51
5.4. INTERFACES GRÁFICAS DESARROLLADAS	55
5.4.1. Módulo Datos Históricos.....	55
5.4.2. Módulo Entrenamiento Red.....	57
5.4.3. Módulo Predicción Demanda	59
5.5. Entrenamiento de la red.....	61
5.5.1. Número de capas ocultas	61
5.5.2. Función de activación de salida.....	61
5.5.3. Módulos de los problemas derivados del entrenamiento.....	62
5.6. Predicción de la demanda eléctrica	68
5.6.1. Variación del algoritmo de entrenamiento	68
5.6.2. Variación del número de neuronas	69
5.6.3. Variación del número de retrasos de tiempo	70
6. CONCLUSIONES Y RECOMENDACIONES	71
6.1. CONCLUSIONES	71
6.2. RECOMENDACIONES	72
7. BIBLIOGRAFÍA.....	73
8. ANEXOS	78

ÍNDICE DE TABLAS

Tabla 2.1: Sistema de tareas en relación a los objetivos planteados.	6
Tabla 3.1: Tipo de carga en el alimentador Santa Rosa de Pichul - San Gerardo.....	11
Tabla 3.2: Funciones de activación.	28
Tabla 5.1: Análisis descriptiva con datos reales de la demanda eléctrica	43
Tabla 5.2: Análisis descriptiva con datos reales de la demanda eléctrica	48
Tabla 5.3: Error promedio entre demanda eléctrica real y pronosticada (semanal).....	52
Tabla 5.4: Error promedio entre demanda eléctrica real y pronosticada (Diaria)	54
Tabla 5.5: Resultados variación algoritmo de entrenamiento de la red neuronal	68
Tabla 5.6: Resultados variación número de neuronas	69
Tabla 5.7: Resultados variación número de neuronas	70

ÍNDICE DE FIGURAS

Figura 3.1: Ubicación geográfica de la S/E San Rafael.	9
Figura 3.2: Alimentador Santa Rosa de Pichul - San Gerardo (CYME).....	10
Figura 3.3: Ubicación geográfica del alimentador Santa Rosa de Pichul - San Gerardo.....	10
Figura 3.4: Curva típica de demanda diaria ($T_n = 24$ horas)	12
Figura 3.5: Curva de la demanda eléctrica.....	12
Figura 3.6: Curva de demanda horaria.	13
Figura 3.7: Curva de la demanda eléctrica de los días laborables.....	14
Figura 3.8: Curva de la demanda eléctrica de los fines de semana.	14
Figura 3.9: Curva de carga diaria típicas.....	15
Figura 3.10: Curvas de carga anual	16
Figura 3.11: Contexto general de actividades en los Sistemas de Energía Eléctrica	17
Figura 3.12: Factores que influyen en el comportamiento de la demanda eléctrica	20
Figura 3.13: Procedimiento para la predicción de la demanda utilizando redes neuronales artificiales.	22
Figura 3.14: Métodos de pronóstico de demanda de Energía Eléctrica	23
Figura 3.15: Clasificación de los métodos de inteligencia artificial para predicción de la demanda eléctrica	24
Figura 3.16: Relación entre una neurona biológica y artificial	26
Figura 3.17: Estructura de una neurona biológica y una neurona artificial mediante un modelo matemático.....	27
Figura 3.18: Red neuronal artificial monocapa.....	30
Figura 3.19: Redes de propagación hacia adelante (feedforward)	31
Figura 3.20: Red multicapa de propagación hacia atrás (Feedback).....	35
Figura 3.21: Equilibrio de aprendizaje en underfitting.	37
Figura 3.22: Equilibrio de aprendizaje en overfitting	38
Figura 3.23: Equilibrio de aprendizaje en normal fitting	38

Figura 3.24: Test de entrenamiento de la red neuronal	39
Figura 5.1: Diagrama de flujo del pronóstico de la demanda a corto plazo.....	41
Figura 5.2: Curva demanda eléctrica semanal	42
Figura 5.3: Desviación estándar de datos de la semana en estudio.....	44
Figura 5.4: Curva de la demanda eléctrica de la semana en estudio.....	45
Figura 5.5: Capacidades del proceso para la demanda de energía eléctrica (datos reales – 1 semana).....	46
Figura 5.6: Curva de la demanda eléctrica diaria con intervalos de 1 hora	46
Figura 5.7: Capacidades del proceso para la demanda de energía eléctrica (datos reales - 1 día)	47
Figura 5.8: Curva de la demanda eléctrica pronosticada	48
Figura 5.9: Desviación estándar con datos de la demanda pronosticada	49
Figura 5.10: Capacidades del proceso para la demanda de energía eléctrica (datos pronosticados - 1 semana)	50
Figura 5.11: Demanda eléctrica diaria con datos obtenidos del pronóstico.....	50
Figura 5.12: Capacidades del proceso para la demanda de energía eléctrica (datos pronosticados - 1 día)	51
Figura 5.13: Curva de la demanda eléctrica real vs pronosticada.....	52
Figura 5.14: Gráfica de error entre curva de la demanda eléctrica real y pronosticada (semanal)	52
Figura 5.15: Intervalos de la demanda de energía eléctrica (Datos reales y de pronóstico – 1 semana).....	53
Figura 5.16: Curva demanda eléctrica real vs pronosticada (Diaria).....	53
Figura 5.17: Gráfica de error entre curva de la demanda eléctrica real y pronosticada (Diaria)	54
Figura 5.18: Intervalos de la demanda de energía eléctrica (Datos reales y de pronóstico - 1 día)	54
Figura 5.19: Menú de selección de módulos.....	55

Figura 5.20: Módulo de datos histórico (Datos totales).....	56
Figura 5.21: Módulo de datos histórico (Datos parciales)	56
Figura 5.22: Módulo de datos histórico (Visualización de datos numéricos).....	57
Figura 5.23: Módulo entrenamiento red.....	58
Figura 5.24: Configuración red neuronal creada.....	58
Figura 5.25: Resultados entrenamiento red neuronal.....	59
Figura 5.26: Módulo Predicción Demanda (Visualización grafica).	60
Figura 5.27: Módulo predicción de la demanda (Visualización numérica).....	60
Figura 5.28: Red neuronal (una capa oculta y una de salida).	61
Figura 5.29: Función de activación (tangente hiperbólica).....	62
Figura 5.30: Código para ingresar parámetros de la red neuronal.	62
Figura 5.31: Red neuronal en underfitting.	62
Figura 5.32: Histograma de error.	63
Figura 5.33: Pendiente de regresión a 45° de la red neuronal (underfitting).	63
Figura 5.34: Código para ingresar parámetros de la red neuronal.	64
Figura 5.35: Red neuronal en overfitting.	64
Figura 5.36: Histograma de error.	65
Figura 5.37: Pendiente de regresión a 45° de la red neuronal (overfitting).	65
Figura 5.38: Código para ingresar parámetros de la red neuronal.	66
Figura 5.39: Red neuronal en normal fitting (ajuste normal).....	66
Figura 5.40: Histograma de error	67
Figura 5.41: Pendiente de regresión a 45° de la red neuronal (ajuste normal).	67
Figura 5.42: Resultados variación algoritmo de entrenamiento de la red neuronal	68
Figura 5.43: Resultados variación número de neuronas	69
Figura 5.44: Resultados variación número de neuronas	70

UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

TEMA: "PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES".

Autores:

Naula Saquina Henry Sebastián

Oscuro Ordoñez Darwin Stalin

RESUMEN

La implementación de la redes neuronales artificiales se realizó debido al problema que existe en la predicción de la demanda eléctrica a corto plazo el cual afecta el desempeño del flujo de carga, análisis de seguridad, coordinación hidrotérmica, plan de mantenimiento preventivo de los generadores y despacho económico, por lo que se ha optado en el desarrollo de una herramienta computacional, basado en redes neuronales artificiales mediante el programa computacional MATLAB, utilizando datos reales del alimentador PRI12 Santa Rosa de Pichul – San Gerardo, esto permitió realizar un análisis del comportamiento de la demanda eléctrica horaria con el objetivo de obtener una predicción óptima. El programa está conformado por la interfaz gráfica (GUIDE) con tres módulos tales como datos históricos, entrenamiento de la red neuronal y predicción de la demanda eléctrica, para este proyecto de investigación la RNA está compuesta por una capa de entrada, una capa oculta (función de activación tangente hiperbólico) y una capa de salida (función de activación lineal), utilizando el algoritmo de entrenamiento levenberg-marquardt mediante 288 retrasos, 10 neuronas, 80 % de datos de entrenamiento, 10 % datos de validación y 10 % de datos de prueba, así obteniendo resultados adecuados de rendimiento del 1.01×10^{-7} , de igual forma presenta el mayor ajuste al comportamiento de la serie de datos con un error porcentual del 1,60 %, finalmente en base de las curvas estadísticas de los valores reales y pronosticados se obtiene un error del 0,99%, obteniendo una predicción a corto plazo satisfactoria.

Palabras Claves— *Predicción de la demanda eléctrica a corto plazo, Redes Neuronales Artificiales, tangente hiperbólica, Lebemberg – Marquart y función lineal.*

TECHNICAL UNIVERSITY OF COTOPAXI

FACULTY OF APPLIED AND ENGINEERING SCIENCE

TITLE: “FORECAST OF ELECTRICAL ENERGY DEMAND IN THE SHORT-TERM BY USING ARTIFICIAL NEURONAL NETWORKS”.

Authors:

Naula Saquinga Henry Sebastian

Oscurio Ordoñez Darwin Stalin

ABSTRACT

The implementation of artificial neuronal networks was carried out due to the problem that exists in the forecast of short-term electricity demand which affects the performance of load flow, safety analysis, hydrothermal coordination, preventive maintenance plan of generators and economic dispatch. Therefore, a computational tool based on artificial neural networks was developed, through the MATLAB computer program, using real data from the PRI12 ‘Santa Rosa de Pichul’ – ‘San Gerardo’ feeder, which allowed to analyze the behavior of the hourly electric demand in order to obtain an optimal forecast. The program is established by the graphical interface (GUIDE) with three modules such as historical data, neural network training and electrical demand forecast, for this research study the ANN is composed by an input layer, a hidden layer (hyperbolic tangent activation function) and an output layer (linear activation function), using the Levenberg-Marquardt training algorithm by using 288 delays, 10 neurons, 80% training data, 10% validation data and 10% test data, thus obtaining adequate performance results of 1.01×10^{-7} , in the same way it presents the best adjustment to the behavior of the data series with a percentage error of 1.60 %, finally on the basis of the statistical curves of the real and predicted values an error of 0.99% was obtained, finding a satisfactory short-term forecast.

Keywords— *Short-term electricity demand forecasting, Artificial Neural Networks, hyperbolic tangent, Levenberg - Marquardt and linear function.*

AVAL DE TRADUCCIÓN

En calidad de Docente del Idioma Inglés del Centro de Idiomas de la Universidad Técnica de Cotopaxi; en forma legal **CERTIFICO** que:

La traducción del resumen al idioma Inglés del proyecto de investigación cuyo título versa: **"PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES"** presentado por: **Naula Saquina Henry Sebastián y Oscuro Ordoñez Darwin Stalin**, egresados de la Carrera de: **Ingeniería Eléctrica**, perteneciente a la **Facultad de Ciencias de la Ingeniería y Aplicadas**, lo realizaron bajo mi supervisión y cumple con una correcta estructura gramatical del Idioma.

Es todo cuanto puedo certificar en honor a la verdad y autorizo a los peticionarios hacer uso del presente aval para los fines académicos legales.

Latacunga, Julio del 2021

Atentamente,



Mg. Patricia Marcela Chacón Porras
DOCENTE CENTRO DE IDIOMAS
C.C. 0502211196



**CENTRO
DE IDIOMAS**

1. INFORMACIÓN GENERAL

Título del proyecto: Predicción de la demanda de energía eléctrica a corto plazo, mediante la utilización de redes neuronales artificiales.

Fecha de inicio: Abril_2021

Fecha de finalización: Agosto_2021

Lugar de ejecución: Universidad Técnica de Cotopaxi - Barrio Eloy Alfaro – Latacunga - Cotopaxi, Ecuador

Facultad que auspicia: Ciencias de la Ingeniería y Aplicadas (CIYA).

Carrera que auspicia: Ingeniería eléctrica en Sistemas Eléctricos de Potencia.

Proyecto de investigación vinculado: Predicción de la demanda eléctrica mediante redes neuronales artificiales.

Equipo de Trabajo:

TUTOR

Nombres y Apellidos: Ing. MSc. Carlos Iván Quinatoa Caiza

Lugar y fecha de Nacimiento: Tanicuchi, 01 de agosto de 1988

Estado civil: Soltero

Cédula de Ciudadanía: 0503287864

E-MAIL: carlos.quinatoa4@utc.edu.ec

Títulos:

- 2016-2018 Universidad Tecnológica de Pereira-Colombia / Universidad Nacional de San Juan-Argentina, Facultad de Ingeniería Eléctrica, Magister en Ingeniería Eléctrica
- 2014-2018 Universidad Nacional de San Juan, San Juan-Argentina, Instituto de Energía Eléctrica, Estudios de Doctorado en Ingeniería Eléctrica.

- 2007-2013 Universidad Técnica de Cotopaxi, Latacunga-Cotopaxi-Ecuador, Facultad de Ciencias de la Ingeniería y Aplicadas, Ingeniero Eléctrico en Sistemas Eléctricos de Potencia
- 2000-2006 Colegio. Gral.” Marco Aurelio Subía”, Tanicuchi-Latacunga-Ecuador, Bachiller, Técnico en Electricidad.
- 1994-2000 Escuela Mixta” Zamora”, Tanicuchi-Latacunga-Ecuador.

POSTULANTE 1:

Nombres: Henry Sebastián

Apellidos: Naula Saquina

Cédula de Ciudadanía: 1850601194

E-MAIL: henry.naula1194@utc.edu.ec

Estudios Realizados

Nivel secundario: Unidad Educativa “Jorge Álvarez”

POSTULANTE 2

Nombres: Darwin Stalin

Apellidos: Oscurio Ordoñez

Cédula de Ciudadanía: 1105536096

E-MAIL: darwin.oscurio6@utc.edu.ec

Estudios Realizados

Nivel secundario: Unidad Educativa Fiscomisional “Santa Teresita”

Área de Conocimiento:

07 Ingeniería, Industria y Construcción / 071 Ingeniería y Profesiones Afines / 0713 Electricidad y Energía.

Línea de investigación:

Energías Alternativas y Renovables, Eficiencia Energética y Protección Ambiental.

Sublíneas de investigación de la Carrera:

Explotación y Diseño en Sistemas Eléctricos de Potencia.

2. INTRODUCCIÓN

Actualmente el pronóstico de la demanda eléctrica es una labor que involucra gran responsabilidad y dificultad, debido a que tras de ella conlleva implicaciones relevantes para los Operadores del Sistema y Agentes del Sector Eléctrico, es de esta forma que, bajo este ámbito, el pronóstico de la demanda eléctrica debe reducir cada una de las incertidumbres, o sea que debería existir compatibilidad entre la calidad del servicio y la asignación de los recursos. En este sentido, el pronóstico de la demanda de energía eléctrica a corto plazo es una funcionalidad sustancial para una confiable y económica operación del sistema de potencia ecuatoriano.

El pronóstico de la demanda de energía eléctrica en el corto plazo comprende un intervalo de 24 horas y es de fundamental trascendencia para diferentes procesos hechos por el Centro Nacional de Control de Energía (CENACE) como, por ejemplo: el despacho económico y la programación de transferencia de energía y el control en tiempo real.

El precio de operación del sistema eléctrico de potencia ecuatoriano se ve perjudicado por componentes, como el error en la predicción de la demanda eléctrica debido a que, sin una idónea representación de las necesidades futuras de generación de energía eléctrica, los inconvenientes por exceso de capacidad o insuficiencia de capacidad, tienen la posibilidad de tener precios altos para el sistema. Gracias a esto nace la necesidad de buscar nuevos procedimientos que permitan obtener predicciones de demanda de eléctrica con niveles de error mínimos con relación a los niveles reales.

2.1. PROBLEMA DE INVESTIGACIÓN

2.1.1. Situación Problémica

Los mercados eléctricos se han desplazado hacia modelos desregulados, creando la necesidad de modelos de previsión de la demanda más precisos, al tener predicciones de demanda de

energía eléctrica erróneas, existe el riesgo de tener una subestimación o sobreestimación de la demanda causando problemas operativos.

Las redes neuronales como modelos de aproximación de funciones, se han aplicado ampliamente en el pronóstico de la demanda de energía eléctrica generando resultados satisfactorios en la aplicación. Las redes neuronales artificiales no presentan restricciones en cuanto a la dimensión de capas y neuronas utilizadas, la selección de la red más óptima es realizada en base a prueba y error, finalmente se seleccionará el caso más óptimo para pronosticar la demanda de energía a corto plazo.

Al no predecir la demanda eléctrica de forma adecuada produce pérdidas económicas en las empresas distribuidoras debido a que se tendrá que adquirir o producir electricidad a mayores costos, con las correspondientes consecuencias técnicas (desconexión de la carga) generando que pierda confiabilidad el sistema de distribución eléctrico.

2.1.2. Formulación del problema:

¿El estudio de las redes neuronales artificiales ayudará para la predicción de la demanda de energía eléctrica a corto plazo?

2.2. OBJETO Y CAMPO DE ACCIÓN

2.2.1. Objeto de Investigación

Alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo

2.2.2. Campo de acción

330000 ciencias Tecnológicas / 3306 Ingeniería y Tecnología Eléctricas / 3306.09 Transmisión y Distribución.

2.3. BENEFICIARIOS DEL PROYECTO

2.3.1. Beneficiarios directos

Los beneficiarios directos de este proyecto de investigación son las empresas distribuidoras de energía eléctrica y los alumnos de la carrera de Ingeniería Eléctrica de la Universidad Técnica de Cotopaxi ya que ayudará a tener una mejor comprensión acerca de la proyección de la demanda eléctrica a corto plazo mediante la utilización de redes neuronales.

2.3.2. Beneficiarios indirectos

Los beneficiarios indirectos son todos los usuarios, que se introduzcan en el análisis de algoritmos para la proyección de la demanda de energía eléctrica.

2.4. JUSTIFICACIÓN

La predicción de la demanda eléctrica es una de las funcionalidades más relevantes para realizar la planificación en los sistemas eléctricos de potencia, con ello se realiza la expansión de redes eléctricas, se ejecuta la construcción de centrales generadoras, subestaciones eléctricas y es una parte integral de la planeación para las empresas de diversa índole; que van desde la generación, transmisión y distribución hasta el consumo.

En la actualidad, las empresas distribuidoras se encargan de realizar el análisis de la predicción de la demanda eléctrica, siendo de gran importancia para los sistemas existentes como para el diseño de nuevos sistemas, garantizando un estado de operación adecuado. Dentro de dicho estudio se analiza el comportamiento de los sistemas de distribución frente a cargas no lineales, en este análisis los aspectos más importantes son identificar el incremento de una carga futura en un sistema dado, para un periodo de tiempo futuro específico.

Debido al inconveniente que existe en la predicción de la demanda eléctrica se necesita llevar a cabo actividades para resolver o bien, para disminuir problemas de pérdidas de dinero en gran magnitud para las empresas suministradoras, tanto así por gastos de generación y operación. Tomando en cuenta a estas razones se sugiere realizar el estudio de las redes neuronales artificiales, así como la utilización de una herramienta de programación accesible como lo es el software MATLAB, obligado a desarrollar un algoritmo, para la resolución de la predicción de la demanda eléctrica a corto plazo en sistemas de distribución, utilizando datos a partir de la demanda histórica que nos proporcionara un acercamiento al sistema real.

2.5. HIPÓTESIS

El desarrollo de una red neuronal en Matlab, permitirá predecir la demanda eléctrica a corto plazo en el alimentador Santa Rosa de Pichul – San Gerardo.

2.6. OBJETIVOS

2.6.1. Objetivo General:

Desarrollar una herramienta computacional para la predicción de la demanda de energía eléctrica a corto plazo basado en redes neuronales artificiales mediante el programa computacional Matlab.

2.6.2. Objetivos Específicos:

- Elaborar el estado del arte de la predicción de la demanda de energía eléctrica utilizando redes neuronales a corto plazo.
- Desarrollar la estructura de redes neuronales artificiales para la predicción de la demanda.
- Realizar una interfaz gráfica para la predicción de la demanda de energía eléctrica a corto plazo en el Alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo.

2.7. SISTEMA DE TAREAS

Tabla 2.1: Sistema de tareas en relación a los objetivos planteados.

OBJETIVOS ESPECÍFICOS	ACTIVIDADES (TAREAS)	RESULTADOS DE LAS ACTIVIDADES	DESCRIPCIÓN DE LA ACTIVIDAD (TÉCNICAS E INSTRUMENTOS).
Elaborar el estado del arte de la predicción de la demanda de energía eléctrica utilizando redes neuronales a corto plazo.	<ul style="list-style-type: none"> • Búsqueda de información en obras colectivas y medios digitales concerniente a demanda de energía eléctrica. • Indagación de los conocimientos básicos de la demanda eléctrica a corto plazo. • Análisis de artículos científicos dedicados al estudio de predicción de la demanda eléctrica utilizando redes neuronales. 	<ul style="list-style-type: none"> • Fundamentación teórica y comparación de los distintos métodos de predicción de la demanda de energía eléctrica. • Fundamentación teórica técnica para el desarrollo de la programación en Matlab. • Metodología para el correcto diseño de la herramienta computacional de predicción de la demanda eléctrica. 	<ul style="list-style-type: none"> • Libros • Tesis • Artículos científicos. • Trabajos académicos • Revistas Científicas • Normativas • Papers • Informes técnicos

<p>Desarrollar la estructura de redes neuronales artificiales para la predicción de la demanda.</p>	<ul style="list-style-type: none"> • Estudio de aspectos funcionales del programa computacional Matlab referentes a redes neuronales artificiales. • Recopilación de datos históricos de demanda de energía eléctrica. • Análisis y comprensión de la base de datos. • Preprocesamiento de la base de datos. 	<ul style="list-style-type: none"> • Red neuronal para la aplicación específica • Graficas de datos históricos realizadas en Matlab. • Graficas de predicción de la demanda para el periodo especificado realizadas en Matlab. • Tablas de resultados de las predicciones de la demanda futura en formato Excel. 	<ul style="list-style-type: none"> • Matlab • Redes Neuronales
<p>Realizar una interfaz gráfica para la predicción de la demanda de energía eléctrica a corto plazo en el Alimentador # 0202 - Santa Rosa Pichul - 11 de noviembre.</p>	<ul style="list-style-type: none"> • Programación de la red neuronal en lenguaje de programación Matlab. • Programación de una interfaz en el programa Matlab de predicción de la demanda eléctrica a corto plazo. • Análisis de los resultados obtenidos en la aplicación 	<ul style="list-style-type: none"> • Interfaz gráfica amigable de la aplicación. • Predicción de la demanda de energía eléctrica a corto plazo. • Factibilidad económica – financiera. 	<ul style="list-style-type: none"> • Datos históricos de la demanda eléctrica a corto plazo.

