



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

**IMPLEMENTACIÓN DE UN MODELO DE PREDICCIÓN DE LA**  
**DEMANDA ELÉCTRICA MEDIANTE REDES NEURONALES**  
**ARTIFICIALES**

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

**Autores:**

Hinojosa Bassantes John Sebastian

**Tutor Académico:**

Ing. MSc. Jiménez Jiménez Diego  
Leonardo

**LATACUNGA – ECUADOR**

**2022**



## DECLARACIÓN DE AUTORÍA

Yo, **HINOJOSA BASSANTES JOHN SEBASTIAN** declaro ser autor del presente proyecto de investigación: **“IMPLEMENTACIÓN DE UN MODELO DE PREDICCIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE REDES NEURONALES ARTIFICIALES”**, siendo el Ing. **JIMENEZ JIMENEZ DIEGO LEONARDO** el tutor del presente trabajo; y eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

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

**Hinojosa Bassantes John Sebastian**

**C.C. 1725610792**



## **AVAL DEL TUTOR DE PROYECTO DE TITULACIÓN**

En calidad de Tutor de Trabajo de Investigación sobre el título:

**"IMPLEMENTACIÓN DE UN MODELO DE PREDICCIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE REDES REURONALES ARTIFICIALES"**, de **Hinojosa Bassantes John Sebastian**, de la carrera de Ingeniería Eléctricos en Sistemas Eléctricos de Potencia, considero que dicho informe cumple con los requerimientos metodológicos y aportes científicos-técnicos suficientes para ser sometidos a la evaluación del Tribunal de Validación del 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 del 2022

El tutor:

**DIEGO  
LEONARDO  
JIMENEZ  
JIMENEZ** Firmado  
digitalmente por  
DIEGO LEONARDO  
JIMENEZ JIMENEZ  
Fecha: 2022.09.05  
16:18:07 -05'00'

---

**Ing. Diego Leonardo Jiménez Jiménez**  
**C.I 050349370-2**



## 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, el postulante: **Hinojosa Bassantes John Sebastian**, con el título de Proyecto de titulación: **"IMPLEMENTACIÓN DE UN MODELO DE PREDICCIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE REDES REURONALES 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 2022

Para constancia firman:

Lector 1 (Presidente)

Nombre: Ing. Jessica Castillo. MSc.

CC: 0604590216

Lector 2

Nombre: Ing. Roberto Salazar. MSc.

CC: 0502847619

Lector 3

Nombre: Ing. Rommel Suarez. MSc.

CC: 1804165353

## AGRADECIMIENTO

*En primera instancia quiero agradecer a la vida porque siempre me recompensa de la mejor manera.*

*A mis padres John y Diana porque con su ejemplo de esfuerzo y dedicación me han sabido guiar para que ahora sea una persona de éxito.*

*A mis hermanas Josselyn y Jaziel que con su presencia y amor me han acompañado en este camino universitario y me han enseñado que el amor de hermanos es un amor puro e incondicional.*

*A mi tío Fernando que con su apoyo moral y psicológico me ha sabido guiar en el ámbito profesional y laboral.*

## DEDICATORIA

*Dedico este trabajo con amor y cariño a mi abuelita Magdalena Hernández y en especial a mi abuelito Euclides Bassantes que con su ejemplo de esfuerzo, dedicación y valentía me ha sabido guiar por el camino del bien, y estoy muy seguro que las cosas que he conseguido es gracias a las bendiciones que él me da. ¡Lo logramos Papachito, nos veremos muy pronto!*

*A toda mi familia, en especial a mis hermanas y tías que siempre creyeron en mí.*

*“Digna es recognitione in loco vitae meae, quamvis advenire non valens, magnam semper habeo erga te amorem et adventum tuum expectabo”*

# ÍNDICE DE CONTENIDO

<b>1</b>	<b>INFORMACIÓN GENERAL .....</b>	<b>1</b>
<b>2</b>	<b>INTRODUCCIÓN.....</b>	<b>2</b>
<b>2.1</b>	<b>PROBLEMA DE INVESTIGACIÓN.....</b>	<b>3</b>
2.1.1	Situación Problemática.....	3
2.1.2	Formulación.....	3
<b>2.2</b>	<b>OBJETO Y CAMPO DE ACCIÓN .....</b>	<b>4</b>
2.2.1	Objeto de Investigación.....	4
2.2.2	Campo de Acción .....	4
<b>2.3</b>	<b>BENEFICIARIOS DEL PROYECTO .....</b>	<b>4</b>
2.3.1	Beneficiarios Directos .....	4
2.3.2	Beneficiarios Indirectos .....	4
<b>2.4</b>	<b>JUSTIFICACIÓN.....</b>	<b>4</b>
<b>2.5</b>	<b>HIPÓTESIS.....</b>	<b>5</b>
<b>2.6</b>	<b>OBJETIVOS.....</b>	<b>5</b>
2.6.1	Objetivo General: .....	5
2.6.2	Objetivos Específicos: .....	5
<b>2.7</b>	<b>SISTEMA DE TAREAS.....</b>	<b>5</b>
<b>3</b>	<b>FUNDAMENTACIÓN TEÓRICA .....</b>	<b>8</b>
<b>3.1</b>	<b>ANTECEDENTES DE LA INVESTIGACIÓN.....</b>	<b>8</b>
<b>3.2</b>	<b>MARCO TEÓRICO.....</b>	<b>9</b>

3.2.1	Barrio San José de Cutuglahua.....	9
<b>3.2.2.</b>	<b>Primario “C” de la Subestación 37 Santa Rosa.....</b>	<b>9</b>
3.2.3	Métodos heurísticos.....	10
3.2.3.	Inteligencia Artificial.....	11
3.2.4	Algoritmo genético.....	12
3.2.5	Lógica difusa.....	14
3.2.5.1	Demanda eléctrica.....	16
3.2.5.2	Tipos de demanda eléctrica.....	16
3.2.6	Curva de Demanda.....	17
3.2.6.1	Curvas de carga diaria.....	18
3.2.6.2	Curvas de carga anual.....	18
3.2.6.3	Demanda Máxima.....	19
3.2.6.4	Carga Instalada.....	19
3.2.6.5	Capacidad Instalada.....	19
3.2.7	Procedimiento para realizar la predicción de la demanda eléctrica mediante redes neuronales artificiales.....	19
3.2.8	Clasificación de los métodos de pronóstico de demanda de Energía Eléctrica.....	21
3.2.9	Redes Neuronales.....	23
3.2.9.1	Redes Neuronales Supervisadas y No Supervisadas.....	23
3.2.10	Neuronas.....	24
3.2.10.1	Tipos de Redes Neuronales.....	24



3.2.11	Sistema Neuronal Artificial .....	25
3.2.11.1	Componentes de la red neuronal artificial.....	26
3.2.11.2	Estructura matemática de la red neuronal .....	27
3.2.12	Error cuadrático medio .....	29
3.2.13	Redes neuronales artificiales .....	30
3.2.13.1	Topología o arquitectura de redes neuronales.....	31
3.2.13.2	Según la estructura en capas.....	31
3.2.13.3	Según el flujo de datos en la red .....	32
3.2.13.4	Según el tipo de respuesta de la red o asociación entrada y salida ...	33
<b>4</b>	<b>METODOLOGÍA.....</b>	<b>33</b>
<b>4.1</b>	<b>TIPO DE INVESTIGACIÓN .....</b>	<b>33</b>
4.1.1	Investigación Descriptiva .....	33
4.1.2	Investigación Diagnóstica.....	34
4.1.3	Investigación Aplicada .....	34
<b>4.2</b>	<b>MÉTODO DE INVESTIGACIÓN.....</b>	<b>34</b>
4.2.1	Metodología de la Investigación bibliográfica .....	34
4.2.2	Metodología Inductiva y Deductiva .....	34
<b>4.3</b>	<b>TÉCNICAS E INSTRUMENTOS.....</b>	<b>35</b>
4.3.1	La observación.....	35
4.3.2	Simulación.....	35
4.3.3	Programación.....	35

<b>4.4</b>	<b>METODOLOGÍA DE LA PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA.....</b>	<b>36</b>
<b>5</b>	<b>ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS .....</b>	<b>37</b>
<b>5.1</b>	<b>ANÁLISIS DE LA BASE DE DATOS HISTÓRICA.....</b>	<b>37</b>
5.1.1	Análisis del comportamiento de la base de datos real .....	37
5.1.2	Análisis del comportamiento del consumo eléctrico pronosticado .....	40
<b>5.2</b>	<b>INTERFASES GRÁFICAS DESARROLLADAS.....</b>	<b>42</b>
5.2.1	Módulo “histórico de la demanda eléctrica” .....	43
5.2.2	Módulo de “propiedades de red neuronal” .....	43
5.2.3	Módulo de “predicciones” .....	44
<b>6</b>	<b>CONCLUSIONES Y RECOMENDACIONES .....</b>	<b>47</b>
<b>6.1</b>	<b>CONCLUSIONES .....</b>	<b>47</b>
<b>6.2</b>	<b>RECOMENDACIONES .....</b>	<b>49</b>
<b>7</b>	<b>BIBLIOGRAFÍA .....</b>	<b>50</b>
<b>8</b>	<b>ANEXOS .....</b>	<b>56</b>