3. FUNDAMENTACIÓN CIENTÍFICO TÉCNICA

3.1. ANTECEDENTES DE LA INVESTIGACIÓN

La predicción de la demanda de energía tiene como propósito mejorar la confiabilidad, tomar decisiones y sobre todo la planificación en el sistema eléctrico de potencia, entre otras, el comportamiento de la energía eléctrica es un problema de mucho interés a resolver en ingeniería debido a que esta no tiene una característica lineal. El método más adecuado para resolver este problema no está claramente definido, sin embargo, el señor M. Ortiz (2015) a través de su trabajo investigativo “Pronóstico de la Demanda Eléctrica Residencial Basado en el Modelo de Regresión Adaptativa Multivariante Spline (MARS)” realiza mediante la técnica de Regresión Adaptativa Multivariante Spline (MARS), que es un modelo de regresión no paramétrica y su principal objetivo es predecir los valores de una variable dependiente o resultado, de un conjunto de variables independientes o predictoras [1].

No obstante A. Manobanda (2020) a través de su trabajo investigativo “Predicción de la Demanda de Energía Eléctrica en la Producción de Petróleo de los Campos de Petroamazonas EP Utilizando Redes Neuronales Artificiales” aplica técnicas muy generales, para este caso, se emplea una Red Neuronal Artificial (RNA) tipo perceptrón multicapa con alimentación hacia

adelante, y aprendizaje supervisado, de igual forma se encontró que una metodología basada en RNA mejora los resultados de predicción comparado con la metodología de regresión lineal simple, debido a que estas pueden replicar mejor un comportamiento no lineal [2].

También existen otros métodos utilizados para la predicción de la demanda de energía eléctrica, como se fundamenta en la aplicación de la serie de tiempo desarrollado inicialmente mediante herramientas de hoja de cálculo, y uso de software de estadística. El Catedrático, L. Gonzales (2016) realiza un informe profesional denominado “Proyección de la Demanda de Energía Eléctrica a Corto Plazo, Mediante Redes Neuronales Artificiales” donde se aborda el uso de herramientas mejoradas para el tratamiento de las series de tiempo, mediante la aplicación de inteligencia artificial. Con el fin de mejorar y facilitar el trabajo de planificación del sistema eléctrico de distribución y se incentiva el uso de las redes neuronales artificiales de la herramienta MATLAB para predecir la demanda de energía eléctrica [3].

3.2. MARCO TEÓRICO

Para el desarrollo de la presente investigación, se brinda una solución practica al problema de la predicción de la demanda, es importante conocer diferentes conceptos de la demanda eléctrica y redes neuronales artificiales. A continuación, se explican sus definiciones principales con el fin de comprender sus características principales y predecir correctamente la demanda eléctrica a corto plazo mediante las redes neuronales.

Con el presente documento se redacta a detalle la capacidad de las Redes Neuronales Artificiales como instrumento fundamental de modelización, poniendo de relieve la superioridad mostrada por las mismas en el modelado de los fenómenos no-lineales. Por consiguiente, programaremos una red neuronal implementado en MATLAB, el mismo que permitirá predecir la evolución de la demanda de energía eléctrica a corto plazo.

3.2.1. Subestación San Rafael – Alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo.

La Subestación San Rafael se encuentra ubicada en la provincia de Cotopaxi, Cantón Latacunga, sector urbanización las Fuentes, sur este de Latacunga, sus límites geográficos son: Al norte la calle Río Pumacunchi, al sur conjuntos habitacionales, al oeste Avenida Río Cutuchi y al este la Calle Río Tigre. La llegada desde la subestación Mulaló a 69kV es por el oeste y la salida de los alimentadores lo realiza por el este.

En la figura 3.2 y 3.3, se ilustra el alimentador Santa Rosa de Pichul - San Gerardo, con base de datos de equipos, red y proyectos, utilizando el software CYME, Google Mapper y finalizando con la ubicación geográfica en Google Earth.



Figura 3.2: Alimentador Santa Rosa de Pichul - San Gerardo (CYME)



Figura 3.3: Ubicación geográfica del alimentador Santa Rosa de Pichul - San Gerardo

En la tabla 3.1, se detalla el número total de clientes que son 784315, los cuales se subdividen en sector residencial, comercial e industrial.

Tabla 3.1: Tipo de carga en el alimentador Santa Rosa de Pichul - San Gerardo

TIPO DE CARGA EN EL ALIMENTADOR		
Residencial		
Número de clientes	Zona Rural	Zona Urbana
	506910	0
Comercial		
Número de clientes	Zona Rural	Zona Urbana
	101867	0
Industrial		
Número de clientes	Sin demanda	Con demanda
	175538	0

El conductor es de cobre, tipo de construcción copperweld calibre 66,4 kcmil con un diámetro de 0,29173 pulgadas, su capacidad nominal es de 230 A, con un límite de carga de 480 A. El hilo de guarda es de cobre, su tipo de construcción es de un solo alambre calibre 41,738 kcmil, con un diámetro de 0,84 pulgadas, los datos nominales de tensión son de 7,2 kV, con un límite de carga de 100 A.

Los transformadores conectados al alimentador son 174 de tipo monofásico y 69 trifásicos, para más detalle en el Anexo A se presenta la tabla de la descripción de los tipos de transformadores que se encuentran en este sector con su respectivo código y descripción.

3.2.2. Demanda eléctrica en Ecuador

3.2.2.1. Demanda eléctrica

Es la cantidad de potencia que un consumidor utiliza en cualquier momento (variable en el tiempo). 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 [4]. 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 [5].




Figura 3.4: Curva típica de demanda diaria ($T_n = 24$ horas)

En la figura 3.5, se puede observar la curva de demanda eléctrica de la primera semana del mes de abril del año 2020 del Alimentador PRI12 – Santa Rosa Pichul – San Gerardo, con intervalos de tiempo de horas para cada día del mes antes mencionado, en este caso su forma y comportamiento depende de las variables que afectan la demanda a corto plazo. Se puede apreciar que el comportamiento de la demanda eléctrica tiende a crecer mientras transcurren las horas de la tarde y noche, con la excepción de las horas a la madrugada el cual decreció existiendo menos consumo eléctrico, con la excepción del día 4 y 5, tomando en cuenta un evento particular que paro la producción o en su cuestión un apagón general del alimentador.

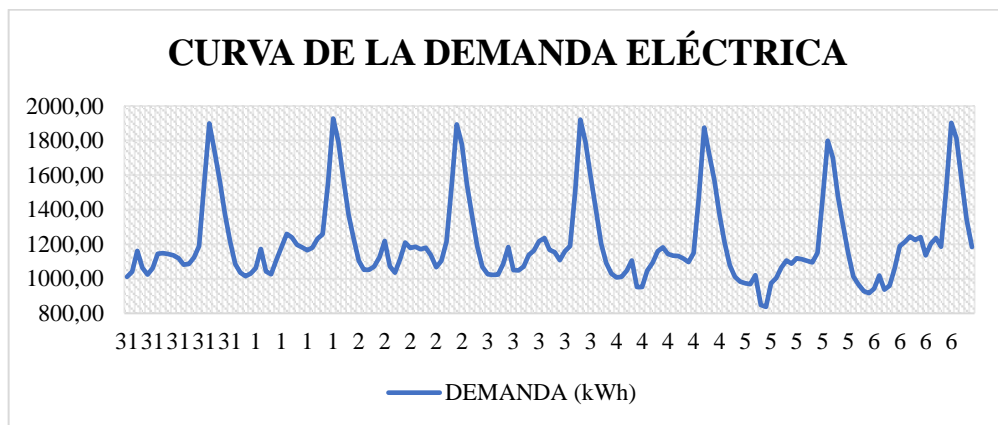


Figura 3.5: Curva de la demanda eléctrica

3.2.2.2. Tipos de demanda eléctrica

- **Consumidor Residencial**

Un consumidor residencial es aquella persona natural o jurídica, pública o privada que utiliza el servicio público de energía eléctrica, exclusivamente, al uso doméstico. Se incluye a los consumidores de escasos recursos económicos y bajos consumos regulados que tienen integrada a su residencia una pequeña actividad comercial o residencial artesanal: para lo cual, es

responsabilidad de la distribuidora evaluar las características de consumo de energía eléctrica, y recomendar la separación de los respectivos circuitos con su sistema de medición independiente y a la tarifa correspondiente [6]. Las cargas residenciales se caracterizan por ser de baja tensión, poca potencia y, en la mayoría de los casos, monofásicas [7].

- **Consumidor Comercial**

Es la persona natural o jurídica, pública o privada, que utiliza la energía eléctrica para fines de negocio, actividades profesionales o cualquier otra actividad con fines de lucro [6]. Las cargas comerciales normalmente son trifásicas y de potencias medianas [7].

- **Consumidor Industrial**

Un consumidor industrial es aquella persona natural o jurídica, pública o privada, que utiliza la energía eléctrica para la elaboración o transformación de productos. También se considera dentro de esta definición a los agroindustriales, que transformen productos de la agricultura, ganadería, riqueza forestal y pesca [6]. La carga industrial en general puede tener grandes potencias y contratar el servicio en altas tensiones, como 115 KV o más [7].

3.2.3. Curva de Demanda

La curva de demanda eléctrica es variante en el tiempo ya que depende de diversas variables, como: factores climáticos, factores sociales, factores económicos, hábitos de los usuarios, entre otros [8]. Dependiendo de la duración del intervalo de tiempo se pueden diferenciar los diferentes tipos de curvas de demanda, en la figura 3.6, se puede observar la curva de demanda horaria, que se caracteriza por tener intervalos de tiempo de una hora para cada hora del día [9].



Figura 3.6: Curva de demanda horaria.

En la figura 3.7 y figura 3.8 se puede apreciar dos curvas de demanda diaria típicas para un día laborable y fines de semana, donde se tiene que tener en cuenta que la categoría que marca el comportamiento de la curva de la demanda eléctrica, pudiendo apreciar que la demanda máxima se produce entre las 19:00 y 20:00 horas y la demanda mínima entre la 01:00 y 05:00 horas.

En el sector residencial, la diferencia entre la demanda máxima y promedio en la curva horaria son grandes, generando esto factores de carga muy bajos, en cambio, para el sector industrial estas diferencias no son tan pronunciadas, es por ello que el factor de carga tiene valores cercanos a uno [10].




Figura 3.7: Curva de la demanda eléctrica de los días laborables

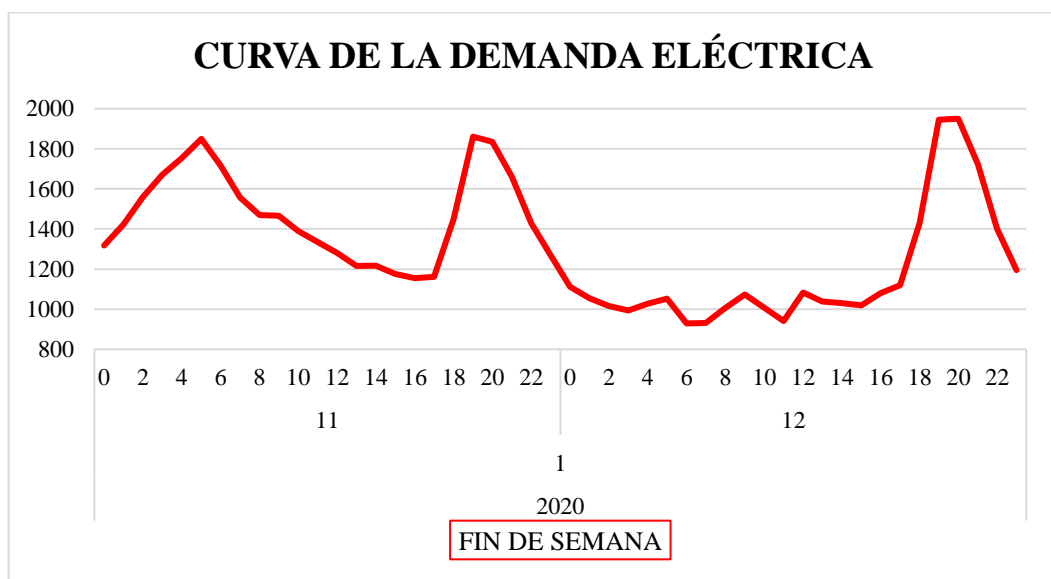


Figura 3.8: Curva de la demanda eléctrica de los fines de semana.

3.2.3.1. Curvas de carga diaria.

Estas curvas se dibujan para el día pico de cada año del período estadístico seleccionado, las curvas de carga diaria están formadas por los picos obtenidos en intervalos de una hora para cada hora del día, dan una indicación de las características de la carga en el sistema y de la forma en que se combinan para producir el pico, proporcionan mayores detalles sobre la forma en que han venido variando durante el período histórico y constituye una base para determinar las tendencias predominantes de las cargas del sistema [5].

En la figura 3.9, se muestran las curvas de carga diarias típicas en el Ecuador para carga residencial, comercial, industrial y alumbrado público que muestran el porcentaje pico contra el tiempo y permite observar el comportamiento de cada una de ellas.

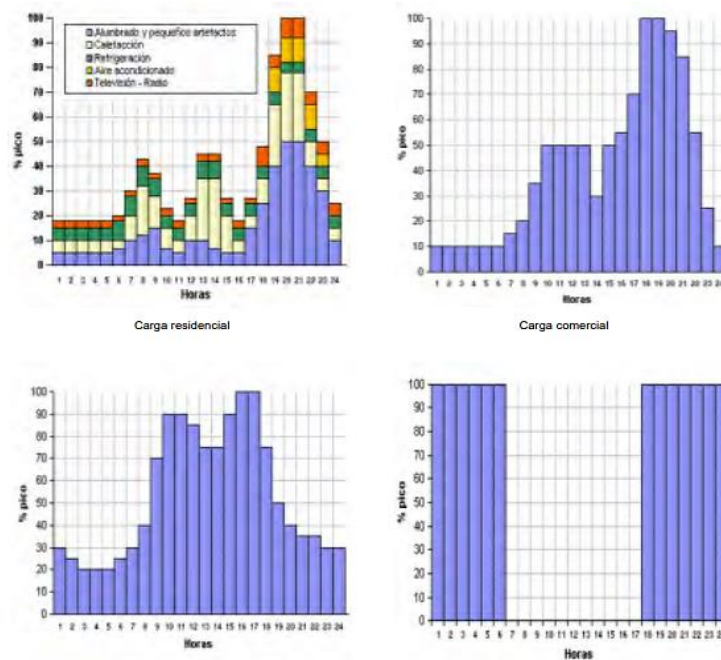


Figura 3.9: Curva de carga diaria típicas [5].

3.2.3.2. Curvas de carga anual.

Estas curvas se deben dibujar en lo posible para los 4 años del período estadístico como se muestra en la figura 3.10 y muestran la forma como se está incrementando la carga durante dicho periodo y ayuda en la deducción de la tasa de crecimiento de la demanda. Las curvas de carga anual están formadas por los valores de la demanda a la hora pico en cada mes, permiten una visualización de los crecimientos y variaciones de los picos mensuales y anuales [5].




Figura 3.10: Curvas de carga anual [5]

3.2.3.3. Demanda Máxima o Carga Máxima

Se define a la demanda máxima como la demanda cuyo valor indicado es el mayor de todas las demandas durante un tiempo específico. Se caracteriza especificando el intervalo de demanda, el periodo y las unidades [11].

3.2.3.4. Carga Instalada

Hace referencia a la suma de potencias nominales, tanto de aparatos y equipos de consumo los cuales se encuentran conectados a un sistema y se expresa en kVA, MVA, kW o MW [12].

3.2.3.5. Capacidad Instalada

Corresponde a la suma de las potencias nominales de los equipos (transformadores, generadores), instalados a líneas que suministran la potencia eléctrica a las cargas o servicios conectados. Es llamada también capacidad nominal del sistema [5].

3.2.4. Predicción de la demanda eléctrica

El problema principal es determinar los valores futuros de la demanda eléctrica, entregando la base de datos históricos de energía eléctrica y algunas entradas impensadas [13]. Las entradas impensadas deben ser adecuadas para la escala de tiempo de interés a determinar, por ejemplo:

- a. **Cada hora:** entradas meteorológicas (temperatura, humedad, velocidad y dirección del viento, nubosidad, etc.), eventos especiales (festivos, eventos deportivos, etc.)
- b. **Semanalmente:** Entradas meteorológicas (grados día de calefacción, grados día 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.).

Una predicción de demanda eléctrica precisa es primordial para que las empresas eléctricas determinen la dinámica y características del trabajo futuro que es primordial en el sistema eléctrico. [14]. La exactitud es el criterio de más grande trascendencia al instante de elegir un modelo de pronóstico, la exactitud refleja la proximidad de los valores pronosticados y los valores reales. El conjunto de actividades involucradas en un Sistema Eléctrico se puede sintetizar en la figura 3.11.




Figura 3.11: Contexto general de actividades en los Sistemas de Energía Eléctrica [15]

- El ambiente del Sistema Eléctrico se refiere a los subsistemas arbitrarios que son los de generación, transmisión, distribución y los consumidores.
- El ambiente del alcance se enlaza con el objeto de la acción a desarrollar, que puede suplir exigencias físicas, técnicas, económicas, medioambientales, entre otros.
- El ambiente de tiempo se relaciona con el lapso que abarca la acción a desarrollar el cual se divide en aumento y en operación.

El consumo de energía, la disponibilidad de recursos fósiles, los aportes de ríos, etc. Son de vital importancia en la Planificación del Crecimiento y en la Programación de la Operación [15].

3.2.4.1. Importancia del pronóstico de demanda de energía eléctrica

El objetivo principal del sistema eléctrico de potencia es suministrar el servicio de energía de manera continua, segura y confiable, por esta razón debe adaptarse continuamente a la demanda. Sin embargo, los sistemas eléctricos no son sistemas adaptativos, y para suplir dicha demanda requiere contar con un estimado del valor demandado por dicho sistema para poder

realizar las modificaciones y cumplir con las exigencias del servicio. Un pronóstico más acertado reduce el riesgo de realizar redespachos donde se deban usar unidades de generación más costosas o, por el contrario, se deba prescindir de generaciones programadas anteriormente.

3.2.4.2. La planificación estratégica y su relación con la predicción de la demanda eléctrica.

La planificación estratégica involucra tomar decisiones por adelantado sobre acontecimientos esperados en el futuro, por el cual se necesita tener conocimientos profundos sobre la situación actual, de las propensiones de los parámetros eléctricos para los próximos años en función de la base de datos del pasado, con esto se desarrolla lo que se tiene por objetivo de anticipar escenarios futuros que permitan tomar decisiones correctas [11].

La planificación energética es fundamental en cualquiera sistema eléctrico, esta aporta conjeturas sobre la energía eléctrica y los recursos obligatorios para satisfacer esta demanda eléctrica, de igual forma estudia el progreso de las condiciones de mercado para garantizar el suministro y los criterios de protección ambiental [16]. La planificación estratégica se considera que debe partir con el establecimiento de metas de largo plazo y alcance, viables y trascendentes que servirán de disposición permanente a todas las acciones que desarrolle la empresa eléctrica [11].

Los objetivos de la planificación energética son:

- la reducción de costes,
- la eficiencia energética,
- la garantía de suministro eléctrico,
- la diversidad de las fuentes utilizadas,
- el fomento de las energías renovables.

La demanda eléctrica es el principal factor que influye en este tipo de decisiones, siendo necesario conocer cómo es su comportamiento en el futuro para que en base a esta predicción se tome las decisiones respectivas para cumplir con los objetivos establecidos. En este argumento, una predicción de escenarios energéticos de gran precisión permite que la inseguridad disminuya notoriamente, donde otro aspecto que toma como base la predicción de la demanda eléctrica es la planificación del despacho, así una vez encontrada la demanda futura solicitada se puede realizar estudios para encontrar la mejor combinación de operación entre las diferentes unidades disponibles tanto hidroeléctricas, térmicas, renovables, además de esto

se puede proyectar la salida de unidades para realizar su respectivo mantenimiento preventivo, y de esta manera obtener mejoras en la eficiencia de los mismos y evitar que el tiempo de vida de los equipos se reduzca de gran manera [11].

3.2.4.3. Horizontes para la predicción de la demanda eléctrica

La predicción de la demanda de energía eléctrica realiza un papel principal en procesos de planificación y operación del sistema eléctrico, consecuente a esto atrae una gran cantidad de actividades de investigación realizadas por investigadores del mundo académico, de igual forma las empresas eléctricas [17].

Esto se atribuye al hecho de que una mejor previsión de energía implica alcanzar planes exactos sin una planificación excesiva o insuficiente. Se ha identificado 4 horizontes de tiempo muy corto plazo, corto plazo, mediano plazo y largo plazo, de los cuales se detallan a continuación:

a. Predicción a corto plazo

El pronóstico de carga a corto plazo (STLF) se centra en predecir las cargas eléctricas horarias y la demanda de energía para períodos de hasta una semana antes, teniendo en cuenta que la demanda de carga es muy diversa en el día a día, mediante todo lo antes mencionado el STLF es un elemento muy decisivo en el proceso de planificación operativa del sistema de energía que afecta al desempeño de muchas funciones.

Estas funciones incluyen los estudios de flujo de carga, análisis de seguridad y contingencias, despacho económico, compromiso unitario, coordinación hidrotérmica, plan de mantenimiento preventivo de los generadores, evaluación de transacciones, evaluación de confiabilidad del sistema eléctrico y comercialización de energía en sistemas interconectados [17]. Se deben tomar en cuenta los cambios imprevistos en la demanda del sistema o las interrupciones del sistema que representan otro tipo de incertidumbre asociada con el proceso de pronóstico de carga.