## ÍNDICE DE TABLAS

<b>Tabla 2.1:</b> Sistema de tareas en relación con el objetivo específico 1. ....	5
<b>Tabla 2.2:</b> Sistema de tareas en relación con el objetivo específico 2.....	6
<b>Tabla 2.3:</b> Sistema de tareas en relación con el objetivo específico 3 .....	6
<b>Tabla 2.4:</b> Sistema de tareas en relación con el objetivo específico 4 .....	7
<b>Tabla 5.1:</b> Análisis Descriptivo de Datos Reales .....	38
<b>Tabla 5.2:</b> Análisis descriptivo de los datos de predicción .....	41
<b>Tabla 5.3:</b> Error promedio anual entre demanda eléctrica real y pronosticada .....	45
<b>Tabla 8.1:</b> __Transformadores instalados en el Primario “C” 37 SANTA ROSA.....	<b>¡Error! Marcador no definido.</b>

## ÍNDICE DE FIGURAS

<b>Figura 3.1.</b> Ubicación geográfica del barrio San José de Cutuglahua.....	9
<b>Figura 3.2.</b> Primario C de la subestación Santa Rosa.....	10
<b>Figura 3.3.</b> Clasificación de técnicas de proyección de la demanda [18].....	11
<b>Figura 3.4.</b> Esquema General de un Algoritmo Genético [18].....	13
<b>Figura 3.5.</b> Diagrama de bloques del modelo de sistema difuso [18] .....	15
<b>Figura 3.6:</b> Tipos de demandas eléctricas [16].....	17
<b>Figura 3.7:</b> Curva de carga [19] .....	18
<b>Figura 3.8:</b> Curva de demanda [17].....	18
<b>Figura 3.9:</b> Curva de carga anual [20].....	19
<b>Figura 3.10:</b> Procedimiento para realizar la predicción de la demanda eléctrica.....	20
<b>Figura 3.11:</b> Pasos para realizar el pronóstico de la demanda eléctrica mediante redes neuronales artificiales [16] .....	21
<b>Figura 3.12:</b> Clasificación de los métodos de pronóstico de demanda [22].....	22
<b>Figura 3.13:</b> Estructura de una neurona .....	24
<b>Figura 3.14:</b> Sistema global de proceso de una red neurona.....	26
<b>Figura 3.15:</b> Modelo de neurona artificial standard .....	26
<b>Figura 3.16:</b> BIAS .....	26
<b>Figura 3.17:</b> Funciones de activación.....	27
<b>Figura 3.18:</b> Modelo de la red neuronal .....	27
<b>Figura 3.19:</b> Red Neuronal Monocapa [36]. .....	31

<b>Figura 3.20:</b> Red Neuronal Multicapa [36].	32
<b>Figura 3.21:</b> Red de propagación hacia delante de tres capas [37].	32
<b>Figura 4.1:</b> Flujograma del pronóstico de la demanda de electricidad.	36
<b>Figura 5.1:</b> Consumo Eléctrico Mes-Hora Datos Reales	38
<b>Figura 5.2:</b> Consumo del Mes de Enero en el Sector de San José de Cutuglahua Datos Reales	39
<b>Figura 5.3:</b> Consumo Energético Diario Datos Reales	40
<b>Figura 5.4:</b> Gráfica Consumo Eléctrico Mes-Hora Predicción	41
<b>Figura 5.5:</b> Curva del Consumo Eléctrico Real VS Pronosticada.	45

# UNIVERSIDAD TÉCNICA DE COTOPAXI

## FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

**TEMA: “IMPLEMENTACIÓN DE UN MODELO DE PREDICCIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE REDES NEURONALES ARTIFICIALES”**

**Autor:**

John Sebastian Hinojosa Bassantes

### RESUMEN

La presente investigación tiene como objetivo implementar un modelo de predicción de la demanda eléctrica mediante redes neuronales artificiales desarrollado por una herramienta computacional con el programa MATLAB, utilizando datos reales de demanda eléctrica en función de la potencia del alimentador C de la Subestación 37 Santa Rosa pertenecientes al barrio de San José de Cutuglahua. Realizando un tipo de investigación descriptiva, diagnóstica y aplicada, con un método bibliográfico, inductivo – deductivo, y la aplicación de técnicas e instrumentos como la observación, simulación y programación. Dentro de la parte de programación el programa cuenta con una interfaz gráfica (APP DESIGNER) que consta de tres módulos para su funcionamiento : Demanda Eléctrica, Propiedades de la red neuronal y Predicciones, con características particulares que permitieron el correcto funcionamiento, así como una pantalla gráfica que permite ver los días requeridos; dentro de este programa se implementó librerías de redes neuronales de MATLAB, para las predicciones de series de tiempo se contó con la red NARNET, utilizando para el algoritmo de entrenamiento levenberg-marquart mediante 5 neuronas con 70 % de los datos ingresados, 15 % de los datos para la validación y 15% de datos de prueba, obteniendo un error porcentual de 4.06%, concluyendo que el pronóstico de la demanda es óptimo y confiable.

*Palabras Claves – Predicción, Redes Neuronales Artificiales, Demanda Eléctrica*

**TECHNICAL UNIVERSITY OF COTOPAXI**

**FACULTY OF ENGINEERING AND APPLIED SCIENCES**

**TITLE:** "IMPLEMENTATION OF AN ELECTRIC DEMAND PREDICTION MODEL BY MEANS OF ARTIFICIAL NEURAL NETWORKS".

**Author:**

John Sebastian Hinojosa Bassantes

**ABSTRACT**

The objective of this research is to implement a prediction model of electrical demand through artificial neural networks developed by a computational tool with the MATLAB program, using real data of electrical demand based on the power of feeder C of Substation 37 Santa Rosa belonging to the neighborhood of San José de Cutuglahua. Carrying out a type of descriptive, diagnostic and applied research, with a bibliographic, inductive - deductive method, and the application of techniques and instruments such as observation, simulation and programming. Within the programming part, the program has a graphical interface (APP DESIGNER) that consists of three modules for its operation: Electricity Demand, Properties of the neural network and Predictions, with particular characteristics that allowed the correct operation, as well as a screen graph that allows you to see the days required; Within this program, MATLAB neural network libraries were implemented, for time series predictions, the NARNET network was used, using the Levenberg-Marquart training algorithm through 5 neurons with 70% of the data entered, 15% of data for validation and 15% of test data, obtaining a percentage error of 4.06%, concluding that the demand forecast is optimal and reliable..

***Keywords*** - *Prediction, Artificial Neural Networks, Electricity Demand*

## **AVAL DE TRADUCCIÓN**



# 1 INFORMACIÓN GENERAL

**Título del proyecto:** Implementación de un modelo de predicción de la demanda eléctrica mediante redes neuronales artificiales

**Fecha de inicio:** Abril\_2022

**Fecha de finalización:** Agosto\_2022

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

**Facultad que auspicia:** Ciencias de la Ingeniería y Aplicadas

**Carrera que auspicia:** Ingeniería Eléctrica en Sistemas Eléctricos de Potencia

**Proyecto de investigación vinculado:** Predicción de la demanda eléctrica a través de redes neuronales artificiales.

**Equipo de trabajo:**

## TUTOR

**Nombres y Apellidos:** Ing. MSc. Diego Leonardo Jiménez Jiménez

**Cédula de ciudadanía:** 050349370-2

**Email:** diego.jimenez@utc.edu.ec

## POSTULANTE 1:

**Nombres:** John Sebastian

**Apellidos:** Hinojosa Bassantes

**Cédula de ciudadanía:** 1725610792

**Email:** john.hinojosa0792@utc.edu.ec

**Estudios realizados**

**Bachillerato:** Colegio Técnico “Sucre”

**Área de conocimiento:**

07 Ingeniería, Industria y Construcción / 071 Ingeniería y Profesiones Afines / 0713

Electricidad y Energía.

**Proyecto Macro Asociado:**

Desarrollo de sistemas eficientes para el abastecimiento y uso de energía eléctrica a nivel local, regional o nacional.

**Equipo de trabajo:**

**Grupo de Investigación:** Sistemas Eléctricos de Potencia

## **2 INTRODUCCIÓN**

En los últimos tiempos, la utilización de electricidad en el mundo se ha incrementado exponencialmente por motivos políticos, económicos e industriales. Las predicciones exactas del consumo energético en general son indispensables para la resolución de toma de datos, más aún si hablamos en términos energía eléctrica [1].

El pronóstico del consumo de energía eléctrica ha ido abriéndose paso en las nuevas propuestas tecnológicas, el deber de pronosticar el consumo eléctrico es necesario para conservar ecuanimidad entre la oferta y la demanda, así se gestionará adecuadamente el proceso de producción, transmisión y distribución de electricidad a corto, mediano y largo plazo.

Las Redes Neuronales Artificiales (RNA) surgen de redes neuronales biológicas del cerebro del ser humano y están conformadas por elementos que tienen un comportamiento idéntico a esta, es decir, la manera de actuar de RNA es similar a la que presenta el cerebro humano [2]. Pero si enlazamos la predicción de demanda eléctrica con las Redes Neuronales Artificiales, se muestran como una solución de problemas de predicción, debido a su capacidad exclusiva como aproximadora de funciones matemáticamente desconocidas y clasificadoras de patrones, que las convierten en una herramienta con grandes ventajas frente a los métodos convencionales de predicción.

## **2.1 PROBLEMA DE INVESTIGACIÓN**

### **2.1.1 Situación Problemática**

Poseer energía en el ser humano significa bienestar y salud, por otro lado, para producir energía es necesario el empleo de combustibles fósiles, tales como, el carbón, gas natural y el petróleo, el 80% de producción de energía se produce por este medio. Tener un óptimo recurso de electricidad es uno de los indicadores del desarrollo y otorga una señal de crecimiento económico. El consumo de electricidad está aumentando exponencialmente [3]. En Ecuador el promedio de consumo de electricidad en las respectivas residencias es mayor a los 138 KW/h, en el sector urbano se calcula un consumo más alto con 155 KW/h; esto llevado a términos monetarios en la Región Costa se paga un promedio mensual de 18,78, mientras que en la Región Sierra se gasta 16,09 [4].

La predicción del consumo eléctrico es una problemática relevante, mediante los resultados predichos los organismos que regulan esta actividad se encargan de tomar las acciones competentes. Realizar un pronóstico satisfactorio trae grandes beneficios ya sea técnico como financieros, así es importante encontrar modelos de predicción con un porcentaje de error ínfimo [5].

No cabe duda de que tener un pronóstico correcto del consumo eléctrico es una estipulación primordial para que la empresa suministradora de electricidad alcance los objetivos que respectan a confiabilidad y calidad que tienen trazadas, ya que la constante dependencia de la electricidad incrementa los perjuicios causados a los clientes si se genera deficiencias en la generación de electricidad [6]. Pero no solo la distribuidora de energía se beneficia de esto, directamente la población de San José de Cutuglahua ya que, al contar con una herramienta tan necesaria y sobre todo confiable, podrá tener una idea acerca de cómo manejar el racionamiento eléctrico que recibe, para que lo use de mejor forma y a su vez establezca una conciencia de conservación de la energía.

### **2.1.2 Formulación**

El pronóstico de la demanda eléctrica es un problema de gran importancia para el sector eléctrico, a partir de los resultados que se obtienen en un pronóstico los organismos que

regulan esta actividad se encargan de tomar las acciones competentes, además de las familias beneficiarias de este servicio.

## **2.2 OBJETO Y CAMPO DE ACCIÓN**

### **2.2.1 Objeto de Investigación**

Red Neuronal Artificial

### **2.2.2 Campo de Acción**

Barrio San José de Cutuglahua, cantón Quito, provincia Pichincha, Ecuador

## **2.3 BENEFICIARIOS DEL PROYECTO**

### **2.3.1 Beneficiarios Directos**

Los beneficiarios directos del proyecto son los pobladores del sector San José de Cutuglahua del Cantón Quito, así como la empresa distribuidora de energía eléctrica.

### **2.3.2 Beneficiarios Indirectos**

Los beneficiarios indirectos son toda la ciudadanía en general.

## **2.4 JUSTIFICACIÓN**

El pronóstico del consumo de electricidad es una actividad de suma relevancia para el organismo encargado de la generación de este recurso. Las predicciones ya sean altas o bajas están directamente ligadas con los costos de energía. En este sentido, es complicado que el cliente final que consume este servicio no resulte perjudicado. Si llegase a faltar electricidad el cliente tendrá que incrementar el pago por el servicio, por otro lado, si existe electricidad de sobra será necesario dejar de operar ciertas centrales y los costos disminuirán. Con la creación de este proyecto se busca tener un mejor control en el consumo eléctrico a partir de predicciones realizadas por la Red Neuronal, además ayudará optimizando de la curva eléctrica y mejorará el criterio de la eficiencia energética en las residencias del Barrio San José de Cutuglahua; aminorando el consumo energético sin poner en riesgo las exigencias de las personas consumidoras.

## **2.5 HIPÓTESIS**

Es posible diseñar una red neuronal que prediga la demanda de energía eléctrica utilizando información de datos históricos de demanda carga y los modelos de Red Neuronal que se aplican a series de tiempo.

## **2.6 OBJETIVOS**

### **2.6.1 Objetivo General:**

Implementar un modelo de predicción con redes neuronales artificiales para determinar la demanda de energía eléctrica en el Barrio San José de Cutuglahua ubicado en el cantón Quito provincia de Pichincha

### **2.6.2 Objetivos Específicos:**

- Investigar diferentes métodos heurísticos para resolver el problema de predicción de demanda eléctrica.
- Depurar los datos obtenidos de la demanda eléctrica horaria del barrio San José de Cutuglahua
- Entrenar a la red neuronal artificial identificando las técnicas de activación de la misma.
- Comparar la demanda eléctrica actual con la demanda eléctrica de predicción entregada por la red neuronal.

## **2.7 SISTEMA DE TAREAS**

**Tabla 2.1:** Sistema de tareas en relación con el objetivo específico 1.

<b>Objetivo específico 1</b>	<b>Actividad (tareas)</b>	<b>Resultados Esperados</b>	<b>Técnicas, Medios e Instrumentos</b>
Investigar diferentes métodos heurísticos para solventar el problema de pronóstico de la demanda eléctrica.	<ul style="list-style-type: none"> <li>• Revisión Bibliográfica</li> <li>• Búsqueda de obras colectivas y medios digitales para obtener información sobre las necesidades de la demanda eléctrica.</li> </ul>	Encontrar la mejor metodología para poder obtener datos de predicción correctos	<ul style="list-style-type: none"> <li>• Libros</li> <li>• Tesis</li> <li>• Artículos científicos</li> <li>• Informes técnicos</li> </ul>

**Tabla 2.2:** Sistema de tareas en relación con el objetivo específico 2

<b>Objetivo específico 2</b>	<b>Actividad (tareas)</b>	<b>Resultados Esperados</b>	<b>Técnicas, Medios e Instrumentos</b>
Depurar los datos obtenidos de la demanda eléctrica horaria del barrio San José de Cutuglahua	<ul style="list-style-type: none"> <li>• Cálculo del promedio de rango de horas por día para normalizarlo.</li> <li>• Desarrollo de algoritmo de normalización y balanceo de datos</li> <li>• Utilizar el método de la media para obtener los datos</li> </ul>	<ul style="list-style-type: none"> <li>• Obtener resultados que sean parejos sin tener desfase de tiempos.</li> <li>• Visualización de datos obtenidos ya corregidos satisfactoriamente mediante matriz normalizada por días y meses del año</li> </ul>	<ul style="list-style-type: none"> <li>• Software MATLAB</li> <li>• Software EXCEL</li> </ul>

**Tabla 2.3:** Sistema de tareas en relación con el objetivo específico 3

<b>Objetivo específico 3</b>	<b>Actividad (tareas)</b>	<b>Resultados Esperados</b>	<b>Técnicas, Medios e Instrumentos</b>
Entrenar a la red neuronal artificial identificando las técnicas de activación de esta.	<ul style="list-style-type: none"> <li>• Ingreso datos de entrada (24 horas del día y mes de consumo)</li> <li>• Ingreso de parámetros para adiestramiento de la red neuronal.</li> </ul>	Obtención de la salida de potencia del dataset, con la predicción del consumo energético.	<ul style="list-style-type: none"> <li>• Software MATLAB</li> <li>• Redes Neuronales Artificiales</li> </ul>

**Tabla 2.4:** Sistema de tareas en relación con el objetivo específico 4

<b>Objetivo específico 4</b>	<b>Actividad (tareas)</b>	<b>Resultados Esperados</b>	<b>Técnicas, Medios e Instrumentos</b>
Comparar la demanda eléctrica actual con la demanda eléctrica de predicción entregada por la red neuronal.	<ul style="list-style-type: none"> <li>• Desarrollo de un entorno gráfico para visualizar datos obtenidos por el adiestramiento de la red neuronal.</li> <li>• Digitar en pantalla de visualización las entradas solicitadas, Mes y Hora.</li> </ul>	Obtener datos más precisos mediante el balanceo y comparar cuales resultan más fiables.	<ul style="list-style-type: none"> <li>• Software MATLAB</li> <li>• Redes Neuronales Artificiales</li> </ul>

### **3 FUNDAMENTACIÓN TEÓRICA**

#### **3.1 ANTECEDENTES DE LA INVESTIGACIÓN**

En la investigación “APLICACIÓN DE UNA RED NEURONAL A UN SISTEMA ELÉCTRICO DE DISTRIBUCIÓN MEDIANTE EL ANÁLISIS DE COMPORTAMIENTO DE SU CARGA EN BAJO VOLTAJE” se aplica RNA a un sistema eléctrico de distribución de bajo voltaje, la cual actúa en base a un modelo genérico de flujos de potencia, donde se respeta restricciones de caída de voltaje y pérdidas técnicas en la transmisión. Esta metodología concede que un sistema de distribución real sea modificado con el objetivo de determinar el ahorro anual de este. Este estudio tiene la finalidad de validar la efectividad de una RNA para sistema de distribución en bajo voltaje, según los resultados se realiza un análisis técnico-económico que posibilita validar la viabilidad económica del método en sistemas existentes [7].