Todo lo antes mencionado se suma a la complejidad de obtener un STLF preciso para cargas eléctricas y se debe forzar para enfocarse en los diferentes factores involucrados en este proceso y en el desarrollo continuo de nuevos métodos para minimizar los errores encontrados durante todo el procedimiento [17].

b. Predicción a medio plazo

El pronóstico de carga a medio plazo (MTLF) es adecuado para empresas eléctricas para la programación de mantenimiento, el período de pronóstico es de varias semanas a 12 meses por delante, en este tipo de pronóstico depende principalmente de factores de crecimiento, es decir, acontecimientos principales, adición de nuevas cargas, patrones de demanda de grandes instalaciones y requisitos de mantenimiento de grandes consumidores [17].

c. Predicción a largo plazo

El pronóstico de carga a largo plazo (LTLF) se utiliza para planificar la expansión del sistema eléctrico, el período de estudio de esta predicción es de 1 año a 15-20 años, lo que se tiene como resultado de este pronóstico suele ser la carga máxima y el requerimiento anual de energía del sistema, es decir, la carga máxima y el requerimiento de energía para los próximos años del período de estudio se determinan mediante el método de pronóstico [17].

3.2.4.4. Factores que influyen en la predicción de la demanda eléctrica

Existen factores que perturban el comportamiento de la demanda de energía eléctrica y su grado de influencia será diferente dependiendo del horizonte de tiempo de la predicción y del tipo de demanda estudiada [18]. En la figura 3.12, se resume los factores que afectan al comportamiento de la demanda eléctrica.

CORTO PLAZO
<ul style="list-style-type: none"> • Tiempo Hora del día, día de la semana • Tipo de día Laboral, feriado • Factores climáticos Temperatura, Humedad, Velocidad del viento

Figura 3.12: Factores que influyen en el comportamiento de la demanda eléctrica [18].

A continuación, se detalla los factores más influyentes para el horizonte de tiempo a corto plazo:

a. Factores considerados en los periodos de corto plazo

La temporalidad es el factor más importante para realizar predicciones a corto plazo, debido a que el comportamiento de la demanda es diferente dependiendo de la hora del día y del día de

la semana a pronosticar, en el sector residencial la demanda eléctrica es mucho mayor en horas cercanas a las 19:00 horas comparadas a las 3:00 de la mañana del mismo día [18].

Del mismo modo se conoce que la demanda es mayor en días laborables comparado con fines de semana, en este punto de análisis el tipo de día juega un papel importante esto implica distinguir entre día: feriado, laborable, evento deportivo, entre otros. La demanda eléctrica es mayor en un día laborable comparado con los días de feriado.

Los factores climáticos como la temperatura, humedad o la velocidad del viento inciden en el comportamiento de la demanda eléctrica, este efecto es evidenciado cuando existen altas temperaturas generalmente la demanda es mayor a un día con una temperatura normal, debido al funcionamiento de equipos como aires acondicionados que permiten controlar dichas temperaturas, de igual forma sucede de tal manera si las temperaturas son muy bajas entran a funcionar los equipos de calefacción [18].

b. Factores considerados en los periodos de mediano y largo plazo

El producto interno bruto (PIB) refleja el nivel socioeconómico de la población, que a su vez incide en el consumo energético, es por tanto un factor relevante para las predicciones de la demanda en mediano y largo plazo [19]. El crecimiento demográfico influye en el comportamiento de la demanda eléctrica, debido a que un aumento en la población incrementa el número de suscriptores y con esto el incremento de la demanda eléctrica [20].

3.2.5. Métodos para la predicción de la demanda eléctrica

Los métodos se pueden clasificar acorde a diferentes criterios, se dividen en métodos cualitativos donde la predicción se da en base de la opinión de los expertos que tengan buenos conocimientos sobre la variable que se pretende predecir y los métodos cuantitativos, el objetivo principal consiste en extraer toda la información posible contenida en los datos históricos [21]. A su vez, los métodos cuantitativos se han dividido en dos subgrupos grandes denominados métodos estadísticos y métodos de inteligencia artificial [22].

3.2.6. Procedimiento para realizar la predicción de la demanda eléctrica mediante redes neuronales artificiales.

El procedimiento para predecir la demanda eléctrica mediante redes neuronales artificiales se presenta en la figura 3.13.

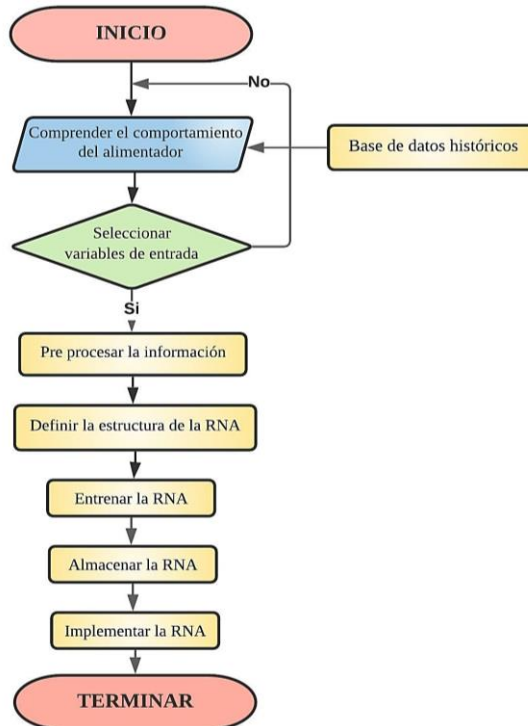


Figura 3.13: Procedimiento para la predicción de la demanda utilizando redes neuronales artificiales.

A continuación, se resumen los 8 pasos básicos para la predicción de la demanda eléctrica utilizando la metodología de redes neuronales artificiales [22].

- **Paso 1.-** Comprender el comportamiento de la demanda en el alimentador, está relacionado a buscar toda la información que permita conocer de mejor manera la operación del alimentador (curvas de la demanda eléctrica, semanal fin de semana y diaria). Como resultado final de este paso permitirá entender la base de datos adquirida.
- **Paso 2.-** Seleccionar variables de entrada de las bases de datos acorde a la aplicación. En base al conocimiento adquirido en el paso 1, es necesario escoger las variables que más influyan en el comportamiento de la demanda de energía eléctrica.
- **Paso 3.-** Validación y preprocesamiento de los datos de entrada. La red neuronal artificial aprende y predice en función de los datos históricos de las variables consideradas, si en estas bases de datos existen datos erróneos los resultados de las predicciones no serán las más acertadas, es por ello que previo al ingreso de las bases históricas de las variables al modelo de la red neuronal artificial es necesario eliminar la mayoría de datos erróneos que pudiesen existir.
- **Paso 4.-** Definir la RNA (número de neuronas de entrada, número de capas ocultas, número de neuronas en las capas ocultas, número de neuronas de salida, número de interconexiones entre las diferentes neuronas, funciones de activación). El paso más

importante a llevar a cabo, depende muchas veces de las experiencias del predictor, se hace necesario ir comparando entre diferentes estructuras de red neuronal artificial para encontrar el que mejor se ajuste a la aplicación

- **Paso 5.-** Entrenamiento de la RNA (criterios de aprendizaje, número de iteraciones) con un conjunto de datos de entrenamiento. En este paso se asignarán los valores finales, tanto el número de retrasos y el algoritmo de entrenamiento, minimizando el valor del criterio de aprendizaje seleccionado.
- **Paso 6.-** Verificación de la red neuronal artificial, con un conjunto de datos de prueba. La verificación de la funcionalidad de la red neuronal artificial se la realiza al predecir valores de la demanda eléctrica y compararlas con datos reales.
- **Paso 7.-** Almacenamiento de los parámetros de la red neuronal artificial una vez verificada. Es necesario almacenar la red neuronal artificial para su uso en el futuro, sin tener la necesidad de repetir los dos últimos pasos mencionados al menos que los responsables lo crean necesario.
- **Paso 8.-** Implementación de la red neuronal artificial para la predicción de la demanda de energía eléctrica futura mediante la programación del algoritmo para proporcionar resultados.

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




Figura 3.14: Métodos de pronóstico de demanda de Energía Eléctrica [23].

3.2.7.1. Métodos de Inteligencia Artificial

La inteligencia artificial es el arte de desarrollar máquinas con capacidad para realizar tareas que por el momento los humanos hacen mejor [24]. Entonces 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 [11]. En la figura 3.15, se resume la clasificación de los diferentes métodos de inteligencia artificial encontrados para la predicción de la demanda eléctrica.




Figura 3.15: Clasificación de los métodos de inteligencia artificial para predicción de la demanda eléctrica [11].

Para desarrollar inteligencia artificial la mayoría de estos algoritmos están inspirados en procesos biológicos con los que cuenta el ser humano, las redes neuronales artificiales como su nombre lo indica están inspiradas en el funcionamiento de las neuronas biológicas de los seres humanos [25].

3.2.8. Redes neuronales artificiales

Las redes neuronales artificiales (RNA, por sus siglas en inglés Artificial Neural Networks) son modelos inspirados en el sistema nervioso del ser humano, dicho sistema consiste, en la interconexión de un grupo de neuronas biológicas que permiten procesar la información y obtener la salida deseada acorde a las necesidades del ser humano. Se calcula que en cada cerebro de un ser humano existen en promedio alrededor de 100 billones de neuronas biológicas, y más de 10.000 interconexiones entre neuronas [26].

Las redes neuronales, permiten aproximar funciones no lineales, esto permite modelar fenómenos complejos donde las variables no están correlacionadas. Así con aplicaciones de Redes Neuronales Artificiales se han obtenido atractivos resultados en medicina, economía, comunicaciones y otras áreas del conocimiento, siendo una de sus características la eliminación de hipótesis de reducción de linealidad que ha dominado el análisis de diferentes problemas a

lo largo del tiempo. Si bien, la hipótesis de simplificación, permite desarrollar formulaciones de modelos matemáticos para explicar fenómenos de diversa naturaleza; no es posible desechar el modelo lineal básico, que se sustenta justamente en la linealidad de sus ecuaciones [27] [28].

3.2.8.1. Ventajas de las redes neuronales artificiales

Las principales ventajas de las RNA son:

- a. **Aprendizaje Adaptativo.** - Las RNA tienen la capacidad de aprender a realizar las tareas en base al entrenamiento (datos de entrenamiento). Es decir, las RNA pueden cambiar su estructura dependiendo de los datos de entrenamiento [19].
- b. **Autoorganización.** - Las RNA crean su propia organización o representación de la información recibida en la etapa de aprendizaje [29].
- c. **Tolerancia a fallos.** - Las RNA tienen la ventaja de retener las capacidades de la red, cuando existiera alguna destrucción parcial de una red. Sin olvidar que esta toleración será mayor o menor dependiendo de la aplicación en la cual es utilizada la RNA [29].
- d. **Modelación no lineal.** - Las RNA, permiten aproximar funciones no lineales (elimina la hipótesis de reducción de linealidad), esto permite modelar aquellos fenómenos complejos donde las variables no están correlacionadas [29].

Adicionalmente se describen más ventajas de las redes neuronales artificiales (RNA):

- a. Mejor redimiendo en el trato con las funciones no lineales, no requieren formulaciones matemáticas complejas o de correlación cuantitativa entre entradas y salidas.
- b. Modelos sencillos y permiten obtener bajos errores en el pronóstico tanto dentro como fuera de la muestra
- c. El software ofrece funciones de preprocesamiento y post-procesamiento de datos implícitas en las funciones de entrenamiento haciendo innecesario el uso individual.
- d. Reducción de costos operacionales y económicos debido a la disminución del error.
- e. Son una solución sencilla, eficaz y confiable para la predicción de demanda de energía eléctrica con una precisión superior al 95%.

También se detallan las desventajas de las redes neuronales artificiales (RNA):

- a. Los paquetes computacionales en el mercado son limitados en su adaptación al problema, algunos tienen restricción en tamaño de la muestra.
- b. Programación de la red es un tanto tediosa pero muy acertada en sus resultados.

3.2.9. Elementos de una red neuronal

3.2.9.1. Neurona artificial.

Son elementos simples de cálculo que, a partir de un vector de entrada procedente del mundo exterior, y/o a partir del estímulo recibido de otras neuronas proporcionan una respuesta única (salida).

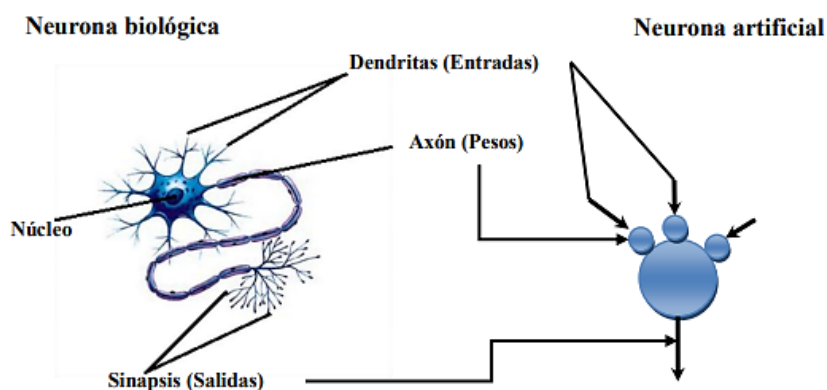


Figura 3.16: Relación entre una neurona biológica y artificial [30].

Las neuronas biológicas son considerados procesadores de información sencillos. Poseen un canal de entrada de información denominado dendrita (ramificaciones), en el cual se recoge la información que llega mediante impulsos eléctricos y las propaga en el interior de la neurona. Esta información llega al órgano de cómputo (soma) donde es procesada generando una respuesta (dependiendo del nivel del impulso eléctrico, la neurona se activará o no) que pasará al canal de salida (axón). El axón envía esta señal a las dendritas de las neuronas adyacentes, esta unión entre axón y dendritas es llamado sinapsis. Las sinapsis son espacios líquidos (concentración de elementos ionizados) donde se ponen en contacto el axón y las dendritas, sin llegar a fusionarse. Debido a la presencia de los elementos ionizantes, este espacio posee propiedades de conductividad que activan o impiden el paso del impulso eléctrico [30].

Las neuronas artificiales se constituyen en estructuras denominadas capas. Una red RNA está compuesta por un conjunto de capas. Por ende, la información se distribuye a lo largo de las sinapsis de la red, dándole al sistema cierta 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 [29].

De manera similar, una RNA esta echa de simples conexiones entre elementos denominados neuro nodos, celdas, unidad o elemento de procesamiento. Las cuales están arregladas en una estructura para formar una red que permite ejecutar y distribuir cálculos. Al igual que una red neuronal biológica, la RNA es capaz de aprender, reconocer patrones en los datos y adaptarse a los cambios, siendo esta una de las principales razones que ha llevado a su empleo en la modelación de datos [31]. Las RNA imitan la estructura del sistema neuronal biológico. En la figura 3.17 se aprecia la equivalencia entre la estructura de las neuronas biológicas y las neuronas artificiales.




Figura 3.17: Estructura de una neurona biológica y una neurona artificial mediante un modelo matemático [32].

Las neuronas artificiales poseen un cierto número de entradas (externas o salidas de neuronas anteriores). Cada entrada tiene un peso asignado que representa el grado de afectación de la entrada a la neurona (sinapsis). La neurona procesa la información sumando las entradas y valor umbral (siempre es recomendable tener un valor umbral para mejorar el procesamiento de la señal), para posterior a eso 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 [32].

3.2.9.2. Unidad de proceso.

La distribución de neuronas dentro de la red se realiza formando niveles o capas, con un número determinado de dichas neuronas en cada una de ellas [27] [28]. A partir de su ubicación dentro de la red, se pueden distinguir tres tipos de capas:

- Capa de entrada.** Es la capa que recibe directamente la información proveniente de las fuentes externas de la red.

- b. **Capa Oculta.** Son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.
- c. **Capa de salida.** En esta capa se transfiere la información de la red hacia el exterior.

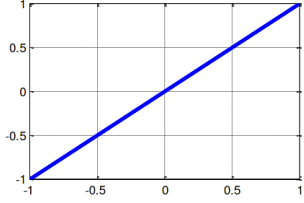

3.2.9.3. Conexiones y pesos sinápticos.

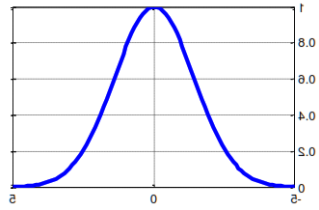
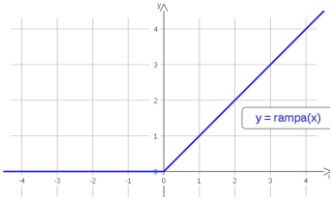
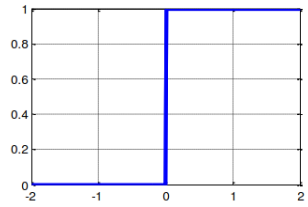
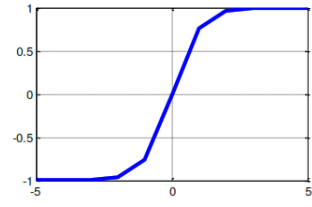
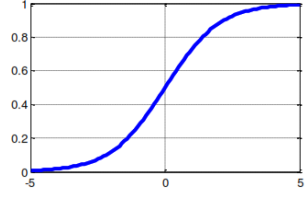
Representan el grado de comunicación entre las diferentes neuronas. Los pesos sinápticos pueden tomar valores negativos (inhibidores), positivos (excitadores) o incluso cero (no hay conexión entre las neuronas) [33].

3.2.9.4. Función de activación.

Es la regla que sigue la RNA, para determinar la activación o el estado de una neurona, en función a las entradas que le lleguen a dicha neurona. Estas funciones pueden ser lineales o no lineales [33]. En la tabla 3.2., se resume las diferentes funciones de activación que comúnmente son utilizadas:

Tabla 3.2: Funciones de activación [33].

Función	Ecuación	Gráfica
Lineal	$y(x) = x$	
Lineal a tramos	$y(x) = \begin{cases} -1 & \text{si } x \leq -1 \\ x & \text{si } -1 < x < 1 \\ 1 & \text{si } x \geq 1 \end{cases}$	

Gaussiano	$y(x) = Ae^{-Bx^2}$	
Rampa	$y(x) = \begin{cases} x & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$	
Escalón	$y(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$	
Tangente hiperbólica	$y(x) = \tanh x$	
Sigmoidal	$y(x) = \frac{1}{1 + e^{-x}}$	

Donde:

- $y(x)$ = Variable dependiente (caso específico demanda total de energía eléctrica).
- x = Variable independiente (caso específico producción total de fluido).

3.2.9.5. Función de salida o transferencia.

Asociada con cada unidad hay una función de salida, que transforma el estado actual de activación en una señal de salida [33]. Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas: Escalón, Lineal y Mixta, Sigmoidal, Gaussiana.

3.2.9.6. Regla de aprendizaje.

El aprendizaje puede ser comprendido como la modificación de comportamiento inducido por la interacción con el entorno y como resultado de experiencias, que conduce al establecimiento de nuevos modelos de respuesta a estímulos externos. En el cerebro humano el conocimiento se encuentra en la sinapsis [27] [28]. En el caso de las RNA el conocimiento se encuentra 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.

3.2.10. Topología o arquitectura de redes neuronales

La topología o arquitectura de las redes neuronales artificiales hace referencia a la organización y disposición de las neuronas en la red formando capas de procesadores interconectados entre sí a través de sinapsis unidireccionales la arquitectura de una red neuronal artificial depende de cuatro parámetros principales: Número de capas del sistema, numero de neuronas por capa, grado de conectividad entre las neuronas y el tipo de conexiones neuronales. Por su parte la conectividad entre los nodos de la red está relacionada con la forma de transmisión de las salidas de las distintas unidades y su transformación en inputs de otros procesadores [27] [28]. Las topologías neuronales pueden clasificarse atendiendo a distintos criterios:

3.2.10.1. Según la estructura en capas.

a. Redes monocapa

Compuestas por una única capa de neuronas, entre las que se establecen conexiones laterales y en ocasiones autor recurrentes. Este tipo de redes suele utilizarse en problemas de auto asociación [27] [28].




Figura 3.18: Red neuronal artificial monocapa [28].

b. Redes multicapa

Las redes multicapa son aquellas que disponen de conjuntos de neuronas agrupadas en varios (2, 3. etc.) niveles o capas. En estos casos, una forma para distinguir a la capa que pertenece una neurona, consistiría en fijarse en el origen de las señales que recibe a la entrada y el destino de la señal de salida. Normalmente todas las neuronas de una capa reciben señales de entrada de otra capa anterior más cercana a la entrada de la red, y envían las señales de salida a una capa posterior, más cercana a la salida de la red. A estas conexiones se les denomina conexiones hacia adelante o feedforward [27] [28].

El número de elementos de procesamiento puede variar en unas capas respecto a otras. Las funciones (tanto de activación como de salida) de los elementos de procesamiento pueden ser diferentes. En general, cuanto mayor sea la diferencia entre los elementos de entrada y los de salida, será necesario dotar a la estructura de más capas ocultas. Estas capas ocultas crean una representación interna de los patrones de entrada. La habilidad de la red para procesar información crece en proporción directa al número de capas ocultas. Según, el número de interconexiones entre capas las redes se clasifican en: totalmente conectadas y localmente conectadas [27] [28].

3.2.10.2. Según el flujo de datos en la red

a. Redes unidireccionales o de propagación hacia adelante (feedforward)

Ninguna salida neuronal es entrada de unidades de la misma capa o de capas precedentes. La información circula en un único sentido desde las neuronas de entrada hacia las neuronas de salida de la red [27] [28].

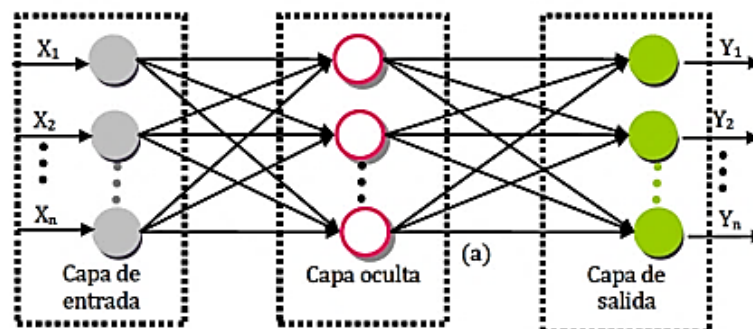


Figura 3.19: Redes de propagación hacia adelante (feedforward) [28].