En la investigación “HERRAMIENTA PARA PREDECIR EL CONSUMO DE ENERGÍA ELÉCTRICA MEDIANTE REDES NEURONALES ARTIFICIALES” su autor muestra una herramienta para estimar el consumo de electricidad en un edificio estudiantil universitario a partir de una información histórica del mismo y en función de un grupo de variables las cuales se consideran como las principales en el comportamiento energético. Se desarrolló una herramienta basada en una Red Neuronal Artificial del tipo Feed-forward backpropagation que arrojó excelentes resultados en la predicción del consumo de energía eléctrica del edificio.[8]

En otro artículo llamado “DISEÑO DE RED NEURONAL PARA LA PREDICCIÓN DEL CONSUMO DE ENERGÍA ELÉCTRICA: CASO PRÁCTICO” se realiza un pronóstico del consumo de electricidad. La metodología emplea RNA y se obtiene un equilibrio entre la energía entregada y consumida, se concluye que si no existe equilibrio los usuarios finales tendrían problemas de abastecimiento o por otro lado la energía entregada sería demasiada y existiría un problema de desperdicio energético.

Finalmente, a trabajos relacionados con este proyecto de investigación se tiene “RED NEURONAL LONG SHORT- TERM MEMORY (LSTM) APLICADA A SERIES TEMPORALES PARA PRONOSTICAR CONSUMO ENERGÉTICO EN EDIFICACIONES.” En este documento se emplea técnicas de aprendizaje automático supervisado mediante RNA para predecir el comportamiento de consumo de una



residencia, de esta manera de realiza un diseño en cuestión emplea un dataset con mediciones energéticas de cuatro años y se ponen a prueba distintas arquitecturas, además se simulan cerca de doscientos modelos con distintos hiperparámetros [9].

## 3.2 MARCO TEÓRICO

### 3.2.1 Barrio San José de Cutuglahua

El barrio de San José de Cutuglahua se ubica en la zona suroeste del cantón de Quito, a 0.36°S 78.55 °O, a 3046 m.s.n.m, sus límites geográficos son: al Norte con el volcán Atacazo, al Sur y Oeste con la parroquia de Tambillo y al Este con la parroquia de Uyumbicho. Actualmente según el Inec y los datos proporcionados por la secretaria nacional de Planificación y Desarrollo en el sector de San José de Cutuglahua son alrededor de 21.750 habitantes y aproximadamente 5000 familias, considerándose como una zona rural de Quito [8].



**Figura 3.1.** Ubicación geográfica del barrio San José de Cutuglahua


### 3.2.2. Primario “C” de la Subestación 37 Santa Rosa

La subestación 37 Santa Rosa consta con aproximadamente 300m<sup>2</sup> de espacio, en su interior consta con 2 transformadores reductores de potencia, y sus salidas tienen 7

alimentadores primario clasificándose por letras alfabéticas A, B,C,D,E,F y G, distribuyéndose por las parroquias de Cutuglahua, Guamaní, Santa Rosa y Turubamba; entregando un voltaje trifásico de 22860V y monofásico en 13200V.

El primario C de la subestación Santa Rosa con aproximadamente 135km de longitud, es el encargado de abastecer de energía eléctrica a lo que es el barrio san José de Cutuglahua.

En la Figura 3.2 se aprecia el diagrama unifilar del primario C de la subestación santa Rosa



**Figura 3.2.** Primario C de la subestación Santa Rosa

### 3.2.3 Métodos heurísticos

Estos métodos son muy conocidos y se clasifican según los siguientes criterios: cualitativos y cuantitativos, en los métodos cualitativos se toma el criterio de expertos en la temática para realizar un predicción, por otro lado, en los métodos cuantitativos se toma datos históricos para predecir, estos a su vez se clasifican en métodos estadísticos y de inteligencia artificial [17].



**Figura 3.3.** Clasificación de técnicas de proyección de la demanda [18].

El trabajo considerará en métodos heurísticos, uso de IA y básicamente en redes neuronales artificiales.

### 3.2.3. Inteligencia Artificial

La inteligencia artificial (IA) es de gran importancia para sectores industriales y económicos del mundo dado su eficiencia. La IA se considera un frente de innovación y una tecnología habilitadora. IA incluye una recopilación de metodología computacionales para obtener información de datos históricos, incluidos los llamados "pequeños datos" generados por el propio algoritmo, ayuda a tomar decisiones y crear información relevante [19]. En general, la IA es considerada como una tecnología relevante que ayuda a la sociedad en el ámbito económico y político. Algunos describen la IA con comportamiento similar a las máquinas de vapor o las tecnologías eléctricas por su impacto al desarrollo de la humanidad. Obviamente, la IA transformará radicalmente el sector energético. General Electric (GE) estima que la IA puede mejorar la producción de un parque eólico hasta en un 20 %, la transformación de la IA en la industria energética influirá directamente en la estabilidad energética internacional y la prosperidad económica. Por ejemplo, el uso de redes neuronales artificiales es importante para que las empresas eléctricas mejoren su productividad, la calidad y seguridad de las producciones y la estabilidad de la electricidad. Como ejemplo,

Google Data Center utilizó DeepMind IA para lograr efectivamente un 40 % de ahorro de energía para la operación del centro de datos [20]. Sin embargo, a medida que aumentan las tasas de adopción y penetración de la tecnología de IA en el sector energético, la IA existente y la investigación relacionada con la energía siguen sin explorarse lo suficiente sin un esfuerzo académico suficiente sobre las aplicaciones de IA en el diseño del mercado de la energía y la electricidad además de la infraestructura energética física y técnica. La IA posibilita simular funciones de procesos cerebrales, como el aprendizaje, resolución de problemas y procesamiento de datos, además, esta tecnología ha desarrollado modelos para reconocer la voz, automatizar procesos, y optimizar procesos de aprendizaje [8].

### **3.2.4 Algoritmo genético**

El AG es un método de optimización global basado en el principio de supervivencia del más apto; La hipótesis de la evolución de Darwin. Los principios básicos del AG se atribuyen a Holland [21] y han sido adaptados para un gran número de aplicaciones en diferentes áreas. AG es similar al proceso de evolución natural en el que una población de una especie determinada se adapta a un entorno natural, se crea una población de diseños y luego se les permite evolucionar para adaptarse al entorno de diseño en consideración. Los AG codifican una posible solución a un problema específico en una cadena de cromosomas simple como estructura de datos y aplican operadores específicos a estas estructuras para preservar información importante y producir un nuevo conjunto de población con el propósito de generar cadenas que se asignan a valores de función altos. Las operaciones básicas de AG, una selección, un cruce de información genética entre padres reproductores y una mutación de información genética afectan las cadenas binarias características en la evolución natural. Una descripción del AG es como sigue. En la población biológica, la información genética generalmente se almacena en forma de cadenas binarias. Los procesos básicos, que afectan la composición de las cadenas binarias en la evolución natural, son una selección, un cruce de información genética entre los padres que se reproducen y una operación de mutación. En este sentido, los AG son metaheurísticas de búsqueda global que toman como referencia un algoritmo que se simula en repetidas ocasiones en cada simulación, así se obtiene el óptimo global de cualquier problema bajo análisis [22].

El algoritmo empieza al crearse una cadena con diferente tipo de soluciones a un problema en específico. La población inicial y el tamaño de esta son parámetros esenciales para la

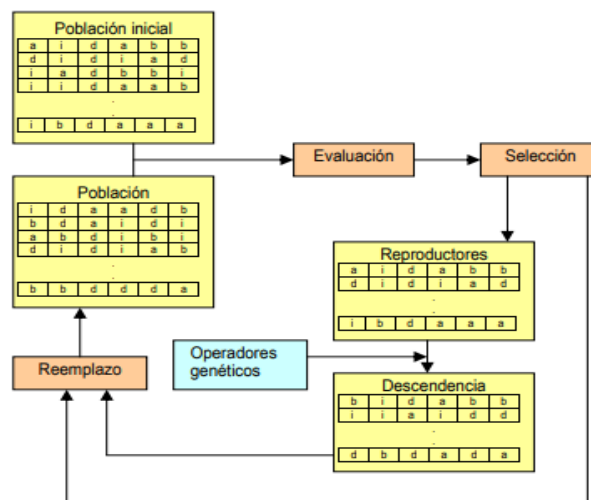
simulación. Cuando se obtiene esos datos empieza el proceso de selección de la población, donde se escoge cierto grupo de individuos que serán la posible solución al problema [18].

Un algoritmo es una serie de pasos organizados que describe el proceso a realizarse, para solucionar alguna problemática. AG está inspirada en la reproducción de los seres vivos e imita a la evolución biológica como estrategia para solventar problemas de la sociedad. En general, los algoritmos genéticos (AGs) forman parte de la inteligencia artificial; es decir, la resolución de problemas mediante el uso de programas computacionales que imitan el comportamiento de la inteligencia natural [23].

a. **Estructura de un algoritmo genético.**

Para solventar un problema mediante el AG, este problema deberá tener lo siguiente:

- Una representación genética de las soluciones primordiales del problema.
- Una forma de crear la población inicial de soluciones potenciales.
- Una función de evaluación que juegue el papel de medio ambiente, y permita ordenar las soluciones de acuerdo con su fitness.
- Operadores genéticos que alteren la composición de los hijos.
- Valores de varios parámetros que el algoritmo genético utiliza



**Figura 3.4.** Esquema General de un Algoritmo Genético [18]

### 3.2.5 Lógica difusa

Básicamente, la Lógica Difusa consiste en una técnica inteligente que pretende modelar el razonamiento, mimetizando la capacidad humana para tomar decisiones en un entorno incierto e impreciso. Por sus características intrínsecas, la Lógica Difusa es capaz de incorporar tanto conocimiento objetivo (a partir de datos numéricos) como subjetivo (a partir de información lingüística). Como se mencionó, la principal ventaja de los modelos difusos es la alta precisión que se logra en escenarios de incertidumbre total. Es por ello que, en periodos de crisis económica, este tipo de metodologías suelen utilizarse como alternativa a otros modelos estadísticos. Al utilizar modelos de lógica difusa, el investigador debe tener en cuenta que otras metodologías pueden brindar una mejor interpretación de la relación entre la variable dependiente con las exógenas, como es el caso de los modelos econométricos. En Lógica Difusa, al contrario de lo que ocurre en la lógica clásica, el grado de pertenencia de un enunciado se representa mediante un número en el rango  $[0,1]$ . Esta característica es útil en muchas situaciones prácticas donde la intensidad de un fenómeno es descrita de manera imprecisa por variables lingüísticas, tales como: muy baja, baja, media, alta o muy alta. La mayor contribución de la lógica difusa radica precisamente en el tratamiento de estas cuestiones lingüísticas a través de funciones de pertenencia a conjuntos difusos [24]. El proceso de inferencia difusa evalúa los niveles de compatibilidad de las variables de entrada con las reglas anteriores, activando las siguientes con intensidades proporcionales a ellas. El resultado de esta operación es un conjunto borroso que se convierte en número, la salida del sistema de inferencia [8].


En lógica difusa, no es necesario emplear matemática para las entradas y salidas, dado que cada uno de estos parámetros se trabajan mediante reglas difusas y así se puede determinar su comportamiento en el problema [8].

#### a. Estructura de un sistema difuso.

Las estructuras empleadas para un sistema difuso sigue el proceso siguiente [1]:

- Decisión del modelo de reglas difusas [1].

- Selección del operador usado en el sistema de inferencia (conjuntivo, disyuntivo) [1].
- Definir las funciones empleadas en los antecedentes y en las consecuencias [2] [1].
- Elegir el tipo de fuzzificación [1].
- Escoger el tipo de defuzzificación [1].
- Seleccionar las metodologías para modelar y adiestrar del sistema [1].



**Figura 3.5.** Diagrama de bloques del modelo de sistema difuso [18]

Cada una de las partes cumple su función determinada:

Entradas: son las variables que permiten de datos para solventar un problema [1]

- Fuzificador: se encarga de cambiar el lenguaje de datos a uno de tipo difuso y asigna un valor de pertenencia (0,1) de esta manera se clasifica los datos [1]
- Reglas base difusas: emplean la regla primordial de inferencia (si-entonces) así alimentan el mecanismo de inferencia por medio de relación y decodificación de las variables de entrada y salida [1]
- Mecanismo de inferencia difuso: es el encargado de relacionar la salida del fuzzificador con las reglas difusas con el objetivo de determinar la salida [1].
- Defuzzificador: emplea un lenguaje de tipo difuso y toma las funciones de propiedad como entrada [1]
- Salidas: presenta los resultados obtenidos [1]

#### **b. Métodos de un sistema difuso.**

Son métodos gráficos de simulación del proceso de razonamiento (sacar conclusiones a partir de presuposiciones). Hay tres tipos de métodos de inferencia: Mamdani, Sugeno y Tsukamoto, siendo el último una combinación del primer.

La diferencia más fundamental entre Mamdani, Tsukamoto y Sugeno es en términos de cómo se genera una salida nítida a partir de una entrada difusa. Mamdani utiliza la técnica del Centro de Gravedad para el proceso de defuzzificación; mientras que Sugeno y Tsukamoto usan el promedio ponderado para calcular la salida nítida. Sugeno tiene un mejor tiempo de procesamiento para una defuzzificación promedio ponderada. Debido a la naturaleza interpretada e intuitiva de la base de reglas, Mamdani se usa ampliamente, especialmente para aplicaciones de soporte de decisiones [25].

### **3.2.5.1 Demanda eléctrica**

Se define como la intensidad de corriente relativa al intervalo de tiempo determinado, mismo que obtiene la carga para su funcionamiento.

Se considera también como la cantidad de potencia consumida en distintos momentos, es decir es la demanda de una instalación eléctrica en los receptores, ya que se lo toma mediante un valor medio respecto al intervalo determinado, el período en el cual el valor medio es tomado se establece con el valor de intervalo de demanda [16].

Respecto a su duración depende del valor de demanda que se pretenda conocer, al querer encontrarla se puede aplicar hacia un cable o transformador, por lo general es de 10 a 15 minutos.

Los intervalos del consumo se dan entre 15, 30 o 60 minutos según estudios de balanceo de carga y transferencia de esta. Sin embargo, el intervalo de 60 minutos ayuda a la construcción de perfiles de carga diaria con el fin de analizar el consumo de energía y de esta manera comprobar su rendimiento respecto a sus dispositivos [17].

### **3.2.5.2 Tipos de demanda eléctrica**

A continuación, se muestra las diferentes demandas eléctricas, dependiendo de los consumidores, sean residencial, comercial o industrial, que se presentan en la siguiente tabla.



Consumidor Residencial:	Consumidor comercial	Consumidor Industrial
<ul style="list-style-type: none"> <li>• Es aquella persona que utiliza la electricidad para uso doméstico.</li> <li>• Incluye consumidores de bajos recurso y aquellos que tiene actividad comercial o artesanal.</li> </ul>	<ul style="list-style-type: none"> <li>• Es aquella persona que utiliza la electricidad para negocio o actividades que otorgan ganancias económicas.</li> <li>• Las cargas comerciales generalmente son trifásicas y de potencias medianas</li> </ul>	<ul style="list-style-type: none"> <li>• Es aquella persona que utiliza la electricidad para elaboración de productos.</li> <li>• Incluye a los agroindustriales.</li> </ul>


**Figura 3.6:** Tipos de demandas eléctricas [16]

Cabe señalar que, los tipos de demanda eléctrica se dan en base a las características del consumidor, sea residencial, comercial o industrial y por los aspectos de los puntos de entrega [18].

### 3.2.6 Curva de Demanda

Representación gráfica de la variación de la demanda o carga eléctrica durante el tiempo. Además, es el tiempo seleccionado para realizar un análisis, mismo que puede ser diario, semanal, mensual, anual.

A continuación, se muestra un ejemplo de la curva de demanda o carga en el cual las abscisas representa el tiempo y en las ordenadas la potencia eléctrica, el área por debajo de la curva significa la energía demandada.




**Figura 3.7:** Curva de carga [19]

### 3.2.6.1 Curvas de carga diaria

De la siguiente figura se evidencia el comportamiento de la demanda hipotética en el día y de manera continua, misma que está asociada al grupo de cargas. Por lo que, el valor de demanda máxima aparece después de las 18 horas, sin embargo, al colocar un instrumento con intervalos de medición a partir de 15 minutos se guarda como el 97% del valor real.


Por otro lado, si el instrumento mide cada 30 minutos se registra el 90% del valor real y si es de 1 hora se guarda como el 87% a las 18 horas. De esta manera, se recalca que la demanda es la cantidad de medida según el caso de estudio como amperios, fusibles, entre otros. Así mismo, se menciona la sucesión de valores de la demanda en función del tiempo con el nombre de curva de carga [17].



**Figura 3.8:** Curva de demanda [17]

### 3.2.6.2 Curvas de carga anual

Se lo realiza en un periodo de 4 años apropiadamente, para observar cómo está el incremento de la carga a lo largo de estos lapsos de tiempo, estas curvas se forman por los valores de la mande en puntos críticos como la hora pico cada mes, con el fin de identificar los datos y los incrementos de los picos tanto mensual como anual [16]



**Figura 3.9:** Curva de carga anual [20]

### 3.2.6.3 Demanda Máxima

El valor definido es el superior de todas las cargas en el tiempo determinado, además se caracteriza por especificar el intervalo del consumo, unidades y el período [16].