Donde: (a) = Conexiones hacia adelante

3.2.10.3. Según el tipo de respuesta de la red o asociación entrada y salida.

Existen dos tipos de arquitecturas según el tipo de respuesta de la red neuronal artificial:

- a. Red neuronal artificial hetero asociativas.** – Las redes neuronales artificiales son entrenadas para que ante la presencia de un patrón A, respondan con otro patrón diferente B. Presentan al menos de 2 capas, la primera para captar la información (entrada) y la segunda para mantener la información asociada (salida) [27] [28].
- b. Red neuronal artificial auto asociativas.** – Las redes neuronales artificiales son entrenadas para que asocien un patrón A consigo mismo, es decir, actuando como un filtro. Pueden presentar una sola capa, la misma que retendrá la información de entrada y representará la información auto asociada [27] [28].

3.2.11. Mecanismo de aprendizaje

El aprendizaje, es un proceso de adaptación al entorno; durante él se crean y manipulan representaciones que sean capaces de explicar dicho entorno. En una red neuronal el aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la destrucción, modificación y creación de conexiones entre las neuronas, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero, una conexión se destruye cuando su peso pasa a ser cero. Se puede afirmar que el proceso de aprendizaje ha finalizado (la red ha aprendido) cuando los valores de los pesos permanecen estables [27] [28]. Existen tres formas de aprendizaje: Supervisado, No supervisado (o auto supervisado) y Reforzamiento (se puede considerar como un caso especial del aprendizaje supervisado). Existen una gran cantidad variedad de algoritmos dentro de cada una de estas categorías.

3.2.11.1. Supervisado

El proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor comprueba la salida de la red y en el caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida se aproxime a la deseada [27] [28]. Se consideran tres formas de llevar a cabo este tipo de aprendizaje:

- a. **Aprendizaje por corrección de error.** - Este tipo de entrenamiento consiste en presentar al sistema un conjunto de datos de entrada y la salida deseada para dicha entrada ajustando los pesos en función de la diferencia entre los valores deseados y los obtenidos como salida de la red. El objetivo, es minimizar el error entre la salida deseada y la salida que se obtiene [27] [28].
- b. **Aprendizaje por refuerzo.** - Es más lento que el anterior. No se dispone de un ejemplo completo del comportamiento deseado pues no se conoce la salida deseada exacta para cada entrada, sino que se conoce el comportamiento de manera general para diferentes entradas. La relación entrada salida, se realiza a través de un proceso de éxito o fracaso, produciendo este una señal de refuerzo que mide el buen funcionamiento del sistema. La función del supervisor es más la de un crítico que la de un maestro [27] [28].
- c. **Aprendizaje estocástico.** - Este tipo de aprendizaje consiste básicamente en realizar cambios aleatorios de los valores de los pesos y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad [27] [28].

3.2.11.2. No supervisado.

En estas redes no requieren ayuda externa para ajustar los pesos de conexiones entre neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada es o no correcta, así que existen varias posibilidades en cuanto a la interpretación de la salida de estas redes [27] [28], tales como:

- a. **Familiaridad o Similitud:** Semejanzas entre la información actual y la pasada.
- b. **Codificación:** En este se realiza una codificación de los datos de entrada, generando a la salida una versión codificada de la entrada, con menos bits, pero manteniendo la información relevante de los datos.
- c. **Mapeo:** Algunas redes con aprendizaje no supervisado realizan un mapeo de características, obteniéndose en las neuronas de salida una disposición geométrica que representa un mapa topográfico de las características de los datos de entrada, de tal forma que, si se presentan a la red informaciones similares, siempre sean afectadas neuronas de salidas próximas entre sí, en la misma zona del mapa.
- d. **Clusterización o establecimiento de clases:** La red se encarga de encontrar las características propias de cada clase.

3.2.11.3. Algoritmo de aprendizaje de retro propagación

El algoritmo de retro propagación para la red neuronal se aplica generalmente a perceptrones de perceptrones múltiples. Perceptrón tiene al menos una sección de entrada, una sección de salida y varias capas que se encuentran entre la entrada y la salida. Esta capa intermedia, también conocida como capas ocultas, puede ser una, dos, tres, etc. En la práctica, el número de capas ocultas como máximo es de tres capas. Con estas tres capas se han resuelto casi todos los problemas del mundo industrializado. La salida de la última capa de la capa oculta se utiliza directamente como salida de la red neuronal [34].

a. El algoritmo de retro programación de Levenberg-Marquard

Ha sido una técnica estándar para problemas de mínimos cuadrados no lineales, comúnmente usada en varias disciplinas para el ajuste de datos. Este algoritmo iterativo puede ser visto como una combinación de los métodos de máximo descenso y el método de Gauss-Newton. Cuando la solución actual se encuentra lejos del mínimo local, el algoritmo se comporta como el método del máximo descenso: lento, pero garantiza convergencia. Este algoritmo es parte del toolbox de redes neuronales que incluye el software Matlab, con el cual se puede entrenar cualquier objeto de red neuronal. El utilizar el mismo algoritmo como base nos asegura un doble beneficio, por una parte, la garantía de ser un algoritmo antes probado y, por otra parte, la total incorporación al entrenamiento de cualquier red, bajo los mismos comandos que el toolbox de redes neuronales. El entrenamiento empleado nos permite afinar la distribución de corrientes obteniendo una mayor aproximación y minimiza el error en un número bajo de iteraciones [34].

b. El Algoritmo de retro propagación gradiente conjugado escalado

Ajusta los pesos en la dirección de descenso más pronunciada, es decir, la más negativa del gradiente. Esta es la dirección en la que la función de rendimiento está disminuyendo más rápidamente. Resulta que, aunque la función disminuye más rápidamente a lo largo del negativo del gradiente, esto no necesariamente producir la convergencia más rápida esta realiza una búsqueda a lo largo de dicha dirección que produce una convergencia generalmente más rápida que la dirección de descenso más pronunciada, al tiempo que se conserva la minimización de errores lograda en todos los pasos anteriores. Esta dirección se llama dirección conjugada. En la mayoría de los algoritmos CG, el tamaño del paso se ajusta en cada iteración. Se realiza una búsqueda a lo largo de la dirección del gradiente conjugado para determinar el tamaño del paso, lo que minimizará la función de rendimiento a lo largo de esa línea. Todos los algoritmos CG

comienzan buscando en la dirección de descenso más empinada en la primera iteración. Con frecuencia, los algoritmos CG se utilizan con la búsqueda de líneas [34].

c. El Algoritmo de retro propagación de regularización bayesiana BR

Es un algoritmo de entrenamiento que actualiza los pesos y los valores de sesgo de acuerdo con la optimización de LM, minimiza la combinación lineal de errores cuadráticos y pesos. También modifica la combinación lineal para que al final del entrenamiento, la red resultante tenga buenas cualidades de generalización [34]. El entrenamiento se detiene cuando ocurre una de estas condiciones:

1. Se alcanza el número máximo de épocas (repeticiones).
2. Se excedió la cantidad máxima de tiempo.
3. El rendimiento se minimiza hasta el destino.
4. El rendimiento del gradiente cae por debajo de min_grad.
5. excede mu_max.

3.2.12. Perceptron multicapa

Dentro de los modelos de Red Neuronal Artificial (RNA) existen diversos tipos de estructuras dependiendo de la disposición de los enlaces que conectan las neuronas o si existen bucles dentro de la red. Una estructura ampliamente utilizada en el pronóstico de series de tiempo es el Perceptrón Multicapa (PM), esta se forma a partir de generalizar el perceptrón simple, el cual está basado en el uso de varias capas de neuronas artificiales (capas ocultas), en vez de usar una sola capa el cual presenta las siguientes características:

- No existen bucles ni conexiones entre las neuronas de una misma capa.
- Las funciones de activación son iguales para cada neurona de una misma capa.
- Tiene una sola neurona en la capa de salida.




Figura 3.20: Red multicapa de propagación hacia atrás (Feedback) [28].

La representación matemática de la figura 3.14, se indica en la ecuación:

$$y = \sum_{j=1}^m w_j * f_j \left(\sum_{i=1}^n a_{ij} x_i + b_j \right) + c \quad (3.1)$$

Donde:

- y = Variable pronosticada
- x_i = Variable entrada
- w_j = Pesos que conectan la j-ésima salida de la capa oculta a la capa de salida
- w_{ij} = Pesos que conectan la i-ésima entrada al modelo con la j-ésima neurona de la capa oculta
- b_j = Sesgos (bias) o intercepto de las j-ésima neurona oculta c es el sesgo (bias) o intercepto de la neurona y de salida

w_{ij} , a_{ij} , b_j y c son los parámetros del modelo que deben ser ajustadas mediante el algoritmo de entrenamiento. En total son $(n + 1)(m + 1)$ parámetros a ajustar, donde n es el número de entradas al modelo y m es el número de neuronas en la capa oculta de la red. Interpretando esta ecuación, el modelo resulta ser una regresión caracterizada por la función f , la cual puede ser lineal o no lineal y determina la forma en que se relacionan las entradas al modelo con la salida.

3.2.13. Problemas derivados del Entrenamiento.

El desafío central al trabajar con redes neuronales es que nuestro algoritmo debe tener buen rendimiento sobre entradas nuevas no observadas previamente, y no solo en aquellas para las cuales nuestro modelo fue entrenado. Esta habilidad de poder desempeñarse correctamente sobre entradas nuevas se denomina generalización.

Típicamente, en un modelo de redes neuronales, tenemos acceso a un conjunto de entrenamiento y podemos calcular alguna medida del error sobre este conjunto, denominada error de entrenamiento. Lo que separa a machine learning y deep learning de un mero problema de optimización es que esperamos que el error de generalización sea pequeño también. Este error se define como la esperanza del error sobre una nueva entrada. Esta esperanza se toma sobre diferentes entradas posibles, extraídas a partir de la distribución de entradas que esperamos que el sistema encuentre en la práctica. Es usual estimar el error de generalización

del modelo midiendo su rendimiento sobre un conjunto de prueba conteniendo ejemplos obtenidos separadamente del conjunto de entrenamiento [35].

Los factores que determinan cuan bien van a desempeñarse un modelo de redes neuronales son su capacidad de hacer pequeño el error de entrenamiento, y de hacer la brecha entre el error de entrenamiento y el error de prueba lo más pequeña posible [35] .

3.2.13.1. Underfitting

Corresponde a underfitting (subajuste), cuando el modelo no puede obtener un error suficientemente bajo sobre el conjunto de entrenamiento. El modelo puede no estar ajustado lo suficiente. Bien por falta de tiempo de entrenamiento o por no disponer de datos suficientes para hacer una modelización fidedigna. Es un problema fácilmente detectable [36].

En la figura 3.21, si nuestros datos de entrenamiento son muy pocos nuestro programa no será capaz de generalizar el conocimiento y estará incurriendo en underfitting.




Figura 3.21: Equilibrio de aprendizaje en underfitting [37].

3.2.13.2. Overfitting

Corresponde con el de overfitting (sobreajuste), que ocurre cuando la brecha entre el error de entrenamiento y el error de prueba es demasiado grande. A medida que se entrena y se itera un modelo, la capacidad de predicción puede no mejorar.

Matemáticamente es posible obtener una función que ajuste para casi cualquier conjunto de datos de entrenamiento. Sin embargo, el modelo gana complejidad muy rápidamente si se quiere minimizar al máximo el error de entrenamiento. Este aumento de la complejidad solo producirá un ajuste de peor calidad en el proceso de generalización del modelo y un mayor coste en tiempo de ejecución.

Puede decirse que un modelo que presenta overfitting particulariza, pero no generaliza. Un modelo que muestre problemas de overfitting no es capaz de generalizar el modelo para datos que no pertenezcan a la muestra de datos de entrenamiento [36].

En la figura 3.22, sobre-entrenamos nuestro modelo y caemos en el overfitting, nuestro algoritmo estará considerando como válidos sólo los datos idénticos a los de nuestro conjunto de entrenamiento y siendo incapaz de distinguir entradas buenas como fiables si se salen un poco de los rangos ya preestablecidos.




Figura 3.22: Equilibrio de aprendizaje en overfitting [37].

3.2.13.3. Normal fitting

Se trata del punto de entrenamiento más adecuado para el modelo. En este punto, el error correspondiente a la serie de entrenamiento y al de la generalización debe ser lo más parecido posible. De manera que el modelo tenga la complejidad adecuada para tener un comportamiento robusto [36].

En la figura 3.23, se encuentra un punto medio en el aprendizaje del modelo aplicado, en el que no está incurriendo en underfitting y tampoco en overfitting.




Figura 3.23: Equilibrio de aprendizaje en normal fitting [37].

Para reconocer este problema deberemos subdividir nuestro conjunto de datos de entrada para entrenamiento en dos: uno para entrenamiento y otro para la Test que el modelo no conocerá de antemano. Esta división se suele hacer del 80% de datos para entrenar y 20% de validación. El conjunto de Test deberá tener muestras diversas en lo posible y una cantidad de muestras suficiente para poder comprobar los resultados una vez entrenado el modelo.




Figura 3.24: Test de entrenamiento de la red neuronal

Cuando entrenamos nuestro modelo solemos parametrizar y limitar el algoritmo, por ejemplo, la cantidad de iteraciones que tendrá o un valor de “tasa de aprendizaje” (learning-rate) por iteración y muchos otros.

Para lograr que nuestro modelo dé buenos resultados iremos revisando y contrastando nuestro entrenamiento con el conjunto de Test y su tasa de errores, utilizando más o menos iteraciones, etc. hasta dar con buenas predicciones y sin tener los problemas de over-under-fitting [37].

4. METODOLOGÍA

4.1. TIPO DE INVESTIGACIÓN

El presente proyecto de investigación da a conocer la situación de los sistemas de distribución en lo referente a la proyección de la demanda de energía eléctrica a corto plazo donde en el alimentador de análisis está involucrado diversas cargas que se añaden o se quitan en diferente horario en todo el día, con lo cual se plantea alternativas que permitan un análisis más fácil, para identificar en comportamiento de la demanda eléctrica.

4.1.1. Investigación descriptiva

Se utiliza principalmente el método de análisis, es decir, se descompone el objeto a aprender en sus diversos puntos o recursos, para tal manera llegar a un entendimiento más técnico, se hace una exposición de hechos e ideas definiendo las situaciones del comportamiento de la demanda de energía eléctrica en el alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo debido al incremento de cargas eléctricas. Este tipo de investigación ayudo analizar como la demanda de energía eléctrica se comporta en el alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo, adquiriendo una base de datos históricos con valores de potencia eléctrica horaria.

4.1.2. Investigación diagnóstica

Este tipo de investigación brinda acceso a las características de un problema planteado abarcando un campo delimitado específico, ayudando a comprender la situación a la cual está sometido actualmente el alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo en el sistemas de distribución, identificando los factores analizar para adentrar más al problema planteado

ayudando a obtener un análisis con los datos obtenidos, permitiendo lograr una alternativa de solución para problema de la predicción de la demanda de energía eléctrica a corto plazo.

4.1.3. Investigación aplicada

En esta parte se pondrá en práctica todos los conocimientos científicos adquiridos, como también el uso del software MATLAB para realizar el análisis y programación de un algoritmo que permita realizar la predicción de la demanda de energía eléctrica con resultados suficientemente próximos a la realidad.

4.2. MÉTODO DE INVESTIGACIÓN

4.2.1. Metodología de la investigación bibliográfica.

Este tipo de investigación ayuda con la especificación del análisis, el cual se basará en consultar artículos técnicos, libros, publicaciones en internet y precedentes de proyectos semejantes referentes a la predicción de la demanda de energía eléctrica en sistemas de distribución. Lo que ha proporcionado el razonamiento de teorías, conjetura, resultados en artefactos aplicados en las referencias seleccionadas, ayudando a la votación del procedimiento conveniente para la solución del problema.

4.2.2. Inductivo – deductivo

Examina de manera descriptiva todos los procedimientos, temas y subtemas que se usaron en la preparación del trabajo de investigación, paralelamente este procedimiento permitió detallar las conclusiones y sugerencias del problema investigado. En relación al método utilizado se analizó cada uno de las metodologías para la resolución de la predicción de la demanda de energía eléctrica a corto plazo, a partir del análisis de investigaciones ya realizadas en diferentes escenarios pero con la misma concordancia, que a su vez ayudo con la implementación de un algoritmo que permitió obtener datos necesarios para establecer nuestras propias deducciones de esta manera recomendar procesos que pueden ser aplicados en este tipo de investigaciones.

4.3. TÉCNICAS E INSTRUMENTOS

4.3.1. La observación

Esta técnica es la más correcta para la indagación, debido a que parte de la implementación de la red neuronal artificial para el que corresponde registro de datos logrados en el proceso, llegando a obtener resultados satisfactorios, óptimos.

4.3.2. Simulación

Se desarrollará mediante el uso de software MATLAB el cual nos ayudaran a determinar los parámetros referentes a la red neuronal artificial con la base de datos históricos totales en el alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo, para de esta manera constatar datos con el algoritmo propuesto e identificar el rango de error existente.

4.3.3. Programación

Se realizará mediante el software MATLAB el cual permitirá diseñar nuestro algoritmo a partir de vectores y formulación matemática aplicado a las redes neuronales artificiales, ingresando la base de datos históricos de la potencia eléctrica, permitiendo identificar el porcentaje de error en la predicción de la demanda de energía eléctrica a corto plazo.

5. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS

5.1. METODOLOGÍA DEL PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO.

Toda la serie para la realización de esta investigación es la siguiente:

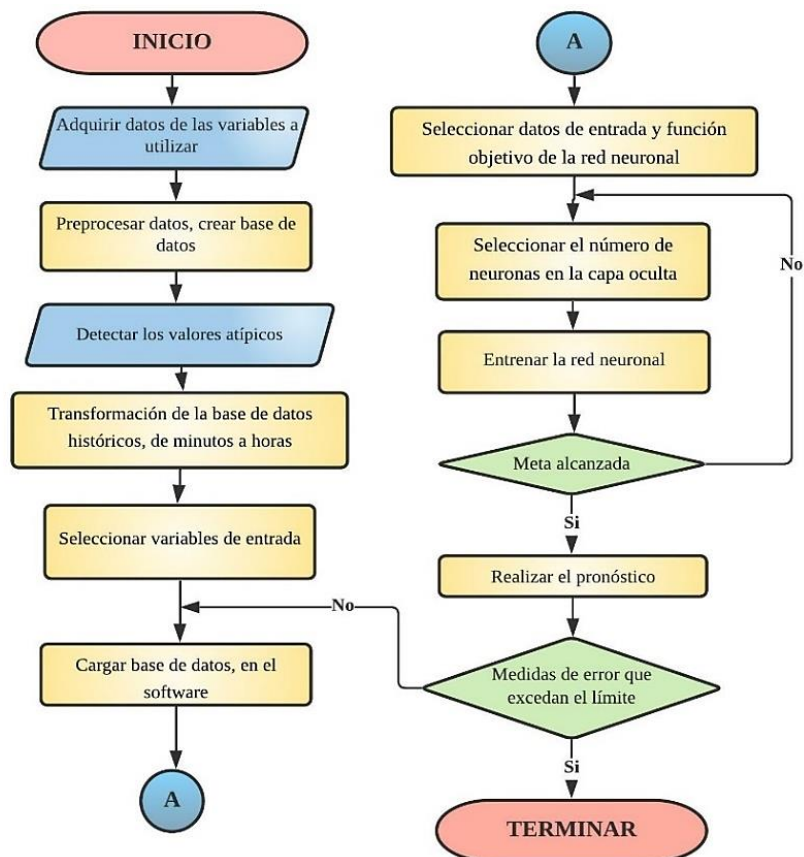


Figura 5.1: Diagrama de flujo del pronóstico de la demanda a corto plazo.

5.2. ANÁLISIS DE LA BASE DE DATOS HISTÓRICOS

5.2.1. Análisis del comportamiento de la base de datos reales

Para poder realizar el pronóstico de la demanda a corto plazo, fue necesario crear una nueva base de datos, es decir crear una hoja de Excel, donde se encuentren datos históricos desde el primero de enero del año 2020 hasta el 31 de marzo del año 2021.

En primera instancia se debe conocer el comportamiento de la serie de los datos en análisis, hacer una estimación de la técnica que se va a emplear y luego el pronóstico de los siguientes periodos; cabe notar que esto es con fines académicos, la base de datos que se tiene son datos históricos reales, el tamaño de la muestra es importante en la precisión del pronóstico, debido a que la demanda es variable, se debe considerar un análisis espaciado de tiempo, para estimar su comportamiento. En la práctica se utilizan datos históricos mayores a un año y con ello proyectarlo a un horizonte de tiempo, que sería a una semana, obteniendo así un pronóstico confiable sobre el comportamiento de la demanda. En caso de contar con el comportamiento de 10 minutos de la demanda, los perfiles de consumo se discriminan por hora del día y día de la semana.

En la figura 5.2, se puede observar la curva de la demanda semanal, desde el 17 al 23 de los últimos 7 días del mes de abril del año 2021 del Alimentador PRI12 – Santa Rosa Pichul – San Gerardo la cual se caracteriza por tener intervalos de tiempo de horas para cada día de la semana. Se puede apreciar que el comportamiento de la demanda eléctrica de la última semana del mes de marzo, es menor en ciertos días y similares para varios días.




Figura 5.2: Curva demanda eléctrica semanal

En la tabla 5.1, se detalla el valor de los datos en estudio, el cual pertenece a los últimos 7 días del mes de marzo, se obtiene valores máximos y mínimos de la demanda eléctrica donde nos presenta un rango de 1159,80 kWh, el cálculo de la frecuencia por que los datos no se repiten, es decir que son diferentes a cada hora.

Tabla 5.1: Análisis descriptiva con datos reales de la demanda eléctrica

ANÁLISIS DESCRIPTIVA	
Máximo	2076,95 kWh
Mínimo	917,14 kWh
Rango	1159,80 kWh
Media	1517,91 kWh
Mediana	1475,91 kWh
Varianza	76662,73
Desviación estándar	276,88
Coefficiente de variación	18,24 %
Límite máximo	1794,79 kWh
Límite mínimo	1241,03 kWh

En medidas de tendencia central el cálculo de la media o el promedio es de 1517,91 kWh es decir que representa el promedio de la energía que se consume en el intervalo de los datos en análisis, la mediana representa el valor que ocupa la parte central del conjunto de datos, donde van a estar el 50% de datos por debajo y 50% por encima de 1475,91 kWh, no se puede realizar el cálculo de la moda, ya que ésta representa el valor que más se repite.