### 3.2.6.4 Carga Instalada

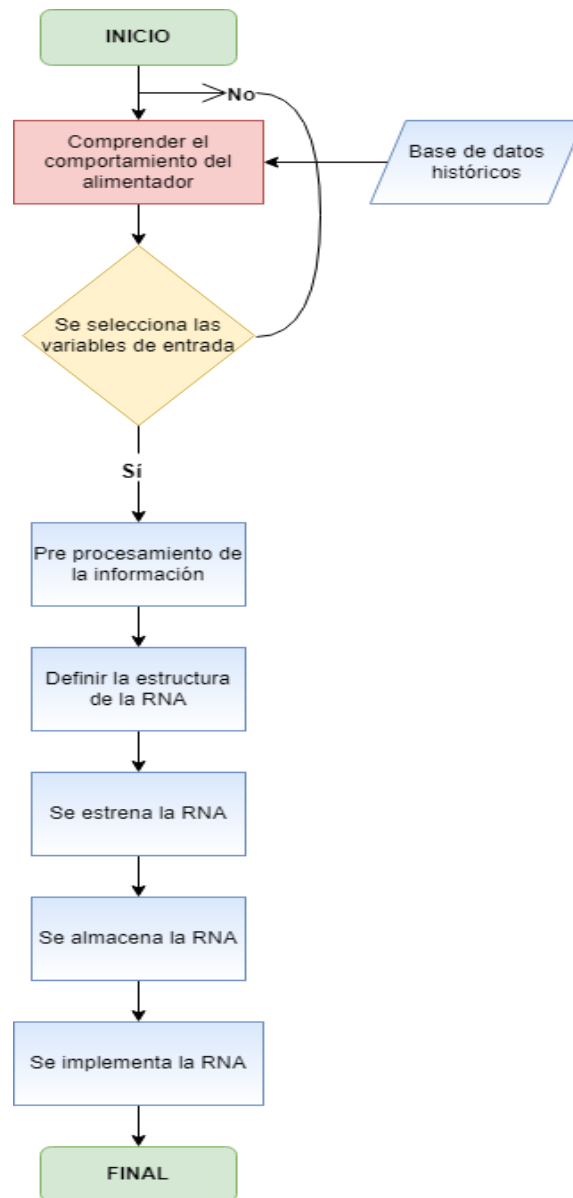
Se considera a la sumatoria de las potencias nominales, en equipos de consumo y aparatos conectados al sistema. Para lo cual, se puede expresar en MW, MVA, kW, kVA [21].

### 3.2.6.5 Capacidad Instalada

Se define como la sumatoria de potencias de los equipos generadores o transformadores, mismos que son instalados en las líneas que almacenan la potencia eléctrica de las cargas. Además, recibe el nombre de capacidad nominal del sistema [16].

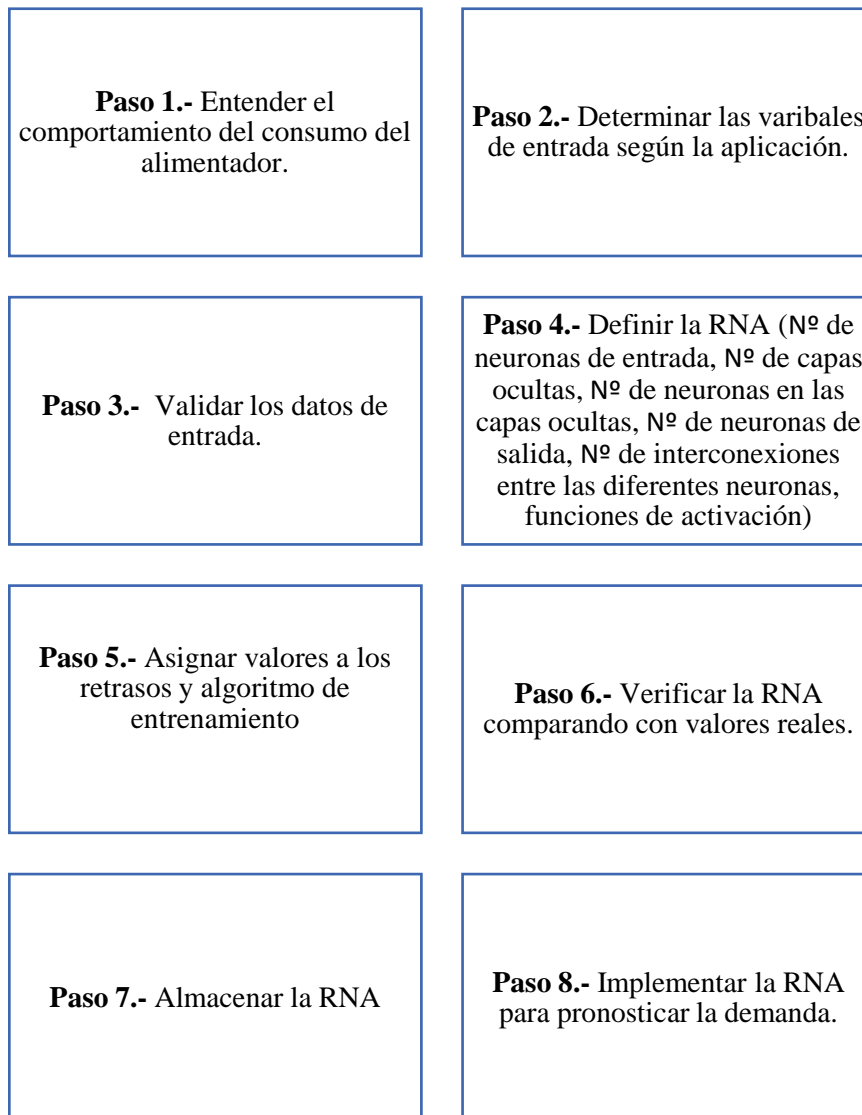
### 3.2.7 Procedimiento para realizar la predicción de la demanda eléctrica mediante redes neuronales artificiales

Este procedimiento se aprecia en la figura 3-4



**Figura 3.10:** Procedimiento para realizar la predicción de la demanda eléctrica

Los pasos para seguir para la implementación descrita son los siguientes:




**Figura 3.11:** Pasos para realizar el pronóstico de la demanda eléctrica mediante redes neuronales artificiales [16]

**Elaborado por:** Elaboración propia

### 3.2.8 Clasificación de los métodos de pronóstico de demanda de Energía Eléctrica

Se pueden clasificar en tres categorías que son horizonte de tiempo, tiempo de demanda eléctrica y técnicas matemáticas, como se detalla a continuación:



**Figura 3.12:** Clasificación de los métodos de pronóstico de demanda [22]

**Elaborado por:** Elaboración propia

En cuanto al horizonte de tiempo se menciona que la planificación será en tres categorías. La de corto plazo es desde un mes hasta un año, la de mediano plazo va hasta cinco años, ambas emplean la construcción de equipos y la operación de estos. Por otro lado, la de largo plazo determina la viabilidad económica de los elementos indicados en los plazos anteriores, el plazo de esta va desde los cinco años hasta los veinticinco años [22].

El tipo de demanda de electricidad hace referencia a la demanda de energía (kWh) o de potencia (kW), la matemática empleada puede ser: estadísticas, inteligencia artificial y análisis por micro áreas. La estadística como la regresión, distribución de probabilidad y series de tiempo. La micro área comprende la tendencial y usos de suelos o simulación. La inteligencia artificial por su lado está en su clasificación las redes neuronales, sistemas de expertos, lógica difusa y redes bayesianas [22].

### 3.2.9 Redes Neuronales

Para poder comprender como funciona y lo que comprende las redes neuronales artificiales existe varias definiciones las cuales van desde pequeñas descripciones, hasta estudios más completo citando así el siguiente concepto [23].

“Las redes neuronales posibilitan la extracción de capacidades cerebrales para solventar problemas, estas son procesadores paralelos distribuidos e interconectados que almacenan conocimiento experimenta”

Otro concepto establecido dice que [23] :

“Son redes interconectadas en paralelo de elementos sencillos y adecuadamente organizados que interactúan con objetos reales del mismo modo que lo hace el sistema”

#### 3.2.9.1 Redes Neuronales Supervisadas y No Supervisadas

Las redes neuronales se clasifican en función de la metodología de adiestramiento, así se tiene: redes de pesos fijos, redes no supervisadas, y redes de entrenamiento supervisado [24]

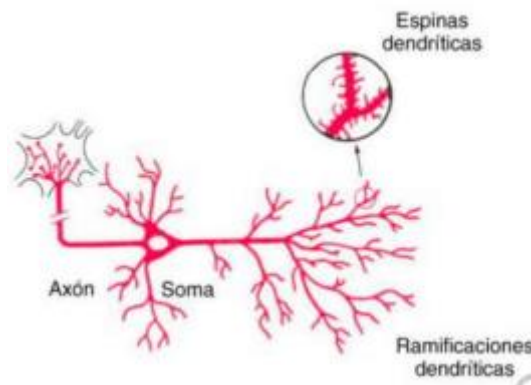
**Reglas de entrenamiento Supervisado:** Es la más empleada. Los datos para el adiestramiento son la entrada y salida, el adiestramiento será inspeccionado por un supervisor que conoce la salida. La fórmula para la adaptación de pesos en la etapa (m +1) se aprecia, a continuación:

$$w_{ij}^{m+1} = w_{ij}^m + \Delta w_{ij}^m$$

**Reglas de Entrenamiento No Supervisado:** Los datos de adiestramiento son la entrada. La red aprende a adaptarse según las experiencias de los patrones de adiestramiento predecesores.

### 3.2.10 Neuronas

Son las células encargadas de transferir la información a través del cuerpo. Poseen una estructura de filamentos que se asemejan a tentáculos que permiten la conexión con otras neuronas. Estos filamentos son conocidos como dendritas estos conectar el cuerpo principal, el soma y los axones para enviar impulsos entre neuronas, apreciar la Figura 7 [25]



**Figura 3.13:** Estructura de una neurona

Las redes neuronales están inspiradas en las neuronas biológicas, así cada neurona posee un receptor de información, la cual envía la información al centro de la neurona donde se procesa y dependiendo de la relevancia de la información podrá ser retransmitida a otras neuronas. La intensidad de retransmisión es conocida como peso ( $w$ ). Dentro de cada neurona la sumatoria de los impulsos puede determinar un valor crítico que facilita la retransmisión de la información recibida [25]

#### 3.2.10.1 Tipos de Redes Neuronales

Existe una diversa cantidad de redes neuronales fabricadas para relacionarse con distintos problemas; esto ya que por la naturaleza de esta y al hecho de que hay dos tipos de redes neuronales las cuales pertenecen a un mismo grupo o a diferentes, dependiendo de la cualidad que se tome.

Se puede identificar dos grupos: las redes neuronales prealimentadas y recurrentes. Las prealimentadas son un operador unidireccional que recibe un vector de valores, por otro lado, las recurrentes son un operador temporal que puede reprocesar la información recibida. Dentro de las redes prealimentadas existe otro tipo de red conocida como



convolutiva que permite analizar la información que otorga un grado de importancia mayor a la distribución especial.


### Clasificación de las Redes Neuronales Artificiales según su aprendizaje

Según [26] existen 3 tipos de aprendizajes los cuales son:

1. Aprendizaje supervisado: Consiste en otorgar salidas deseadas a un conjunto de señales de entrada, es decir, para cada entrada existe una salida, así se crea una tabla llamada tabla de atributo que representa el proceso y comportamiento de las señales, mediante el análisis de esto se formulan hipótesis del aprendizaje.
2. Aprendizaje no supervisado: Se determinan entradas, pero no salidas, de esta manera lo que se busca es similitud de comportamiento de las señales introducidas. El algoritmo de este aprendizaje toma en consideración los pesos y umbrales sinápticos de la red, el diseñador puede definir la magnitud del peso.
3. Aprendizaje por refuerzo: Consiste en otorgar una salida a cada entrada introducida, además, ajustan parámetros neuronales basados en información cualitativa o cuantitativa para evaluar el rendimiento del aprendizaje, se analiza según la funcionalidad, es decir, se hacen pruebas de error y según eso se determina la eficacia, si es eficaz los pesos y umbral sináptico serán elevados.


#### **3.2.11 Sistema Neuronal Artificial**

El elemento primordial de un sistema neuronal biológico es la neurona. Un sistema neuronal está constituido por millones de neuronas que están organizados de manera jerárquica, así, la neurona artificial está organizada en capas que constituyen una red [27]. Por último, una red neuronal con interfaces de entrada y salida conforman el sistema global de proceso, véase la Figura 7.



**Figura 3.14:** Sistema global de proceso de una red neuronal


### 3.2.11.1 Componentes de la red neuronal artificial



**Figura 3.15:** Modelo de neurona artificial standard

La red neuronal se compone por:

1. **Entradas (p):** es la información que recibe la red
2. **Pesos (w):** Valor numérico encargado de determinar la relación de una entrada en la salida deseada.
3. **Bías (b):** valor asociado a una entrada constante 1. El modelo se volverá más flexible.



**Figura 3.16:** BIAS

4. **Función de activación o transferencia (f):** Empleadas para agregar la no linealidad en las redes neuronales.




Figura 3.17: Funciones de activación

### 3.2.11.2 Estructura matemática de la red neuronal

#### Capa 1: Entradas




Figura 3.18: Modelo de la red neuronal

#### Aplicando matrices:

#### Pesos

$$\begin{bmatrix} W_{11}^1 \\ W_{21}^1 \\ W_{31}^1 \\ W_{41}^1 \\ W_{51}^1 \end{bmatrix} \cdot |P_1| + \begin{bmatrix} b_1^1 \\ b_2^1 \\ b_3^1 \\ b_4^1 \\ b_5^1 \end{bmatrix} \quad (3.16)$$

Donde:

$W_{11}^1$  indica el peso,  $P_1$  representa el ingreso 1, y  $b_1^1$  es el bias de la capa 1.

$$n_j = (W * P^T) + b \quad (3.17)$$

$$\begin{bmatrix} n_1^1 \\ n_2^1 \\ n_3^1 \\ n_4^1 \\ n_5^1 \end{bmatrix} = \begin{bmatrix} W_{11}^1 P_1 + b_1^1 \\ W_{21}^1 P_2 + b_2^1 \\ W_{31}^1 P_3 + b_3^1 \\ W_{41}^1 P_4 + b_4^1 \\ W_{51}^1 P_5 + b_5^1 \end{bmatrix} \quad (3.18)$$

$n_1^1$  es la resolución de la primera neurona,  $W$  es el peso de la neurona,  $P_1$  es la entrada de la matriz transpuesta, y  $b_1^1$  es el bios de la capa 1.

Representa de la salida de la capa oculta.

$$\begin{bmatrix} a_1^1 \\ a_2^1 \\ a_3^1 \\ a_4^1 \\ a_5^1 \end{bmatrix} = \begin{bmatrix} f' n_1^1 \\ f' n_2^1 \\ f' n_3^1 \\ f' n_4^1 \\ f' n_5^1 \end{bmatrix} \quad (3.19)$$

Donde

$a_1^1$  indica la salida de la capa oculta,  $f'$  es la función de activación y  $n_1^1$  es la resolución de la neurona.

Donde la función de activación de la capa,  $f'$

$$f' = \frac{d}{dn} \left( \frac{e^n - e^{-n}}{e^n + e^{-n}} \right) \quad (3.20)$$

Al derivar la función de activación se obtiene:

$$a = f' = (1 - (a_1^1)^2) \quad (3.21)$$

La capa de salida 2

Matriz de pesos de la capa de salida

$$[W_{11}^2 + W_{21}^2 + W_{31}^2 + W_{41}^2 + W_{51}^2] \quad (3.22)$$

Donde:

$W_{11}^2$  el peso de la capa de salida

Resultado de la capa de salida

$$n^2 = [a_1^1 W_{11}^2 + a_2^1 W_{21}^2 + a_3^1 W_{31}^2 + a_4^1 W_{41}^2 + a_5^1 W_{51}^2] \quad (3.23)$$

$$a^2 = f^2(n^2 + b_1^2) \quad (3.24)$$

La función de activación de la capa de salida es lineal aplicando la derivada

$$f^2(n) = \frac{d}{dn} = 1 \quad (3.25)$$

Donde:

$f^2(n)$  es la función de la capa 2,  $\frac{d}{dn}$  es la función de activación lineal.

### 3.2.12 Error cuadrático medio

En estadística, el error cuadrático medio (ECM) de un estimador otorga la medición promedio de los errores al cuadrado. El ECM es una función de riesgo, y la diferencia es ocasionada debido a la aleatoriedad. El ECM toma en consideración la varianza del estimador y el sesgo. Para un estimados sin sesgo, el ECM es la varianza, las unidades de medida serán las del estimador, para encontrar la desviación estándar se realiza la raíz cuadrada del ECM.

$$MSE = \frac{1}{N} \sum_{t=1}^N (y_t - f_t)^2 = \frac{SSE}{N} \quad (3.26)$$

Donde:

$y_t$  es el resultado actual en el tiempo t.

$f_t$  es el pronóstico de valor en el tiempo t.

$SSE$  es la suma del error cuadrático.

### 3.2.13 Redes neuronales artificiales

Las redes neuronales artificiales son objetos de programación que imitan el funcionamiento de las neuronas biológicas. Están formadas por la interconexión de redes de manera paralela, además poseen jerarquía para solventar problemas, reaccionan a algún estímulo externo. Son sistemas creados para simular el comportamiento cerebral almacenando una cantidad de información considerable [30].

Las redes neuronales artificiales (RNA) son sistemas de aprendizaje inspirados en el funcionamiento del cerebro humano. Así, simulan sistemas relacionando variables de entradas y salidas. La ventaja primordial de estas redes radica en que procesan información en paralelo en tiempo real, de esta manera se facilita la resolución de problemas (Martínez, 2014). La detección de no-linealidades en problemas permiten el pronóstico de datos económicos y financieros [31].

#### Ventajas de las RNA

- Aprendizaje: Se analizan los datos de entrada de la red y por medio del entrenamiento o una experiencia inicial se aprende.
- Auto organización: Una red neuronal tiene su información organizada internamente.
- Tolerancia a fallos: La redundancia de información permite que la red opere óptimamente así tenga ciertos fallos internos.
- Flexibilidad: Cuando existen cambios menores la RNA los maneja eficazmente y sigue operando con normalidad.
- Tiempo real: Dado que la estructura de RNA es en paralelo, la información puede ser entregada al instante [32].

Entre otras de las ventajas de las RNA, se encuentran:

- La generalización de información
- Otorgar una respuesta adecuada a entradas nunca vistas anteriormente
- Naturaleza distribuida
- Construcción de sistemas eficientes
- Aproximación de funciones no lineales

- Resolución de problemas no complejos y su adaptabilidad frente a cambios en el entorno

Mientras que dentro de las desventajas se mencionan a las siguientes:


- Complejidad de aprendizaje a más información, mayor dificultad
- Tiempo de aprendizaje elevado. Dependerá de la cantidad de patrones a evaluar y de la flexibilidad de la red.
- Falta de interpretación lo que se ha aprendido, la red al final otorga una salida y esta debe ser descifrada por el programador.
- Vasta cantidad de datos para el entrenamiento, si se desea mayor flexibilidad será necesario mayor adiestramiento [33].