Las medidas de dispersión nos muestran que tan alejadas o cercanas están los datos con respecto a las medidas de tendencia central, donde la varianza representa la inestabilidad de la serie de datos, respecto a la media en este caso obtenemos un valor muy elevado, la desviación estándar se trata de que tan cerca o alejadas están los valores con respecto a la media, en este caso se obtiene un valor 276,88, es decir que con el coeficiente de variación se obtiene un porcentaje de la dispersión de los datos del 18,24 %, es decir que no existe homogeneidad en los datos.

En medidas de tendencia central el cálculo de la media o el promedio es de 1517,91 kWh es decir que representa el promedio de la energía que se consume en el intervalo de los datos en análisis, la mediana representa el valor que ocupa la parte central del conjunto de datos, donde van a estar el 50% de datos por debajo y 50% por encima de 1475,91 kWh, no se puede realizar el cálculo de la moda, ya que ésta representa el valor que más se repite, es decir no existe valores homogéneos.

Las medidas de dispersión nos muestran que tan alejadas o cercanas están los datos con respecto a las medidas de tendencia central, donde la varianza representa la inestabilidad de la serie de datos, respecto a la media en este caso obtenemos un valor muy elevado, la desviación estándar se trata de que tan cerca o alejadas están los valores con respecto a la media, en este caso se obtiene un valor 276,88, es decir que con el coeficiente de variación se obtiene un porcentaje de la dispersión de los datos del 18,24 %, es decir que no existe homogeneidad en los datos de análisis.

En la figura 5.3, se observa el comportamiento de los valores reales donde representa el valor límite máximo y mínimo, de la misma manera la desviación estándar observando el intervalo de la dispersión de los datos.



Figura 5.3: Desviación estándar de datos de la semana en estudio

En la figura 5.4, se puede observar la curva de la demanda semanal de los últimos 7 días del mes de abril del año 2021 del Alimentador PRI12 – Santa Rosa Pichul – San Gerardo, con intervalos de tiempo de horas para cada día del mes. En este caso su forma y comportamiento depende de las variables que afectan la demanda a corto plazo, se puede apreciar que el comportamiento de la demanda eléctrica tiende a crecer mientras transcurren las horas de la tarde y noche, sin tomar en cuenta las horas de la madrugada, el cual decreció existiendo menos consumo eléctrico, con la excepción a la madrugada del día 18 y 21 existiendo un apagón general del alimentador o a su vez mantenimiento de la red.




Figura 5.4: Curva de la demanda eléctrica de la semana en estudio

En la presente figura 5.5, se detalla la capacidad del proceso para la demanda de energía eléctrica de los datos reales, donde nos presenta 6 comportamientos, con la gráfica Xbarra se observa el límite de caso superior e inferior como los datos atípicos obteniendo un promedio de 1518 kWh, dando un óptimo resultado para la predicción de la demanda a corto plazo.

En el histograma de capacidad nos presenta tres comportamientos, días laborables, fines de semana y los datos atípicos, en estos resultados, los datos del proceso se encuentran bastante centrados entre los límites de especificación, la mayoría de los datos se encuentra dentro de los límites de especificación que son datos, hay partes no conformes por debajo del límite de especificación inferior (LEI) y por encima del límite de especificación superior (LES) estas representan elementos no conformes, es decir datos atípicos.

La gráfica R permite monitorear la estabilidad del proceso en el tiempo, para identificar y corregir las inestabilidades en un proceso, existe tres puntos fuera de los límites de control y el resto varían aleatoriamente alrededor de la línea central y se encuentran dentro de los límites de control, por lo tanto, la variación del proceso está bajo control.

La gráfica de probabilidad normal representa si los datos siguen una distribución normal, en estos resultados la línea de distribución ajustada es la línea recta intermedia en la gráfica, las líneas continuas externas en la gráfica son los intervalos de confianza de los percentiles individuales por ende los datos son normales.

La grafica de los últimos 25 subgrupos hace referencia al grupo de unidades que se crean bajo el mismo conjunto de condiciones, los datos en análisis demuestran estabilidad y por último para la capacidad de subgrupos/corto plazo, el C_p es 1.72, lo que indica que la dispersión de

especificación es 1,72 veces mayor que la dispersión de todo el proceso. Cp (1.72) y Cpk (1.65) están muy cercanos entre sí, lo que indica que el proceso está aproximadamente centrado.

Para la capacidad general, Pp (0,70), Ppk (0,68) están muy cercanos entre sí, lo que indica que el proceso está en el objetivo, es decir, que los datos son aceptados para un proceso capaz.




Figura 5.5: Capacidades del proceso para la demanda de energía eléctrica (datos reales – 1 semana)

Para tener una mejor visualización del comportamiento de la curva de la demanda eléctrica en la figura 5.6, se grafica datos diarios de dos últimos días del mes de marzo del año 2020, con datos reales donde se observa un comportamiento casi similar, tanto en el crecimiento y la disminución de la carga eléctrica durante todo el día.




Figura 5.6: Curva de la demanda eléctrica diaria con intervalos de 1 hora

Para un análisis con mayor detalle en la figura 5.7, se presenta datos reales de 1 día, donde las gráficas Xbarra y R indican que el proceso es estable, sin puntos más allá de los límites de control. La gráfica de probabilidad normal indica que los datos están distribuidos normalmente. Por lo tanto, los supuestos del análisis de capacidad (subgrupos/corto plazo) se cumplen y se puede analizar la capacidad del proceso. El histograma de capacidad muestra que el proceso está aproximadamente centrado y que las mediciones están dentro de los límites de especificación, con partes no conformes por debajo del LEI y por encima del LES que representan datos atípicos.

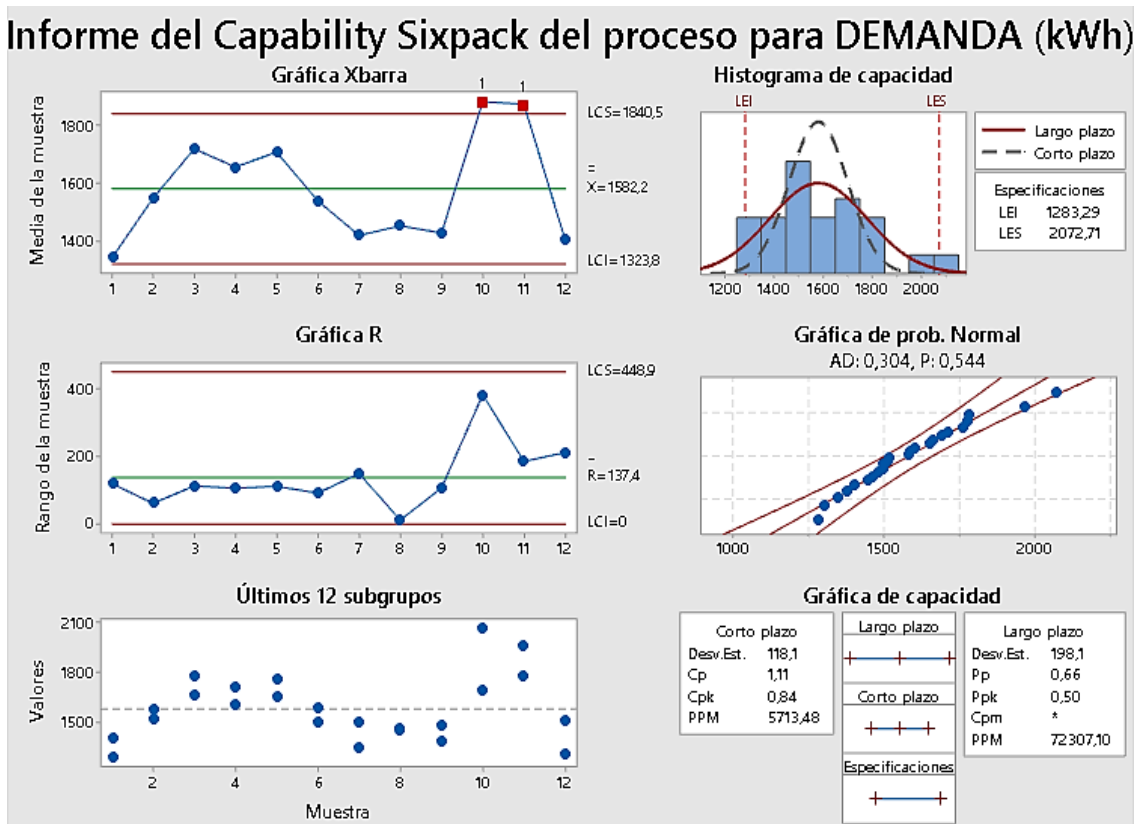


Figura 5.7: Capacidades del proceso para la demanda de energía eléctrica (datos reales - 1 día)

5.2.2. Análisis del comportamiento de la demanda eléctrica pronosticada

En la figura 5.8, se puede observar la curva de la demanda semanal pronosticada, desde el 31 de marzo al 6 de abril del año 2021 del Alimentador PRI12 – Santa Rosa Pichul – San Gerardo, la cual obtenemos valores con intervalos de tiempo de horas para cada día de la semana. En este caso se puede apreciar que el comportamiento de la demanda eléctrica pronosticada tiende a crecer mientras transcurren las horas de la tarde y noche, sin tomar en cuenta las horas de la madrugada, el cual decrece existiendo menos consumo eléctrico.




Figura 5.8: Curva de la demanda eléctrica pronosticada

En la tabla 5.2, se detalla el valor de los datos que se pronosticaron, los cuales pertenecen al último día del mes de marzo y los primeros 6 días del mes de abril considerando como una semana, se obtiene datos de valor máximo de la demanda eléctrica y el valor mínimo donde nos presenta un rango de 1090 kWh, del mismo modo no se puede realizar el cálculo de la frecuencia por que los datos no se repiten.

Tabla 5.2: Análisis descriptiva con datos reales de la demanda eléctrica

ANÁLISIS DESCRIPTIVA	
Máximo	2092 kWh
Mínimo	1002 kWh
Rango	1090 kWh
Media	1488,52 kWh
Mediana	1471 kWh
Varianza	67091,81
Desviación estándar	259,02
Coefficiente de variación	17,40 %
Límite máximo	1747,54 kWh
Límite mínimo	1229,50 kWh

En medidas de tendencia central el cálculo de la media o el promedio es de 1488,52 kWh es decir que representa el promedio de la energía que se consume en el intervalo de los datos en análisis, la mediana representa el valor que ocupa la parte central del conjunto de datos, donde van a estar el 50% de datos por debajo y 50% por encima de 1471 kWh, no se puede realizar el

cálculo de la moda, ya que ante se mencionó que representa el valor que más se repite. En datos de medidas de dispersión, el cálculo de la desviación estándar se obtiene un valor de 259,02, con un coeficiente de variación de 17,40 %, comprobando la no homogeneidad en los datos de análisis. En la figura 5.7, se observa el comportamiento de los valores de pronóstico de la demanda de energía eléctrica, donde representa el valor límite máximo y mínimo, observando el intervalo de la dispersión de los datos.




Figura 5.9: Desviación estándar con datos de la demanda pronosticada

En la figura 5.10, se detalla la capacidad del proceso para la demanda de energía eléctrica de los datos pronosticados, donde nos presenta 6 comportamientos, las gráficas Xbarra y R indican que el proceso es estable, con pocos puntos más allá de los límites de control, la gráfica de los últimos 25 subgrupos indica que los datos están distribuidos de forma aleatoria y simétrica alrededor de la media del proceso. La gráfica de probabilidad normal indica que los datos están distribuidos normalmente, entonces los supuestos del análisis de capacidad normal se cumplen. El histograma y los índices de capacidad indican que el proceso está aproximadamente centrado en el objetivo y que las mediciones están dentro de los límites de especificación. Los índices de capacidad Cpk, Ppk y Cpm son mayores que 1.33, que es un valor mínimo generalmente aceptado para un proceso capaz, entonces el proceso cumple con los requisitos y el pronóstico es confiable.




Figura 5.10: Capacidades del proceso para la demanda de energía eléctrica (datos pronosticados - 1 semana)

Para tener una mejor visualización del comportamiento de la curva de la demanda eléctrica pronosticada en la figura 5.11, se grafica datos horarios donde se observa un comportamiento muy singular a la curva de la demanda eléctrica, tanto en el crecimiento y la disminución de la carga durante todo el día.




Figura 5.11: Demanda eléctrica diaria con datos obtenidos del pronostico

Para un análisis con mayor detalle en la figura 5.12, se presenta datos pronosticados de 1 día, donde las gráficas Xbarra y R indican que el proceso es estable, sin puntos más allá de los límites de control. La gráfica de probabilidad normal indica que los datos están distribuidos normalmente. Por lo tanto, los supuestos del análisis de capacidad (subgrupos/corto plazo) se cumplen y se puede analizar la capacidad del proceso. El histograma de capacidad muestra que el proceso está aproximadamente centrado y que las mediciones están dentro de los límites de especificación, con partes no conformes por debajo del LEI y por encima del LES que representan datos atípicos.




Figura 5.12: Capacidades del proceso para la demanda de energía eléctrica (datos pronosticados - 1 día)

5.3. COMPARACIÓN DE DATOS REALES Y PRONÓSTICO DE LA RED NEURONAL

En la figura 5.13, se puede observar el comportamiento de la curva de la demanda eléctrica con datos reales de los últimos 7 días del mes de marzo del 2021 y los datos de los 7 días del pronóstico de la demanda eléctrica del mismo año. Donde actúan de manera muy similar tanto en el crecimiento y en la reducción de la demanda.




Figura 5.13: Curva de la demanda eléctrica real vs pronosticada

Por consiguiente, en la figura 5.14, representa el porcentaje de error de los datos reales y del pronóstico de carga, en la tabla 5.3, se obtiene el error porcentual que se tuvo en la comparativa de los datos de las dos curvas de la demanda eléctrica, el cual es del 1,60%, por ende, los datos que se obtuvo del pronóstico de la demanda son óptimos y confiables.

Tabla 5.3: Error promedio entre demanda eléctrica real y pronosticada (semanal)

ERROR	
Error promedio	0,02
Error promedio %	1,60




Figura 5.14: Gráfica de error entre curva de la demanda eléctrica real y pronosticada (semanal)

En la figura 5.15, se ilustra intervalos de la demanda de energía eléctrica con datos reales y de pronóstico, en un intervalo de 1 semana, donde se verifica el comportamiento de la curva eléctrica de gran similitud tanto en real como en pronóstico, existe valores elevados de demanda en horas de la madrugada y de la noche, al medio día disminuye notoriamente, esto se da debido a que el alimentador pertenece a una zona rural.




Figura 5.15: Intervalos de la demanda de energía eléctrica (Datos reales y de pronóstico – 1 semana)

Para visualizar de mejor manera el comportamiento de la curva de la demanda eléctrica tanto con datos reales y de pronóstico, en la figura 5.16, representa la demanda eléctrica pronosticada y real que tienden a ser similares, en horas de la madrugada existe un incremento en la carga hasta las 11 am, entre 13:00 y 17:00 decreció existiendo menos consumo eléctrico, mientras que transcurren las horas de la tarde y noche tiende a crecer la carga de manera muy elevada.




Figura 5.16: Curva demanda eléctrica real vs pronosticada (Diaria)

Del mismo modo en la figura 5.17, representa el porcentaje de error de los datos reales y del pronóstico de carga, en la tabla 5.4, se obtiene el error porcentual que se tuvo en la comparativa de las dos curvas de la demanda eléctrica, el cual es de 0,66% por ende los datos que se obtuvo del pronóstico de la demanda son óptimos, confiables y con menor error.

Tabla 5.4: Error promedio entre demanda eléctrica real y pronosticada (Diaria)

ERROR	
Error promedio	0,01
Error promedio %	0,66




Figura 5.17: Grafica de error entre curva de la demanda eléctrica real y pronosticada (Diaria)

Para una mejor visualización más detallado en la figura 5.18, se ilustra intervalos de la demanda de energía eléctrica con datos reales y pronosticados de 1 día, donde se verifica el comportamiento de la curva eléctrica de gran similitud tanto en real como en pronóstico, existe valores elevados de demanda en horas de la madrugada y de la noche, al medio día disminuye notoriamente.




Figura 5.18: Intervalos de la demanda de energía eléctrica (Datos reales y de pronóstico - 1 día)

5.4. INTERFACES GRÁFICAS DESARROLLADAS

En esta sección se presenta y verifica la funcionalidad de la interfaz gráfica desarrollada en Matlab para la predicción de la demanda de energía eléctrica a corto plazo. Se presenta los resultados de predicción numérica y gráficamente obtenidos para el caso de estudio (base de datos de la demanda de energía eléctrica para el Alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo).

La interfaz gráfica desarrollada en el presente trabajo de titulación está constituida por tres módulos: módulo de datos históricos, módulo de entrenamiento de red y módulo de predicción demanda, cada módulo presenta características propias que permitirán el correcto funcionamiento.

La interfaz gráfica desarrollada presenta un menú para la selección del módulo activo (el módulo esta activo si el botón se encuentra de color verde, el módulo esta inactivo si el botón se encuentra de color gris), además en este menú se encuentra un botón para salir de la herramienta computacional.



Figura 5.19: Menú de selección de módulos

A continuación, se detalla las funcionalidades cada módulo.

5.4.1. Módulo de Datos Históricos

La finalidad del presente módulo es analizar los datos históricos de la base de datos utilizada. El módulo presenta dos secciones. La primera sección permite configurar el intervalo de tiempo a analizar de la base de datos y la segunda sección permite tanto graficar los datos históricos como visualizar numéricamente los datos históricos.

En la figura 5.20, se puede evidenciar la funcionalidad del módulo datos históricos, en la cual se selecciona la opción total y se procede a graficar todos los datos históricos de la base de datos.




Figura 5.20: Módulo de datos históricos (Datos totales).

En la figura 5.21, se puede evidenciar la funcionalidad del módulo datos históricos, en la cual se selecciona la opción parcial, para esta opción se habilita el menú de selección de la fecha de inicio y la fecha de fin del intervalo a considerar y se procede a graficar únicamente los datos históricos del intervalo de tiempo seleccionado de la base de datos. Las fechas son ingresadas considerando año-mes-día -hora, es importante notar que la fecha de inicio debe ser más antigua que la fecha de fin, en caso de un error en el ingreso de las fechas la herramienta computacional indicara mediante un mensaje que las fechas ingresadas son incorrectas o no existen en la base de datos.




Figura 5.21: Módulo de datos históricos (Datos parciales)

Como se mencionó anteriormente la herramienta computacional además de graficar los datos históricos, permite visualizar numéricamente estos valores, en la figura 5.22, se detalla la tabla visualizada, indicando la demanda de energía eléctrica por cada hora del día.

Esta tabla es creada cuando se grafica los datos históricos sin importar si se encuentra en la opción total o parcial.




Figura 5.22: Módulo de datos históricos (Visualización de datos numéricos)

5.4.2. Módulo de Entrenamiento de la red

La finalidad del presente módulo es configurar, crear y entrenar una red neuronal específica útil para la predicción de la demanda de energía eléctrica a corto plazo. Al igual que el anterior módulo este presenta dos secciones.

La primera sección permite configurar los parámetros de la red neuronal como:

- La primera sección permite crear (número de neuronas, número de retrasos de tiempo, porcentaje de datos de entrenamiento, prueba y validación)
- la segunda sección permite graficar los resultados del entrenamiento de la red neuronal, además de indicar el rendimiento de la red neuronal una vez finalizado el entrenamiento.

En la figura 5.23, se puede evidenciar la funcionalidad del módulo de entrenamiento de la red.




Figura 5.23: Módulo de entrenamiento de la red.

En el instante que se procede a entrenar la red neuronal configurada, el módulo abre dos ventanas adicionales, en la primera pestaña (Figura 5.24) se visualiza la configuración de la red neuronal creada y en la segunda pestaña (Figura 5.25) se visualiza gráficamente los resultados del entrenamiento de la red neuronal y los errores producidos.




Figura 5.24: Configuración de la red neuronal creada.




Figura 5.25: Resultados del entrenamiento de la red neuronal.

5.4.3. Módulo de Predicción de la Demanda

La finalidad del presente módulo es presentar las predicciones de la demanda de energía eléctrica en base a los datos históricos ingresados, los resultados se visualizarán tanto grafica como numéricamente. Al igual que en los anteriores módulos este módulo presenta dos secciones: la primera sección permite seleccionar el periodo de predicción de la demanda y la segunda sección permite graficar los resultados de la predicción de la demanda de energía eléctrica utilizando la red neuronal creada y entrenada en el módulo anterior.

Las fechas son ingresadas considerando año-mes-día -hora, es importante notar que la fecha de inicio debe ser más antigua que la fecha de fin, en caso de un error en el ingreso de las fechas la herramienta computacional indicara mediante un mensaje que las fechas ingresadas son incorrectas. Del mismo modo la herramienta computacional cuenta con un apartado donde se ingresa una fecha específica para calcular la demanda de energía eléctrica de dicha fecha y visualizar el valor junto con la gráfica creada.

En la figura 5.26, se puede evidenciar la funcionalidad del módulo predicción demanda.




Figura 5.26: Módulo de Predicción de la Demanda (Visualización grafica).

Finalmente, los valores numéricos de la predicción de energía eléctrica realizada se visualizan en formato de tabla (Figura 5.27), en el cual se especifica la fecha y la demanda calculada por la red neuronal artificial desarrollada.




Figura 5.27: Módulo de predicción de la demanda (Visualización numérica).

5.5. ENTRENAMIENTO DE LA RED

5.5.1. Número de capas ocultas

Se hizo uso de la librería de redes neuronales de Matlab, existen varios tipos de redes que dependiendo de la aplicación se selecciona y se configura, para el caso de predicción de series de tiempo Matlab la librería cuenta con la red NARNET, mismo que tiene como datos de entrada los datos pasados de la variable. En este caso no se puede cambiar el número de capas ocultas a nuestro placer, debido a que esta configuración tiene ya predefinido el número de capas ocultas la cual es de 1 (generalmente en referencias bibliográficas 1 capa es lo ideal para predecir series de tiempo como es el caso). En caso de querer cambiar el número de capas ocultas es necesario cambiar la configuración de la red, así como cambiar el formato de ingreso de los datos.




Figura 5.28: Red neuronal (una capa oculta y una de salida).

5.5.2. Función de activación de salida

La función de activación de salida es la función lineal (Predefinida en la configuración escogida de la librería de Matlab). Del mismo modo que el punto anterior no se puede cambiar la función de activación de salida, ya que la red escogida está diseñada y probada para que funcione para la predicción de series de tiempo.

Los datos que se pueden configurar a placer son: el número de neuronas de la capa oculta, el número de datos pasados que depende en el cálculo del dato actual (rezagos), porcentaje de datos de entrenamiento, validación, prueba y algoritmo de entrenamiento de la red (todos estos fueron probados en el capítulo de resultados).




Figura 5.29: Función de activación (tangente hiperbólica)

5.5.3. Módulos de los problemas derivados del entrenamiento.

a. Underfitting

En la figura 5.30, se verifica que los datos históricos ingresados en los parámetros a considerar, tanto el número de retrasos 20, que es aleatorio a cambiar, número de neuronas que son 10, entrenamiento de datos el 80%, de prueba el 10% y de validación el 10%, nuestra red neuronal va a entrar en Underfitting por el motivo de que se ingresa pocos datos poca información.

```

%% Ingreso de parametros
Retrasos=20;% número de retrasos que que quieran
NumeroNeuronas=10;% se puede cambiar las neuronas
trainFcn = 'trainlm'; %Tipo de entrenamiento inicial...tipo de función de entrenamiento
Ent=80;% 70% de los datos
Pru=10;% Pruebas
Val=10;% Validación
    
```

Figura 5.30: Código para ingresar parámetros de la red neuronal.

En la figura 5.31, se observa el comportamiento subajustado, debido al deficiente rendimiento del modelo, donde existe un error en el entrenamiento muy grande y por ende la predicción será muy defectuosa, por lo que va a causar un ajuste insuficiente de los datos.

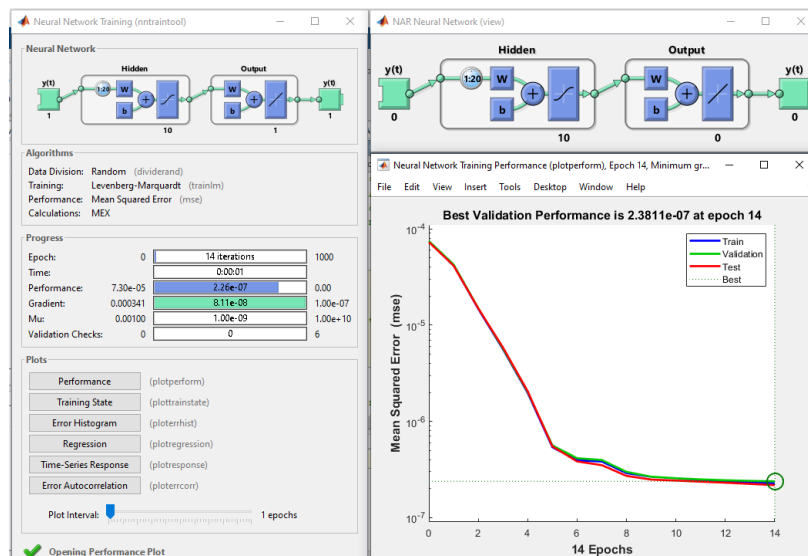


Figura 5.31: Red neuronal en underfitting.

En la figura 5.32, se observa el histograma de error, el mismo que va desde -0,00171 hasta 0,000467, la mayoría concentrándose en valores a $-7,7 \cdot 10^{-5}$, se determina que tenemos mal desempeño para esta regresión, debido a la poca información ingresada.




Figura 5.32: Histograma de error.

En la figura 5.33 se observa la pendiente de regresión, obteniendo un mínimo error, con un resultado del entrenamiento de $R = 0.97321$, siendo un resultado no óptimo para la predicción del caso de estudio presentado.




Figura 5.33: Pendiente de regresión a 45° de la red neuronal (underfitting).

b. Overfitting.

En la figura 5.34, se verifica que, con los datos históricos ingresados en los parámetros a considerar, tanto el número de retrasos 900, que es aleatorio a cambiar, número de neuronas que son 10, entrenamiento de datos el 80%, de prueba el 10% y de validación el 10% nuestra red neuronal se considera en estado de overfitting por el motivo que se ingresa bastantes datos de retraso (mucha información).

```

%% Ingreso de parametros
Retrasos=900;% número de retrasos que que quieran
NumeroNeuronas=10;% se puede cambiar las neuronas
trainFcn = 'trainlm'; %Tipo de entrenamiento inicial...tipo de función de entrenamiento
Ent=80;%% 70% de los datos
Pru=10;%% Pruebas
Val=10;% Validación
    
```

Figura 5.34: Código para ingresar parámetros de la red neuronal.

En la figura 5.35, se visualiza el comportamiento sobre ajustado, por ende, es un modelo donde aprende y predice los datos que ingresan, el cual esto no es deseable, en el entrenamiento se va obtener resultados óptimos pero las pruebas van a ser muy deficientes debido a su complejidad o también llamado alta varianza.




Figura 5.35: Red neuronal en overfitting.

En la figura 5.36, se observa el histograma de error, el mismo que va desde -0,00053 hasta 0,000653, la mayoría concentrándose en valores a -0,00014, se determina que se tiene mal desempeño para esta regresión por un gran número de retrasos, por ende, en este modelo se llega a overfitting.




Figura 5.36: Histograma de error.

En la figura 5.37, se observa la pendiente de regresión, obteniendo un mínimo error, con un resultado del entrenamiento de $R = 0.99026$, siendo un resultado no óptimo para la predicción del caso de estudio presentado.




Figura 5.37: Pendiente de regresión a 45° de la red neuronal (overfitting).

c. Normal fitting.

En la figura 5.36, se verifica que, con los datos históricos ingresados en los parámetros a considerar, tanto el número de retrasos 288, que es aleatorio a cambiar, número de neuronas que son 10, entrenamiento de datos el 80%, de prueba el 10% y de validación el 10% nuestra red neuronal se considera en estado normal fitting, por el motivo que se ingresa datos específicos siendo así el entrenamiento más óptimo para la predicción a corto plazo del caso de estudio planteado.

```

%% Ingreso de parametros
Retrasos=288;% número de retrasos que que quieran
NumeroNeuronas=10;% se puede cambiar las neuronas
trainFcn = 'trainlm'; %Tipo de entrenamiento inicial...tipo de función de entrenamiento
Ent=80;% 70% de los datos
Pru=10;% Pruebas
Val=10;% Validación
%% Entrenamiento red
    
```

Figura 5.38: Código para ingresar parámetros de la red neuronal.

En la figura 5.40, se visualiza el comportamiento del ajuste normal del entrenamiento de la red neuronal, por ende, es un modelo donde analiza toda la información ingresada de una forma correcta, el cual mantiene el equilibrio entre el sesgo y la varianza, siendo así el más deseable y acertado para el caso de estudio planteado.




Figura 5.39: Red neuronal en normal fitting (ajuste normal).

En la figura 5.41, se observa el histograma de error, el mismo que va desde -0,00042 hasta 0,000444, la mayoría concentrándose en valores a $1,22 \cdot 10^{-5}$, justificando un buen funcionamiento de la predicción de la demanda de energía eléctrica a corto plazo planteado en este proyecto de investigación.




Figura 5.40: Histograma de error

En la figura 5.42, se observa la pendiente de regresión, obteniendo un mínimo error, con un resultado del entrenamiento de $R = 0.98682$, siendo un resultado óptimo y correcto, para la predicción del caso de estudio presentado.




Figura 5.41: Pendiente de regresión a 45° de la red neuronal (ajuste normal).

5.6. PREDICCIÓN DE LA DEMANDA ELÉCTRICA

El correcto diseño de una red neuronal artificial es desarrollado mediante la comparación de diferentes configuraciones propuestas por el diseñador, para seleccionar la red que mejores resultados proporcione a la predicción de la demanda de energía eléctrica, es por ello que a continuación se presentan y comparan diferentes configuraciones de redes neuronales artificiales, las diferencias entre las redes neuronas artificiales son: tipo de algoritmo de entrenamiento, número de neuronas y número de retrasos de tiempo. La herramienta computacional desarrollada en el presente proyecto de titulación ingresa como dato de entrada la demanda histórica de energía eléctrica del Alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo, mismas que fueron proporcionados por la empresa eléctrica de Ambato.

5.6.1. Variación del algoritmo de entrenamiento

Matlab cuenta con tres tipos de algoritmos de entrenamiento: levenberg-marquardt (LM), bayesia regularization (BR) y scaled conjugate gradient (SCG). Para este caso se mantiene constante los parámetros de número de neuronas (15) y número de retrasos de tiempo (288). En la tabla 5.5, se presenta los resultados de rendimiento obtenidos para cada algoritmo de entrenamiento, de igual manera en la figura 5.40, se visualiza gráficamente los resultados de la predicción de la demanda de energía eléctrica (resultados numéricos Anexo B.1) para la última semana del mes de marzo del año 2021.

Tabla 5.5: Resultados variación algoritmo de entrenamiento de la red neuronal

Tipo de algoritmo	Rendimiento
LM	1.104×10^{-7}
BR	5.317×10^{-8}
SCG	2.948×10^{-7}




Figura 5.42: Resultados variación algoritmo de entrenamiento de la red neuronal

Acorde a los resultados presentados el algoritmo de entrenamiento que mejores resultados proporcionó para la predicción de la demanda de energía eléctrica es el denominado levenberg-marquardt (LM).

5.6.2. Variación del número de neuronas

El segundo parámetro a analizar es el número de neuronas que conforma la red neuronal artificial, en este caso los parámetros que permanecen constante son: tipo de algoritmo de entrenamiento (levenberg-marquardt) y numero de retrasos de tiempo (288). En la tabla 5.6, se presenta los resultados de rendimiento obtenidos para cada caso propuesto y en la figura 5.41 se visualiza gráficamente los resultados de la predicción de la demanda de energía eléctrica (resultados numéricos anexo B) para la última semana del mes de marzo del año 2021.

Tabla 5.6: Resultados variación número de neuronas

Número de neuronas	Rendimiento
1	1.326×10^{-7}
3	1.046×10^{-7}
5	1.054×10^{-7}
10	1.01×10^{-7}
15	8.82×10^{-8}




Figura 5.43: Resultados variación número de neuronas

Acorde a los resultados presentados el número de neuronas en la red neuronal artificial que mejores resultados proporcionó para la predicción de la demanda de energía eléctrica es de 10 neuronas.

5.6.3. Variación del número de retrasos de tiempo

El tercer parámetro a analizar es el número de retrasos de tiempo que conforma la red neuronal artificial, en este caso los parámetros que permanecen constante son: tipo de algoritmo de entrenamiento (levenberg-marquardt) y numero de neuronas (10). En la tabla 5.7, se presenta los resultados de rendimiento obtenidos para cada caso propuesto y en la figura 5.42, se visualiza gráficamente los resultados de la predicción de la demanda de energía eléctrica (resultados numéricos anexo C) para la última semana del mes de marzo del año 2021.

Tabla 5.7: Resultados variación número de neuronas

Número de retrasos de tiempo	Rendimiento
12	2.777×10^{-7}
24	1.773×10^{-7}
72	1.136×10^{-7}
144	1.067×10^{-7}
288	8.82×10^{-8}




Figura 5.44: Resultados variación número de neuronas

Acorde a los resultados presentados el número de retrasos de tiempo en la red neuronal artificial que mejores resultados proporcionó para la predicción de la demanda de energía eléctrica es de 288 retrasos.

6. CONCLUSIONES Y RECOMENDACIONES

6.1. CONCLUSIONES

- Al realizar el estudio investigativo en literaturas científicas 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. Para este proyecto de investigación la red neuronal artificial está compuesta por una capa de entrada, una capa oculta (función de activación tangente hiperbólico) y una capa de salida (función de activación lineal). Los parámetros que se configuran son: el tipo de algoritmo de entrenamiento, número de neuronas de la capa oculta y número de retrasos de tiempo.
- A partir de los datos de la demanda de energía eléctrica del alimentador PRI12 - Sta. Rosa de Pichul - San Gerardo, del último periodo del mes de marzo del año 2021 a la semana siguiente del mes de abril del mismo año, que corresponden a 7 días, se puede afirmar que el modelo generado a partir del método de redes neuronales artificiales, presenta el mayor ajuste al comportamiento de la serie de datos con un error porcentual del 1,60 %, puesto que obtenemos un valor muy bajo, con este modelo se establece el pronóstico a una semana, finalmente en base de las curvas estadísticas de los valores reales y pronosticados se obtiene un error del 0,99%.
- Se desarrollo una herramienta computacional en Matlab, por medio de la interfaz gráfica (GUIDE) que permite predecir la demanda de energía eléctrica a corto plazo, utilizando la red neuronal artificial, mediante el manejo del 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 se obtuvo un rendimiento del 1.01×10^{-7} , mediante resultados pronosticados así proporcionando un acercamiento a los datos reales.

6.2. RECOMENDACIONES

- En el presente proyecto de titulación se trabajó únicamente con los datos históricos de la demanda de energía eléctrica, se recomienda incluir más variables que pueden afectar a la demanda de energía eléctrica como lo son: clima y día de la semana
- La herramienta computacional fue desarrollada en Matlab, a pesar de ser uno de los softwares más sofisticados requiere de licencias que muchas veces las empresas públicas no pueden costear, se recomienda realizar la presente aplicación en un software libre como lo puede ser Python.
- Las redes neuronales artificiales es un pequeño campo de la inteligencia artificial, se recomienda predecir la demanda de energía eléctrica en base a otros campos de la inteligencia artificial, para su comparación con la usada en el presente proyecto de titulación.

7. BIBLIOGRAFÍA

- [1] M. E. O. Alvarado, «Pronóstico de la Demanda Eléctrica Residencial Basado en el Modelo de Regresión Adaptativa Multivariante Spline (MARS),» Universidad Politécnica Salesiana, Quito, 2015.
- [2] A. F. M. Vega, «Predicción de la Demanda de Energía Eléctrica en la Producción de Petróleo de los Campos de Petroamazonas EP Utilizando Redes Neuronales Artificiales,» Universidad Politécnica Nacional, Quito, 2020.
- [3] L. F. G. Peña, «Proyección de la Demanda de Energía Eléctrica a Corto Plazo, Mediante Redes Neuronales Artificiales,» Escuela Superior Politécnica del Litoral, Guayaquil, 2016.
- [4] T. Gönen, «Electric Power Distribution Engineering,» Taylor & Francis Group, LLC, New York, 2014.
- [5] S. Ramirez Castaño, Redes de Distribucion de Energia, Colombia: Centro de Publicaciones Universidad Nacional de Colombia , 2004.
- [6] ARCONEL, «Pliego tarifario para las empresas eléctricas de distribución codificado,» Resolución Nro. ARCONEL - 002/19, 2019; Resolución Nro. ARCONEL - 050/18, 2018, Quito, 2019.
- [7] J. Juárez, Sistemas de distribución de energía eléctrica, México: Azcapotzalco, 1995.
- [8] V. Simbaña, «Optimización mediante el método Montecarlo de la demanda eléctrica,» Ecuador: Universidad politécnica salesiana, Quito, 2015.
- [9] A. Hernandez y C. Sebasti, «Análisis de la curva de demanda eléctrica para usuarios residenciales estrato 4 en la ciudad de Bogotá ante diferentes escenarios de los hábitos de consumo,» Universidad Distrital Francisco José de Caldas, Bogotá, 2017.
- [10] X. Segura, «Estudio y gestión de la demanda eléctrica,» Quito, 2013.
- [11] F. Monobanda, «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, 2020.

- [12] G. Enriquez, *El ABC del alumbrado y las instalaciones eléctricas en baja tensión*, México: Limusa, 2004.
- [13] J. Ringwood, «Intelligent Forecasting of Electricity Demand,» Department of Electronic Engineering, Maynooth, Department of Electronic Engineering NUI Maynooth.
- [14] S. Avdaković, E. Bećirović, N. Hasanspahić, M. Musić, A. Merzić, A. Tuhčić y J. Karadža, «Long-term forecasting of energy, electricity and active power demanda - Bosnida and Herzegovina case study,» *BALKAN JOURNAL OF ELECTRICAL & COMPUTER ENGINEERING*, vol. 3, n° 1, pp. 11 - 16, 2015.
- [15] L. d. P. H. Orbea, «Pronostico de la demanda utilizando inteligencia artificial,» Escuela Politécnica Nacional, Quito, 2007.
- [16] «Rincon educativo,» [En línea]. Available: <https://www.rinconeducativo.org/es/recursos-educativos/la-planificacion-energetica-en-espana>. [Último acceso: 25 05 2021].
- [17] F. Elakrmi y N. Abu Shikhah, «Electricity Load Forecasting - Science and Practice,» Universidad de Amman, Ammán.
- [18] V. Gupta y S. Pal, «An Overview of Different Types of Load Forecasting Methods and the Factors Affecting the V,» *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, vol. 5, n° IV, pp. 729 - 733, 2017.
- [19] L. D. Q. Villacís, «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, 2017.
- [20] M. Al Mamun y K. Nagasaka, «Artificial Neural Networks Applied to Long-term Electricity Demand Forecasting,» Department of Electrical and Electronics Engineering, Tokyo, 2005.
- [21] Y. Garcia, «Predicción de la Demanda Eléctrica empleando Redes Neuronales Artificiales,» Universidad Central “Marta Abreu” de Las Villas, Santa Clara, 2009.
- [22] P. Bunnoon, K. Charlermyanont y C. Limsakul, «Mid-Term Load Forecasting Based on Neural Network,» *Revista Internacional de Ingeniería Informática y Eléctrica*, vol. 3, n° 4, pp. 600-605, 2011.

- [23] B. Bowerman, R. O'Connell, A. Koehler y M. Balderas, Pronósticos, series de tiempo y regresión : un enfoque aplicado, México: Cengage Learning, 2007.
- [24] S. Russell y P. Norving, Inteligencia Artificial un Enfoque Moderno, Madrid: PEARSON Prentice Hall, 2004.
- [25] P. Ponce, Inteligencia Artificial con Aplicaciones a la Ingeniería, México: Alfaomega, 2010.
- [26] P. Isasi Viñuela y I. Galván León, «Redes Neuronales Artificiales - Un enfoque practico,» PEARSON EDUCACIÓN S.A., Madrid, 2004.
- [27] J. Fernández Fernández y R. Flórez López, Las redes neuronales artificiales : fundamentos teóricos y aplicaciones prácticas, La Coruña: Netbiblo S.L., 2008.
- [28] J. R. Hilera González y V. J. Martínez Hernand, Redes Neuronales Artificiales: Fundamentos,, Madrid: Alfa Omega-Ram, 2000.
- [29] D. J. Matich, «Redes Neuronales: Conceptos Básicos y Aplicaciones,» Universidad Tecnológica Nacional, Rosario, 2001.
- [30] B. Martín del Brio y A. Sanz Molina, Redes neuronales y sistemas difusos, Ciudad de Mexico: Alfaomega, 2020.
- [31] S. Amakali, «Development of models for short-term load forecasting using artificial neural networks,» Cape Peninsula University of Technology, Ciudad del Cabo, 2008.
- [32] A. Requena, R. Quintanilla, J. Bolarín, A. Vázquez, A. Bastida, J. Zúñiga y L. Tomás, «Equivalencia entre redes artificiales y biológicas,» *Nuevas Tecnologías y Contaminación de Atmósferas, para PYMEs*, vol. VI, nº 4, p. 3, 2019.
- [33] L. F. Bertona, «Entrenamiento de redes neuronales basado en algoritmos evolutivos,» Universidad de Buenos Aires, Buenos Aires, 2005.
- [34] Hartono, A. M. Ahmad y M. Sadikin, «Comparison methods of short term electrical load forecasting,» EDP Sciences, 2018.
- [35] A. Repeteur, «Redes Neuronales Artificiales,» Universidad Nacional del Centro de la Provincia de Buenos Aires, Tandil, 2019.

- [36] C. Juan Carlos, «Aplicación de modelos de redes neuronales a la predicción de la fiebre,» Universidad Politécnica de Madrid, Madrid, 2019.
- [37] B. Juan, «Qué es overfitting y underfitting y cómo solucionarlo,» Aprende Machine Learning, Buenos Aires, 2017.
- [38] P. Bunnoon, K. Chalermyanont y C. Limsakul, «A Computing Model of Artificial Intelligent Approaches to Mid-term Load Forecasting: a state-of-the-art- survey for the researcher,» *IACSIT*, vol. 2, n° 1, pp. 94-100, 2010.

ANEXOS

8. ANEXOS

Tabla A.1: Tipo de transformadores eléctricos instalados en el alimentador San Rosa de Pichul – San Gerardo.

CANTIDAD	TIPOS DE TRANSFORMADORES				TIPOS DE TRANSFORMADORES	
3	TRANSFORMADOR	1A5T		11	TRANSFORMADOR	1C15T
	TIPO	MONOFÁSICO			TIPO	MONOFÁSICO
	VALORES NOMINALES	5,00 KVA			VALORES NOMINALES	15,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
2	TRANSFORMADOR	1C5T		1	TRANSFORMADOR	3C15T
	TIPO	MONOFÁSICO			TIPO	TRIFÁSICO ACOLUMNAS
	VALORES NOMINALES	5,00 KVA			VALORES NOMINALES	15,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
19	TRANSFORMADOR	1A10T		38	TRANSFORMADOR	1A25T
	TIPO	MONOFÁSICO			TIPO	MONOFÁSICO
	VALORES NOMINALES	10,00 KVA			VALORES NOMINALES	25,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
18	TRANSFORMADOR	1C10T		25	TRANSFORMADOR	1C25T
	TIPO	MONOFÁSICO			TIPO	MONOFÁSICO
	VALORES NOMINALES	10,00 KVA			VALORES NOMINALES	25,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
30	TRANSFORMADOR	1A15T		6	TRANSFORMADOR	1P25T
	TIPO	MONOFÁSICO			TIPO	MONOFÁSICO
	VALORES NOMINALES	15,00 KVA			VALORES NOMINALES	25,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
22	TRANSFORMADOR	3C30T		2	TRANSFORMADOR	1C50T
	TIPO	TRIFÁSICO A COLUMNAS			TIPO	MONOFÁSICO
	VALORES NOMINALES	30,00 KVA			VALORES NOMINALES	50,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
22	TRANSFORMADOR	1A37,5T		10	TRANSFORMADOR	3C50T
	TIPO	MONOFÁSICO			TIPO	TRIFÁSICO A COLUMNAS
	VALORES NOMINALES	37,50 KVA			VALORES NOMINALES	50,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
23	TRANSFORMADOR	1C37,5T		15	TRANSFORMADOR	3C75T
	TIPO	MONOFÁSICO			TIPO	TRIFÁSICO A COLUMNAS
	VALORES NOMINALES	37,50 KVA			VALORES NOMINALES	75,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
12	TRANSFORMADOR	3C45T		4	TRANSFORMADOR	3C100T
	TIPO	TRIFÁSICO A COLUMNAS			TIPO	TRIFÁSICO A COLUMNAS
	VALORES NOMINALES	45,00 KVA			VALORES NOMINALES	100,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
5	TRANSFORMADOR	1A50T		1	TRANSFORMADOR	3C125T
	TIPO	MONOFÁSICO			TIPO	TRIFÁSICO A COLUMNAS
	VALORES NOMINALES	50,00 KVA			VALORES NOMINALES	125,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
1	TRANSFORMADOR	3C150T		2	TRANSFORMADOR	3O300T
	TIPO	TRIFÁSICO A COLUMNAS			TIPO	TRIFÁSICO A COLUMNAS
	VALORES NOMINALES	150,00 KVA			VALORES NOMINALES	300,00 KVA
		13,80 KV/0,24 KV				13,80 KV/0,24 KV
1	TRANSFORMADOR	3O150T		TOTAL		
	TIPO	TRIFÁSICO A COLUMNAS		174	TRANSFORMADORES MONOFÁSICOS	
	VALORES NOMINALES	150,00 KVA		69	TRANSFORMADORES TRIFÁSICOS	
		13,80 KV/0,24 KV				

Anexo B: Resultados de la predicción de la demanda de energía eléctrica variando el tipo de algoritmo de entrenamiento.

Tabla B.1: Resultados de la predicción de la demanda de energía eléctrica variando el tipo de algoritmo de entrenamiento

Año	Mes	Dia	Hora	Demanda Real	Demanda Calculada			Error predicción		
					LM	BR	SCG	LM	BR	SCG
2021	3	26	0	1371,526143	1329,90156	1407,12312	1328,85448	3,0349101	-2,59542803	3,11125402
2021	3	26	1	1533,046244	1487,81461	1697,68836	1520,77005	2,95044141	-10,7395398	0,80077152
2021	3	26	2	1717,446859	1609,18182	2076,52251	1702,62433	6,30383617	-20,9075265	0,86305593
2021	3	26	3	1836,932678	1673,52743	2154,15141	1762,30768	8,89554904	-17,268936	4,06247864
2021	3	26	4	1967,222351	1733,81517	2009,70186	1772,94222	11,8648094	-2,15936508	9,87586019
2021	3	26	5	2052,506409	1821,87285	1916,17328	1884,84169	11,236679	6,64227521	8,16877911
2021	3	26	6	2051,651225	1778,9473	1844,45504	1799,9699	13,2919244	10,0989964	12,267257
2021	3	26	7	1775,787537	1632,63693	1650,77936	1603,98981	8,06124619	7,03959095	9,67445278
2021	3	26	8	1698,76359	1636,98767	1605,06313	1572,3624	3,63652267	5,51580315	7,44077556
2021	3	26	9	1755,181986	1705,62657	1623,18015	1619,34719	2,82337776	7,52069241	7,73907165
2021	3	26	10	1725,077759	1585,81789	1540,57089	1591,6421	8,07267205	10,6955681	7,73505175
2021	3	26	11	1575,958862	1494,58327	1478,01126	1564,71794	5,16356081	6,21511131	0,71327483
2021	3	26	12	1452,331726	1425,17244	1437,27736	1520,99583	1,87004714	1,03656493	-4,72785238
2021	3	26	13	1339,537944	1321,23865	1335,7155	1506,55784	1,36609025	0,28535565	-12,4684705
2021	3	26	14	1374,46934	1382,83403	1302,3403	1482,14158	-0,60857566	5,24777357	-7,83373157
2021	3	26	15	1437,156067	1398,74508	1279,56974	1423,01244	2,67270801	10,9651507	0,98413966
2021	3	26	16	1385,195984	1418,04311	1315,17829	1444,85351	-2,37129786	5,05471406	-4,30679345
2021	3	26	17	1417,204915	1385,78787	1358,39586	1430,10693	2,21683139	4,14965116	-0,91038446

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	26	18	1671,532552	1656,90262	1647,27958	1771,20219	0,87524037	1,45094238	-5,96276974
2021	3	26	19	2019,452087	2032,40569	1999,7207	2069,41354	-0,64144153	0,97706625	-2,4740103
2021	3	26	20	1916,633993	1950,25742	1879,33421	1962,53299	-1,75429584	1,94610894	-2,39477117
2021	3	26	21	1758,286987	1737,13078	1688,79537	1810,09816	1,20322824	3,95223422	-2,94668444
2021	3	26	22	1515,200521	1502,46174	1477,93045	1614,22384	0,84073239	2,45974486	-6,5353277
2021	3	26	23	1367,309225	1353,55631	1349,22772	1467,97837	1,00583757	1,32241509	-7,36257319
2021	3	27	0	1397,469605	1318,42689	1366,53646	1419,27718	5,65613123	2,21351103	-1,56050445
2021	3	27	1	1479,088339	1409,03376	1423,99092	1541,30156	4,73633521	3,72509343	-4,20618695
2021	3	27	2	1525,176026	1460,56044	1381,1511	1694,67049	4,23659832	9,44316723	-11,1131085
2021	3	27	3	1601,815328	1514,20997	1392,39755	1806,33985	5,46912951	13,073778	-12,7682962
2021	3	27	4	1653,173279	1556,2724	1373,15713	1780,91699	5,86150786	16,9381002	-7,72718198
2021	3	27	5	1724,427836	1656,00289	1519,38069	1826,43358	3,96797994	11,890735	-5,91533827
2021	3	27	6	1615,822083	1562,99702	1423,85886	1662,77784	3,26923772	11,8802201	-2,9059979
2021	3	27	7	1422,946493	1395,03813	1354,4762	1430,49759	1,96130807	4,81186701	-0,53066655
2021	3	27	8	1415,026794	1385,92594	1270,99645	1405,28796	2,05655872	10,1786302	0,68824414
2021	3	27	9	1465,670573	1420,08959	1282,96431	1479,82529	3,10990637	12,4657112	-0,96575036
2021	3	27	10	1408,622762	1369,8867	1276,6436	1471,15481	2,7499242	9,3693758	-4,439233
2021	3	27	11	1384,049032	1322,84365	1274,34391	1464,42214	4,42219735	7,92638996	-5,80709963
2021	3	27	12	1303,735718	1288,11536	1267,49032	1454,6567	1,19812319	2,78011813	-11,5760408
2021	3	27	13	1258,392477	1214,5322	1222,86488	1412,79607	3,48542121	2,82325216	-12,2699074
2021	3	27	14	1267,092367	1230,92936	1208,5528	1338,9231	2,85401481	4,61999201	-5,66894228
2021	3	27	15	1240,86558	1192,73945	1195,72394	1251,66901	3,87843258	3,63791535	-0,87063635

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	27	16	1227,013245	1189,91048	1229,15119	1202,99028	3,02382771	-0,17423992	1,95784083
2021	3	27	17	1269,380595	1164,02357	1190,61335	1203,26656	8,29987677	6,2051716	5,2083695
2021	3	27	18	1622,594198	1437,00203	1470,31461	1476,08801	11,4379904	9,38494579	9,02913321
2021	3	27	19	1926,496521	1820,63579	1885,96157	1824,29335	5,49498675	2,10407621	5,30513144
2021	3	27	20	1826,272095	1769,40217	1792,85595	1744,60289	3,11398954	1,82974621	4,47190779
2021	3	27	21	1713,500366	1606,60261	1619,53647	1529,59707	6,23856045	5,4837394	10,7326089
2021	3	27	22	1467,172038	1401,05538	1407,48867	1306,15668	4,50640127	4,06791872	10,9745386
2021	3	27	23	1292,1085	1207,27855	1245,75368	1135,39632	6,56523452	3,58753347	12,128407
2021	3	28	0	1136,343506	1057,64842	1132,57813	1077,19164	6,92529038	0,33135865	5,20545625
2021	3	28	1	1044,309814	1038,80027	1130,92462	1051,95118	0,52757729	-8,2939763	-0,73171443
2021	3	28	2	1036,077942	1010,22476	1142,38806	1097,4967	2,49529293	-10,2608228	-5,92800524
2021	3	28	3	1045,388652	997,021904	1161,9624	1100,3423	4,62667612	-11,1512354	-5,25676764
2021	3	28	4	1031,99232	978,395681	1116,55156	1069,67697	5,19351142	-8,19378578	-3,65164016
2021	3	28	5	1082,210673	1022,7808	1112,33263	1135,93661	5,49152579	-2,78337305	-4,96446217
2021	3	28	6	973,2938943	907,871408	947,419572	1097,78027	6,72176072	2,65842856	-12,7902144
2021	3	28	7	917,1438903	893,812388	838,353826	1022,75192	2,54393042	8,59080727	-11,5148811
2021	3	28	8	1043,535604	1010,16753	952,437925	1126,96556	3,19759837	8,72971452	-7,99493127
2021	3	28	9	1137,705261	1111,30966	1046,23482	1244,9045	2,3200737	8,0399064	-9,4224088
2021	3	28	10	1143,460429	1115,38575	1089,3772	1369,77628	2,45523846	4,72978543	-19,7921892
2021	3	28	11	1112,451925	1123,16886	1094,97554	1391,67474	-0,96336178	1,57097851	-25,0997649
2021	3	28	12	1100,316956	1105,71353	1041,18372	1417,21692	-0,49045667	5,37420057	-28,800789
2021	3	28	13	1059,523946	1079,81726	1013,04347	1360,30492	-1,91532351	4,38692095	-28,3883133

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	28	14	1055,363119	1074,76979	964,867134	1253,0305	-1,83886246	8,57486704	-18,7297982
2021	3	28	15	1034,596598	1033,65965	940,017523	1157,53707	0,09056179	9,14163799	-11,8829382
2021	3	28	16	1039,026845	1054,98872	930,564497	1102,03626	-1,53623266	10,4388398	-6,06427222
2021	3	28	17	1100,619059	1090,10712	999,029972	1090,93458	0,95509373	9,23017699	0,87991182
2021	3	28	18	1441,921265	1435,80612	1396,52897	1380,94389	0,42409695	3,14804285	4,22889742
2021	3	28	19	1893,08724	1826,5955	1730,47143	1766,79023	3,51234443	8,58997995	6,67148409
2021	3	28	20	1800,839437	1759,61319	1739,57589	1773,3265	2,2892797	3,40194369	1,52778404
2021	3	28	21	1651,498535	1582,82953	1597,34703	1602,03976	4,15798133	3,27893118	2,99478166
2021	3	28	22	1408,059102	1348,73999	1386,37097	1317,53878	4,2128283	1,54028532	6,42873001
2021	3	28	23	1228,863993	1161,52885	1198,43521	1186,0412	5,47946278	2,47617184	3,48474653
2021	3	29	0	1132,45284	1022,36513	1079,32297	1104,91287	9,72117371	4,69157458	2,4318868
2021	3	29	1	1137,419352	1007,66432	1123,96987	1074,13058	11,4078444	1,1824557	5,56424238
2021	3	29	2	1153,273906	1036,27147	1165,74427	1121,38712	10,1452428	-1,08130156	2,7648927
2021	3	29	3	1154,568522	1054,8747	1192,19562	1199,19777	8,63472549	-3,25897509	-3,86544812
2021	3	29	4	1189,858032	1083,8971	1190,66986	1228,34456	8,90534278	-0,06822892	-3,23454824
2021	3	29	5	1293,47526	1185,14499	1172,36859	1374,66672	8,37513244	9,36289014	-6,27700162
2021	3	29	6	1311,260783	1173,59666	1079,2974	1344,79491	10,4986074	17,6901032	-2,55739609
2021	3	29	7	1312,983968	1151,51793	1105,37113	1246,66456	12,2976398	15,8122907	5,05104449
2021	3	29	8	1330,878316	1218,96237	1157,09101	1343,91946	8,40917941	13,0580913	-0,97988987
2021	3	29	9	1370,835165	1297,99692	1214,87803	1434,96409	5,31342132	11,3767971	-4,67809147
2021	3	29	10	1437,684326	1328,13389	1268,23995	1465,47327	7,61992286	11,7859235	-1,93289603
2021	3	29	11	1487,041565	1320,84797	1324,47867	1491,70947	11,1761229	10,9319669	-0,31390529

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	29	12	1407,080546	1327,09779	1311,78524	1417,07334	5,68430566	6,77255543	-0,71017931
2021	3	29	13	1287,380493	1278,71471	1204,79021	1381,20617	0,67313288	6,41537486	-7,28810741
2021	3	29	14	1312,204163	1280,88792	1212,16411	1343,74826	2,38653756	7,62381797	-2,40390139
2021	3	29	15	1367,229411	1256,92261	1240,93662	1319,49697	8,06790759	9,2371325	3,49118019
2021	3	29	16	1452,066996	1283,338	1243,73105	1354,8448	11,6199181	14,3475437	6,69543432
2021	3	29	17	1319,217021	1253,30285	1225,25288	1409,86509	4,99646164	7,12272042	-6,87135362
2021	3	29	18	1613,761393	1527,95043	1508,54459	1696,04835	5,31745071	6,51997295	-5,09907845
2021	3	29	19	2051,170817	1950,13431	1920,1695	2091,7776	4,92579679	6,38666073	-1,9796878
2021	3	29	20	1960,377136	1900,75976	1888,2052	2036,69657	3,04111781	3,68153321	-3,89309982
2021	3	29	21	1750,071696	1730,89504	1692,1771	1844,48353	1,09576377	3,30812722	-5,39474109
2021	3	29	22	1495,691915	1461,88147	1456,13147	1515,09499	2,26052199	2,64495928	-1,29726441
2021	3	29	23	1320,844259	1286,2374	1311,31677	1350,45979	2,6200561	0,72131805	-2,24216645
2021	3	30	0	1283,288106	1215,02742	1229,27326	1277,58626	5,31920203	4,20909758	0,44431536
2021	3	30	1	1403,224589	1292,24608	1333,33489	1302,64406	7,90882015	4,98064981	7,16781433
2021	3	30	2	1518,563314	1428,47146	1444,26161	1403,89848	5,9327034	4,89289461	7,55087618
2021	3	30	3	1579,962911	1518,0531	1553,07079	1511,19631	3,91843473	1,70207313	4,35241861
2021	3	30	4	1563,207743	1570,11007	1599,37084	1563,44873	-0,44154902	-2,31339028	-0,01541647
2021	3	30	5	1675,624736	1686,24466	1629,4853	1652,03098	-0,63378886	2,75356633	1,40805697
2021	3	30	6	1610,214274	1700,92477	1505,96948	1583,75889	-5,63344261	6,47397002	1,64297274
2021	3	30	7	1504,144572	1582,74945	1425,19759	1467,79549	-5,2258855	5,24863024	2,41659485
2021	3	30	8	1552,595683	1588,43164	1460,67591	1496,70422	-2,30813226	5,92039326	3,5998725
2021	3	30	9	1664,058106	1658,182	1569,26738	1544,50562	0,35311896	5,69635921	7,18439381

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	30	10	1586,422343	1611,65724	1529,50226	1526,95726	-1,59067956	3,58795274	3,74837634
2021	3	30	11	1494,839742	1545,77322	1483,45676	1496,99201	-3,40728672	0,76148485	-0,1439798
2021	3	30	12	1496,293396	1464,98014	1403,77664	1394,10488	2,09272139	6,18306237	6,82944361
2021	3	30	13	1347,065369	1378,03432	1276,02787	1318,13114	-2,29899384	5,27350064	2,14794569
2021	3	30	14	1360,735637	1388,8375	1294,57967	1304,54339	-2,0651965	4,86177981	4,12954902
2021	3	30	15	1448,706482	1400,9803	1305,00341	1279,30312	3,29439964	9,91940594	11,6934216
2021	3	30	16	1383,498189	1411,28428	1305,15893	1314,13995	-2,00839404	5,66240442	5,0132515
2021	3	30	17	1376,996318	1372,23155	1269,95024	1354,178	0,34602592	7,77388267	1,65710814
2021	3	30	18	1690,967997	1646,15361	1581,22884	1674,86296	2,65022111	6,48972404	0,95241501
2021	3	30	19	2072,706543	2032,2962	1956,07346	2036,79186	1,94964122	5,62709114	1,73274344
2021	3	30	20	1965,76239	1985,61063	1879,81456	2013,68069	-1,0096969	4,37223879	-2,43764443
2021	3	30	21	1780,814738	1772,52926	1681,25719	1826,11389	0,46526314	5,59056194	-2,54373162
2021	3	30	22	1511,643677	1501,85524	1451,18948	1539,25247	0,64753608	3,99923564	-1,82640874
2021	3	30	23	1300,410604	1341,87242	1267,76798	1342,79822	-3,18836327	2,51017853	-3,25955633

Anexo C: Resultados de la predicción de la demanda de energía eléctrica variando el número de neuronas

Tabla C.1: Resultados de la predicción de la demanda de energía eléctrica variando el número de neuronas

Año	Mes	Dia	Hora	Demanda Real	Numero de neuronas				
					1	3	5	10	15
2021	3	26	0	1371,526143	1347,40156	1355,71928	1350,40923	1358,90396	1379,99924
2021	3	26	1	1533,046244	1529,34169	1541,54753	1525,16907	1532,1096	1554,4831
2021	3	26	2	1717,446859	1677,17597	1703,84206	1654,95204	1668,03746	1678,2216
2021	3	26	3	1836,932678	1782,65972	1765,34196	1725,22291	1769,22486	1704,90777
2021	3	26	4	1967,222351	1861,32047	1817,8286	1783,27674	1849,68867	1743,10018
2021	3	26	5	2052,506409	1945,38829	1909,86011	1887,15166	1937,07224	1834,19803
2021	3	26	6	2051,651225	1865,73433	1845,40143	1833,19383	1871,23085	1802,898
2021	3	26	7	1775,787537	1667,75368	1621,35008	1633,65326	1686,0104	1629,82142
2021	3	26	8	1698,76359	1663,11294	1604,01215	1624,39045	1660,37835	1618,85171
2021	3	26	9	1755,181986	1754,00045	1699,33105	1737,68491	1748,09341	1695,10795
2021	3	26	10	1725,077759	1680,3969	1575,3269	1641,34653	1651,85446	1604,53223
2021	3	26	11	1575,958862	1605,5125	1506,98955	1557,45441	1546,21472	1534,22456
2021	3	26	12	1452,331726	1530,33412	1426,39535	1483,78169	1464,84619	1451,02531
2021	3	26	13	1339,537944	1430,28806	1333,36444	1380,71382	1346,14674	1346,54571
2021	3	26	14	1374,46934	1507,84299	1380,87634	1414,60327	1363,24872	1373,06832
2021	3	26	15	1437,156067	1456,97881	1348,09795	1389,75273	1350,82303	1389,57384
2021	3	26	16	1385,195984	1451,11916	1373,33496	1412,12362	1372,99484	1421,02915
2021	3	26	17	1417,204915	1427,10251	1380,66167	1403,97302	1366,59607	1445,33269

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	26	18	1671,532552	1706,04306	1701,01212	1705,08782	1668,12893	1757,72497
2021	3	26	19	2019,452087	2040,15383	2042,53823	2047,10997	2009,86421	2061,39592
2021	3	26	20	1916,633993	1955,43799	1950,41059	1950,77684	1939,87013	2013,6624
2021	3	26	21	1758,286987	1748,57631	1741,0569	1742,4448	1746,45006	1847,06445
2021	3	26	22	1515,200521	1523,98881	1481,92594	1517,82722	1524,1702	1602,71214
2021	3	26	23	1367,309225	1394,13961	1333,07192	1372,28139	1376,15281	1437,77034
2021	3	27	0	1397,469605	1374,79474	1320,77831	1373,12253	1375,94942	1422,13143
2021	3	27	1	1479,088339	1472,59327	1431,37639	1494,74395	1509,72741	1532,27163
2021	3	27	2	1525,176026	1569,81414	1525,11889	1571,02411	1593,28651	1591,37638
2021	3	27	3	1601,815328	1627,35561	1570,03343	1624,51086	1659,51992	1609,34714
2021	3	27	4	1653,173279	1675,0347	1624,64473	1655,95071	1721,31541	1637,7086
2021	3	27	5	1724,427836	1748,65943	1719,90615	1736,99672	1816,504	1717,60967
2021	3	27	6	1615,822083	1632,42881	1610,34807	1611,75537	1694,24401	1577,26581
2021	3	27	7	1422,946493	1432,61337	1407,90029	1405,02541	1466,83609	1406,6251
2021	3	27	8	1415,026794	1451,23723	1402,72702	1380,28274	1400,51357	1379,06879
2021	3	27	9	1465,670573	1519,84624	1434,98024	1382,54243	1404,70677	1375,20542
2021	3	27	10	1408,622762	1467,56396	1371,94614	1336,02703	1344,10268	1329,77191
2021	3	27	11	1384,049032	1413,1845	1310,1116	1292,91973	1316,09773	1298,2541
2021	3	27	12	1303,735718	1361,5754	1258,76942	1237,43774	1276,11293	1272,64833
2021	3	27	13	1258,392477	1282,97843	1198,69453	1153,74336	1192,29189	1206,51386
2021	3	27	14	1267,092367	1281,47459	1184,84684	1164,47891	1187,45877	1186,1275
2021	3	27	15	1240,86558	1208,96212	1147,43811	1134,00836	1187,96817	1184,96692

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	27	16	1227,013245	1211,57688	1152,65814	1141,54355	1226,31218	1168,65402
2021	3	27	17	1269,380595	1173,40652	1155,63535	1123,89796	1212,03297	1140,52754
2021	3	27	18	1622,594198	1470,80769	1493,36054	1443,29011	1520,77565	1442,35128
2021	3	27	19	1926,496521	1850,45834	1839,53678	1830,43567	1886,2916	1823,61731
2021	3	27	20	1826,272095	1797,45164	1804,87741	1774,6733	1818,75835	1781,38863
2021	3	27	21	1713,500366	1602,14966	1650,33422	1613,62418	1659,26286	1627,20371
2021	3	27	22	1467,172038	1345,41845	1398,57858	1376,47806	1421,24957	1413,22012
2021	3	27	23	1292,1085	1172,49841	1219,93484	1178,38287	1251,06911	1240,47929
2021	3	28	0	1136,343506	1064,48301	1096,15999	1043,55788	1118,96651	1096,91508
2021	3	28	1	1044,309814	1051,49284	1052,40448	998,925009	1086,01119	1024,48109
2021	3	28	2	1036,077942	1052,66437	1007,19576	961,110897	1084,3042	981,418107
2021	3	28	3	1045,388652	1057,84316	997,395171	938,199686	1119,11085	987,685185
2021	3	28	4	1031,99232	1062,68755	983,827498	936,781807	1140,41995	994,897937
2021	3	28	5	1082,210673	1102,49094	1021,98136	971,312617	1157,55627	1039,85239
2021	3	28	6	973,2938943	1017,20063	907,816249	890,584586	1020,94435	888,823732
2021	3	28	7	917,1438903	935,736867	873,077133	883,499087	978,234227	857,830081
2021	3	28	8	1043,535604	1022,37635	969,477902	969,762646	1043,41766	943,479198
2021	3	28	9	1137,705261	1144,38843	1036,93768	1035,37075	1110,47973	1042,43238
2021	3	28	10	1143,460429	1145,89441	1061,74869	1074,75097	1130,58621	1088,5349
2021	3	28	11	1112,451925	1148,51704	1056,97975	1104,47814	1160,73452	1111,02964
2021	3	28	12	1100,316956	1128,3402	1023,19626	1070,93114	1142,12186	1077,94246
2021	3	28	13	1059,523946	1086,65883	1008,74214	1018,19124	1102,05388	1031,54568

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	28	14	1055,363119	1104,17519	998,600201	1028,01805	1090,11426	1017,31355
2021	3	28	15	1034,596598	1066,2119	981,015411	1004,86854	1094,70957	1014,2471
2021	3	28	16	1039,026845	1071,67841	1004,64877	1036,86051	1117,98221	1017,86753
2021	3	28	17	1100,619059	1085,30823	1076,40007	1085,42063	1169,20117	1074,68825
2021	3	28	18	1441,921265	1417,91093	1419,5532	1427,18471	1526,562	1445,44367
2021	3	28	19	1893,08724	1839,40605	1839,90579	1839,64799	1938,34638	1873,22965
2021	3	28	20	1800,839437	1811,0117	1789,82757	1809,50119	1849,37514	1800,41537
2021	3	28	21	1651,498535	1615,09303	1625,56512	1636,01285	1642,87541	1613,96967
2021	3	28	22	1408,059102	1348,33323	1386,44365	1395,15438	1417,60999	1392,08777
2021	3	28	23	1228,863993	1156,32266	1175,5417	1206,1075	1240,46995	1208,71665
2021	3	29	0	1132,45284	1047,04158	1053,13593	1081,85309	1087,4535	1075,77404
2021	3	29	1	1137,419352	1058,69797	1010,42871	1059,15373	1073,41435	1046,58685
2021	3	29	2	1153,273906	1115,90769	1036,69868	1084,27375	1121,88785	1089,64435
2021	3	29	3	1154,568522	1133,56058	1074,75442	1106,31946	1178,91292	1101,32741
2021	3	29	4	1189,858032	1168,05666	1071,86867	1117,63464	1220,36057	1108,65128
2021	3	29	5	1293,47526	1261,02222	1139,69545	1202,59602	1310,89123	1198,98155
2021	3	29	6	1311,260783	1256,18872	1130,33284	1186,47092	1303,78961	1204,43091
2021	3	29	7	1312,983968	1187,48661	1138,54421	1182,41242	1267,98183	1189,31451
2021	3	29	8	1330,878316	1261,6372	1209,92295	1225,79642	1290,68411	1204,94486
2021	3	29	9	1370,835165	1354,5802	1260,1411	1278,40745	1368,52142	1279,70233
2021	3	29	10	1437,684326	1370,7167	1274,96595	1312,00431	1390,59841	1337,24163
2021	3	29	11	1487,041565	1357,39428	1294,12399	1336,80252	1403,71156	1366,08451

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	29	12	1407,080546	1345,55179	1301,65352	1327,8022	1387,893	1344,71374
2021	3	29	13	1287,380493	1280,50188	1256,14868	1250,34559	1343,49746	1253,17967
2021	3	29	14	1312,204163	1325,51227	1307,49882	1289,06609	1393,67632	1302,52716
2021	3	29	15	1367,229411	1305,94697	1326,86243	1289,68931	1396,28569	1316,55128
2021	3	29	16	1452,066996	1327,6381	1369,59905	1324,16895	1431,2294	1340,36574
2021	3	29	17	1319,217021	1341,4775	1368,25962	1332,31918	1442,45811	1333,79508
2021	3	29	18	1613,761393	1650,32611	1634,69906	1620,88565	1726,18181	1615,1742
2021	3	29	19	2051,170817	2003,76201	2003,51833	1991,95122	2071,10862	1982,60538
2021	3	29	20	1960,377136	1921,27626	1913,64255	1898,81769	1964,28068	1909,54889
2021	3	29	21	1750,071696	1706,03758	1719,56639	1715,68931	1767,55519	1722,06571
2021	3	29	22	1495,691915	1449,85184	1460,4239	1464,26661	1483,41662	1459,92727
2021	3	29	23	1320,844259	1274,86392	1285,54726	1274,85204	1313,36716	1274,33576
2021	3	30	0	1283,288106	1234,75761	1227,21022	1235,13235	1256,92495	1230,10008
2021	3	30	1	1403,224589	1328,90401	1305,93867	1313,72493	1354,24388	1313,20503
2021	3	30	2	1518,563314	1467,15366	1432,52493	1426,00495	1472,3848	1414,8913
2021	3	30	3	1579,962911	1577,52982	1533,35454	1515,48985	1592,01556	1503,8494
2021	3	30	4	1563,207743	1662,76815	1607,59731	1585,80404	1674,08869	1564,93084
2021	3	30	5	1675,624736	1779,01142	1707,58755	1697,87949	1765,12344	1658,75735
2021	3	30	6	1610,214274	1750,17432	1672,35768	1658,60316	1738,93957	1600,0003
2021	3	30	7	1504,144572	1629,35204	1547,3482	1539,3863	1582,66593	1475,75507
2021	3	30	8	1552,595683	1629,12391	1559,23395	1549,18887	1588,10918	1507,96425
2021	3	30	9	1664,058106	1701,47957	1631,7572	1649,04516	1680,62674	1618,97115

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	30	10	1586,422343	1660,92594	1584,34508	1599,7881	1644,8358	1580,40507
2021	3	30	11	1494,839742	1580,18401	1514,10007	1521,98928	1557,79591	1506,256
2021	3	30	12	1496,293396	1496,13079	1416,09988	1426,4152	1480,54519	1409,14177
2021	3	30	13	1347,065369	1398,88442	1328,26957	1329,31614	1401,61246	1311,18169
2021	3	30	14	1360,735637	1440,74417	1367,96061	1364,52447	1440,8982	1339,76943
2021	3	30	15	1448,706482	1447,78099	1398,47359	1383,35012	1463,73881	1371,73923
2021	3	30	16	1383,498189	1443,45977	1415,60773	1386,22245	1462,96506	1365,36754
2021	3	30	17	1376,996318	1413,73603	1401,39629	1358,25082	1436,40115	1349,54615
2021	3	30	18	1690,967997	1689,62541	1678,80145	1627,38026	1712,39287	1651,80757
2021	3	30	19	2072,706543	2027,2062	2033,78165	2010,10345	2055,63694	2008,62561
2021	3	30	20	1965,76239	1950,82849	1949,22473	1954,29471	1943,09761	1942,44384
2021	3	30	21	1780,814738	1741,10999	1725,94907	1741,96773	1739,99529	1733,61997
2021	3	30	22	1511,643677	1497,37676	1464,42419	1477,2993	1477,70166	1473,23823
2021	3	30	23	1300,410604	1336,065	1302,58458	1309,62825	1305,02795	1300,29856

Anexo D: Resultados de la predicción de la demanda de energía eléctrica variando el número de retardos de tiempo

Tabla D.1: Resultados de la predicción de la demanda de energía eléctrica variando el número de retardos de tiempo

Año	Mes	Dia	Hora	Demanda Real	Numero de retrasos				
					12	24	72	144	288
2021	3	26	0	1371,526143	1319,10413	1319,08005	1324,72043	1336,38865	1379,99924
2021	3	26	1	1533,046244	1456,97281	1442,41678	1440,91423	1511,76102	1554,4831
2021	3	26	2	1717,446859	1585,48235	1566,92866	1556,79366	1685,26903	1678,2216
2021	3	26	3	1836,932678	1677,7356	1628,27572	1625,06597	1780,50371	1704,90777
2021	3	26	4	1967,222351	1727,61312	1733,78821	1705,10401	1847,601	1743,10018
2021	3	26	5	2052,506409	1839,81622	1843,1918	1798,13289	1944,84559	1834,19803
2021	3	26	6	2051,651225	1800,52872	1809,2119	1738,99462	1866,92272	1802,898
2021	3	26	7	1775,787537	1638,30865	1652,28089	1562,13355	1671,07672	1629,82142
2021	3	26	8	1698,76359	1621,04445	1655,33247	1531,58738	1636,2212	1618,85171
2021	3	26	9	1755,181986	1658,45614	1702,20511	1581,42161	1685,7558	1695,10795
2021	3	26	10	1725,077759	1628,58237	1636,20294	1520,47512	1612,56007	1604,53223
2021	3	26	11	1575,958862	1544,70446	1552,77008	1451,64236	1508,57447	1534,22456
2021	3	26	12	1452,331726	1466,1922	1431,25334	1367,13099	1408,9591	1451,02531
2021	3	26	13	1339,537944	1418,38616	1347,6496	1296,62737	1325,70757	1346,54571
2021	3	26	14	1374,46934	1441,33956	1347,18202	1280,70117	1336,05352	1373,06832
2021	3	26	15	1437,156067	1531,33007	1370,52551	1291,38117	1339,16767	1389,57384
2021	3	26	16	1385,195984	1598,53698	1359,79631	1290,71414	1352,9022	1421,02915
2021	3	26	17	1417,204915	1698,8241	1343,72466	1306,17085	1367,71359	1445,33269

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	26	18	1671,532552	1918,53354	1597,32249	1583,91583	1664,56706	1757,72497
2021	3	26	19	2019,452087	1959,67691	1946,26775	1921,45146	1986,43973	2061,39592
2021	3	26	20	1916,633993	1809,86187	1926,55215	1872,98262	1914,07043	2013,6624
2021	3	26	21	1758,286987	1580,19409	1756,34331	1700,07949	1722,85866	1847,06445
2021	3	26	22	1515,200521	1426,02692	1550,7421	1470,80929	1488,67737	1602,71214
2021	3	26	23	1367,309225	1349,05006	1388,4861	1307,2707	1337,80718	1437,77034
2021	3	27	0	1397,469605	1354,66584	1325,82056	1230,55731	1319,46596	1422,13143
2021	3	27	1	1479,088339	1397,4391	1390,87763	1270,19401	1437,04511	1532,27163
2021	3	27	2	1525,176026	1434,51458	1482,72378	1294,15828	1538,17222	1591,37638
2021	3	27	3	1601,815328	1510,07205	1537,83898	1335,51154	1619,71044	1609,34714
2021	3	27	4	1653,173279	1675,95095	1604,88336	1398,01083	1681,40445	1637,7086
2021	3	27	5	1724,427836	1813,06491	1733,69796	1457,02612	1748,6477	1717,60967
2021	3	27	6	1615,822083	1803,80421	1733,69736	1353,37254	1620,38945	1577,26581
2021	3	27	7	1422,946493	1712,17436	1626,92522	1257,56061	1424,50988	1406,6251
2021	3	27	8	1415,026794	1617,55391	1639,39423	1304,51216	1375,91686	1379,06879
2021	3	27	9	1465,670573	1507,56167	1709,86957	1354,20417	1376,16014	1375,20542
2021	3	27	10	1408,622762	1428,37276	1670,57952	1327,0372	1322,08705	1329,77191
2021	3	27	11	1384,049032	1395,92956	1586,79023	1277,46417	1269,65798	1298,2541
2021	3	27	12	1303,735718	1382,87218	1478,13589	1228,48874	1246,4678	1272,64833
2021	3	27	13	1258,392477	1395,5996	1372,04661	1181,57217	1189,44318	1206,51386
2021	3	27	14	1267,092367	1447,29662	1365,6138	1181,736	1161,82844	1186,1275
2021	3	27	15	1240,86558	1534,85449	1395,44365	1182,10351	1152,789	1184,96692

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	27	16	1227,013245	1668,37295	1407,01319	1175,60317	1150,15758	1168,65402
2021	3	27	17	1269,380595	1840,36614	1384,25996	1212,80459	1170,77388	1140,52754
2021	3	27	18	1622,594198	1909,5439	1503,09943	1473,14671	1479,23474	1442,35128
2021	3	27	19	1926,496521	1795,76135	1797,26149	1865,83678	1840,39256	1823,61731
2021	3	27	20	1826,272095	1584,47887	1866,04377	1826,25616	1788,45075	1781,38863
2021	3	27	21	1713,500366	1395,63689	1755,91807	1664,11762	1644,26675	1627,20371
2021	3	27	22	1467,172038	1291,30584	1611,01959	1437,90797	1426,36826	1413,22012
2021	3	27	23	1292,1085	1261,89309	1480,9962	1253,62735	1237,81993	1240,47929
2021	3	28	0	1136,343506	1285,33927	1395,67065	1147,65133	1119,24432	1096,91508
2021	3	28	1	1044,309814	1320,97743	1392,94285	1120,67467	1070,59438	1024,48109
2021	3	28	2	1036,077942	1368,21465	1435,04124	1113,35686	1027,82249	981,418107
2021	3	28	3	1045,388652	1480,49853	1456,23728	1120,71423	1012,46002	987,685185
2021	3	28	4	1031,99232	1662,79323	1472,01685	1143,7977	1031,4105	994,897937
2021	3	28	5	1082,210673	1779,97018	1532,24803	1175,63478	1063,11826	1039,85239
2021	3	28	6	973,2938943	1772,64534	1551,3531	1116,83942	965,006666	888,823732
2021	3	28	7	917,1438903	1697,09757	1490,37154	1061,89045	960,81824	857,830081
2021	3	28	8	1043,535604	1544,80981	1515,51101	1133,75329	1023,08845	943,479198
2021	3	28	9	1137,705261	1385,57539	1612,23222	1197,53554	1074,3945	1042,43238
2021	3	28	10	1143,460429	1293,19841	1630,86579	1200,97875	1086,80712	1088,5349
2021	3	28	11	1112,451925	1251,37282	1577,44824	1199,38146	1094,94435	1111,02964
2021	3	28	12	1100,316956	1232,21032	1503,01702	1161,94307	1094,67139	1077,94246
2021	3	28	13	1059,523946	1234,55669	1413,47612	1123,63615	1050,07005	1031,54568

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD

2021	3	28	14	1055,363119	1256,94973	1359,70826	1131,64003	1045,77138	1017,31355
2021	3	28	15	1034,596598	1298,03757	1362,47498	1148,02737	1057,15266	1014,2471
2021	3	28	16	1039,026845	1387,93489	1371,73237	1144,96282	1089,57421	1017,86753
2021	3	28	17	1100,619059	1554,49807	1356,9965	1161,59449	1142,32137	1074,68825
2021	3	28	18	1441,921265	1703,41475	1379,73117	1442,17863	1470,56338	1445,44367
2021	3	28	19	1893,08724	1774,32774	1535,94294	1837,66374	1843,76129	1873,22965
2021	3	28	20	1800,839437	1696,7235	1647,53766	1814,05383	1806,60111	1800,41537
2021	3	28	21	1651,498535	1504,34178	1622,46266	1647,72744	1627,66128	1613,96967
2021	3	28	22	1408,059102	1306,8683	1567,70086	1421,71421	1387,1786	1392,08777
2021	3	28	23	1228,863993	1176,52052	1521,67048	1242,96445	1238,32084	1208,71665
2021	3	29	0	1132,45284	1094,88497	1468,91757	1121,4785	1133,41166	1075,77404
2021	3	29	1	1137,419352	1035,98499	1423,54519	1092,82928	1134,24092	1046,58685
2021	3	29	2	1153,273906	983,638128	1393,67903	1094,03454	1173,83339	1089,64435
2021	3	29	3	1154,568522	911,397592	1354,67425	1114,15136	1199,91319	1101,32741
2021	3	29	4	1189,858032	789,467068	1321,28841	1138,13965	1218,47169	1108,65128
2021	3	29	5	1293,47526	632,731203	1305,47671	1203,79474	1294,50071	1198,98155
2021	3	29	6	1311,260783	668,757643	1285,24553	1175,24811	1277,23649	1204,43091
2021	3	29	7	1312,983968	867,413679	1232,8762	1133,20817	1243,86628	1189,31451
2021	3	29	8	1330,878316	871,589099	1217,01432	1211,53048	1284,50614	1204,94486
2021	3	29	9	1370,835165	953,703879	1267,4115	1300,16741	1341,12999	1279,70233
2021	3	29	10	1437,684326	1092,88896	1312,0525	1319,92221	1372,13465	1337,24163
2021	3	29	11	1487,041565	1147,81376	1310,88244	1301,25528	1371,8541	1366,08451

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD


2021	3	29	12	1407,080546	1029,84356	1307,44184	1250,37038	1344,57154	1344,71374
2021	3	29	13	1287,380493	716,811454	1307,80644	1200,18342	1278,7883	1253,17967
2021	3	29	14	1312,204163	410,642246	1293,29682	1227,04255	1302,37197	1302,52716
2021	3	29	15	1367,229411	425,485774	1275,19395	1266,8551	1322,66153	1316,55128
2021	3	29	16	1452,066996	771,516026	1256,31525	1281,76852	1336,71828	1340,36574
2021	3	29	17	1319,217021	1423,9582	1234,68289	1282,81661	1335,34978	1333,79508
2021	3	29	18	1613,761393	2104,16569	1226,23349	1528,44168	1615,20629	1615,1742
2021	3	29	19	2051,170817	1865,35855	1249,45961	1921,12133	1970,90711	1982,60538
2021	3	29	20	1960,377136	2099,69403	1272,79797	1876,16735	1910,18627	1909,54889
2021	3	29	21	1750,071696	2421,11628	1264,54764	1688,69467	1713,92438	1722,06571
2021	3	29	22	1495,691915	2970,77181	1254,0553	1448,85026	1440,69958	1459,92727
2021	3	29	23	1320,844259	3644,60829	1265,49383	1263,80596	1289,58613	1274,33576
2021	3	30	0	1283,288106	3816,15238	1275,97515	1159,16573	1244,39883	1230,10008
2021	3	30	1	1403,224589	2623,25069	1271,4571	1166,42508	1338,81157	1313,20503
2021	3	30	2	1518,563314	824,689787	1266,43858	1203,38763	1469,67434	1414,8913
2021	3	30	3	1579,962911	3277,27548	1263,05645	1249,5197	1571,38387	1503,8494
2021	3	30	4	1563,207743	4215,50339	1249,72661	1300,2539	1639,97022	1564,93084
2021	3	30	5	1675,624736	2480,82636	1227,38084	1391,94592	1731,50025	1658,75735
2021	3	30	6	1610,214274	4158,39393	1200,59186	1387,15733	1690,93472	1600,0003
2021	3	30	7	1504,144572	2957,05823	1170,48764	1297,02432	1553,17702	1475,75507
2021	3	30	8	1552,595683	1806,74926	1147,23656	1355,81581	1565,48147	1507,96425
2021	3	30	9	1664,058106	4854,64603	1133,5288	1456,13946	1629,61861	1618,97115

UNIVERSIDAD TÉCNICA DE COTOPAXI – CARRERA DE ELECTRICIDAD


2021	3	30	10	1586,422343	1751,01202	1118,82251	1448,93562	1597,85257	1580,40507
2021	3	30	11	1494,839742	1648,0358	1098,19158	1397,62633	1530,15825	1506,256
2021	3	30	12	1496,293396	370,49122	1080,80125	1331,50073	1452,06715	1409,14177
2021	3	30	13	1347,065369	2624,67397	1069,63774	1271,73999	1356,74518	1311,18169
2021	3	30	14	1360,735637	2128,39117	1053,66475	1299,78536	1379,0042	1339,76943
2021	3	30	15	1448,706482	3572,25857	1029,52573	1333,54101	1391,25147	1371,73923
2021	3	30	16	1383,498189	1389,56991	1008,48239	1347,50921	1388,24991	1365,36754
2021	3	30	17	1376,996318	1429,90092	995,914556	1336,64855	1385,50973	1349,54615
2021	3	30	18	1690,967997	-113,5398	986,497148	1565,64464	1663,54423	1651,80757
2021	3	30	19	2072,706543	2795,88036	971,353889	1959,52579	2011,27926	2008,62561
2021	3	30	20	1965,76239	4429,57215	948,681512	1908,90023	1935,44775	1942,44384
2021	3	30	21	1780,814738	1956,96721	925,526409	1709,60939	1739,1343	1733,61997
2021	3	30	22	1511,643677	2532,36494	906,231814	1455,33252	1472,99152	1473,23823
2021	3	30	23	1300,410604	2138,90892	887,938681	1264,90497	1306,84702	1300,29856

ANEXO E: Informe de resumen de la demanda de energía eléctrica (kWh) con datos reales por días de una semana.


Resultados de DIA = 24




Resultados de DIA = 25




Resultados de DIA = 26




Resultados de DIA = 27




Resultados de DIA = 28



Resultados de DIA = 29




Resultados de DIA = 30




ANEXO F: Informe de resumen de la demanda de energía eléctrica (kWh) con datos pronosticados por días de una semana


Resultados de DIA = 1




Resultados de DIA = 2




Resultados de DIA = 3




Resultados de DIA = 4



Resultados de DIA = 5



Resultados de DIA = 6



Resultados de DIA = 31