### 3.2.13.1 Topología o arquitectura de redes neuronales

Es la organización de las neuronas en la red conformando capas de neuronas. Los parámetros fundamentales de la red son: número de capas, número de neuronas por capa, grado de conectividad y tipo de conexión entre neuronas [34], [35].

### 3.2.13.2 Según la estructura en capas

- Red Neuronal Monocapa.** Neuronas de una misma capa se interconectan lateralmente. Ejemplos de redes de este tipo son la red HOPFIELD y la red BRAIN-STATE-IN-A-BOX. Las redes monocapa se emplean generalmente en deberes de autoasociación; por ejemplo, para regenerar informaciones de entrada que se presenta distorsionada [34].



**Figura 3.19:** Red Neuronal Monocapa [36].

### a) Red Neuronal Multicapa

La red neuronal multicapa además de disponer de entradas y salidas dispone de un conjunto de capas intermedias (capas ocultas). Según el número de conexiones que presente la red esta puede estar total o parcialmente conectada [36].




Figura 3.20: Red Neuronal Multicapa [36].

#### 3.2.13.3 Según el flujo de datos en la red

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

Ninguna salida neuronal es entrada de otra neurona. La información es unidireccional, de la entrada a la salida [30].




Figura 3.21: Red de propagación hacia adelante de tres capas [37].



### **3.2.13.4 Según el tipo de respuesta de la red o asociación entrada y salida**

Las redes neuronales son sistemas que almacenan información, esta se distribuye según los pesos asociados a las conexiones entre neuronas. La memoria asociativa permite establecer relación entre la información de la red y la salida otorgada. Existe dos maneras de realizar esta asociación:

1. **Redes hetero asociativas:** La red aprende parejas de datos [(A1, B1), (A2, B2), ..., (An, Bn)], de tal forma que cuando se le presente determinada información de entrada  $A_i$  responda con la salida correspondiente  $B_i$ . Así, se precisan por lo menos dos capas, una para captar la información en la entrada y otra para mantener la información en la salida. Si no existiese la capa de entrada la red no tendría realimentación para seguir operando y el aprendizaje sería nulo.
2. **Redes auto asociativas:** La red aprende ciertas informaciones  $A_1, A_2, A_n$  de forma que cuando se le presenta una información de entrada realizará una autocorrelación, respondiendo con uno de los datos almacenados, el más parecido al de entrada. Esto puede emplearse en una sola capa de neuronas, el tipo de aprendizaje empleado aquí es el no supervisado, así se solventarán los problemas propuestos [34].

## **4 METODOLOGÍA**

### **4.1 TIPO DE INVESTIGACIÓN**

Dentro de la siguiente indagación se pretende comprender el estado de los sistemas de distribución con respecto al consumo de electricidad a corto plazo en el Barrio San José de Cutuglahua en la ciudad de Quito Provincia de Pichincha; en el cual se involucra el alimentador de análisis ya que a diversas demandas se le agregan o se le quitan en diferentes horas en el transcurso del día, Con esto se propone un estudio más práctico, para realizar la identificación del comportamiento del consumo eléctrico.

#### **4.1.1 Investigación Descriptiva**

Se implementa la metodología analítica, ya que el objeto que a va a ser utilizado para aprender se desglosa de tal forma que se llegue a una comprensión más técnica; se realiza

una exposición de ideas o acontecimientos que definan los aspectos del consumo de electricidad en el barrio San José de Cutuglahua, debido al aumento de la demanda. Este tipo de indagación ayudará a comprender el comportamiento del consumo de electricidad en este sector, para posterior adquirir una base de datos históricos con valores de potencia útil.

#### **4.1.2 Investigación Diagnóstica**

Se brinda las particularidades del problema a tratar llegando así a delimitar el campo de estudio, lo cual ayuda a diagnosticar la situación actual del barrio San José de Cutuglahua; llegando a poder identificar los parámetros a ser analizados dentro de dicho problema, para que a su vez se obtenga un estudio con los datos, permitiendo brindar una solución conforme las partes interesadas requieran.

#### **4.1.3 Investigación Aplicada**

Dentro de este apartado se pondrá en práctica los conocimientos otorgados durante el recorrido académico, así también se implementó el software MATLAB para realizar el estudio y elaboración del algoritmo, el cual permite establecer el pronóstico del consumo de electricidad con los resultados más cercanos a la realidad.

### **4.2 MÉTODO DE INVESTIGACIÓN**

#### **4.2.1 Metodología de la Investigación bibliográfica**

Ayuda a obtener información de varios medios como son libros, proyectos similares, sitios web, publicaciones, artículos científicos que esta relacionados a la pronóstico de la demanda de electricidad. Dando como resultado la obtención de técnicas o la relación de usar varios implementos similares, para que ayuden en la solución del problema ya establecido.

#### **4.2.2 Metodología Inductiva y Deductiva**

Se realiza un examen descriptivo de los procedimientos y objetos que se implementaron dentro del proyecto de investigación, a su vez este proceso permite obtener las conclusiones y recomendaciones al problema de estudio. Respecto al método usado, se realizó el estudio de cada metodología para resolver la predicción del consumo eléctrico;

partiendo de estudios anteriores aplicados a diferentes situaciones pero que se relacionan entre sí, ayudando además a obtener el algoritmo que genera los datos necesarios para llegar a una conclusión propia.

### **4.3 TÉCNICAS E INSTRUMENTOS**

#### **4.3.1 La observación**

Se implantó este tipo de herramienta ya que es la más adecuada para la investigación, ya que, al implementar la RNA para el pronóstico de la demanda de electricidad, dentro de estos se registra los datos obtenidos en el proceso, obteniendo resultados satisfactorios que se pueden visualizar de forma simple.


#### **4.3.2 Simulación**

Mediante la implementación del software MATLAB, se desarrollará la simulación que ayudará a establecer los distintos parámetros a los cuales se refiere la red neuronal relacionándose con los datos históricos del consumo en el Barrio San José de Cutuglahua, para que se puede verificar los datos en el algoritmo propuestos y así analizar los posibles errores que existen.

#### **4.3.3 Programación**

Como en el anterior punto, se usará el software MATLAB, en el cual se diseñará un algoritmo en base a vectores y formulación matemática aplicando redes neuronales artificiales. Se ingresa el histórico de la demanda de consumo de energía, con lo que se identifica el valor de error en el pronóstico.

#### 4.4 METODOLOGÍA DE LA PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA



**Figura 4.1:** Flujograma del pronóstico de la demanda de electricidad

En la figura 5.1 se puede observar los pasos que se va a utilizar para el adiestramiento de la red neuronal y por consiguiente la predicción que se desea realizar, en primer lugar, se identifica las variables que se van a utilizar en este caso es la demanda eléctrica, después se procede a realizar la creación de la base de datos, se depura dichos datos con el método de la media obteniendo así datos de demanda eléctrica diarios, al momento de entrenar mi red neuronal el primer paso es cargar la base de datos en función potencia KW/h de acuerdo a la estructura que se va a utilizar se selecciona datos de entrada para la red neuronal, se selecciona número de neuronas para la capa oculta y se procede a adiestrar la red neuronal si es el resultado es satisfactorio la red procederá a realizar un pronóstico caso contrario volvemos a aumentar o disminuir neuronas en la capa oculta, si tengo un pronóstico acertado con el error deseado que es menos del 5% daremos por finalizado el

programa caso contrario se verá en la obligación de cargar más datos en la base de datos de la red neuronal y así continuar con el proceso

## **5 ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS**


### **5.1 ANÁLISIS DE LA BASE DE DATOS HISTÓRICA**

#### **5.1.1 Análisis del comportamiento de la base de datos real**

Al realizar la predicción del consumo eléctrico, se creó una base de datos dentro de una hoja de Excel, ahí se visualizan datos históricos del consumo kilowatt hora que se realiza por días y por mes.

En primer lugar, se debe conocer el comportamiento de los datos a analizar, posterior a estos definir la mejor técnica que se va a implementar para definir el pronóstico de consumo. La base de datos está formada por cifras reales; respecto al tamaño de la muestra es importante que sea precisa, ya que la demanda no es constante, además se debe tomar en cuenta dentro de un rango definido de tiempo, para predecir su comportamiento.

En la figura 5-2, se aprecia la curva de la mensual del año 2020 en el Sector de San José de Cutuglahua, esta está caracterizada por tener intervalos de tiempo de horas de todo el día. Se puede visualizar que el comportamiento del consumo eléctrico es menor en ciertos horas llegando a su pico más alto alrededor de la hora 19.



**Figura 5.1:** Consumo Eléctrico Mes-Hora Datos Reales


En la tabla 5-1, se aprecia los datos de estudio, los cuales pertenecen a los meses de la base de datos reales para la toma de mediciones, se consigue los valores más elevados y más bajos del consumo donde se visualiza un intervalo de 2717,14 KWh, el cómputo de la frecuencia no se realiza ya que los datos son diferentes.

**Tabla 5.1:** Análisis Descriptivo de Datos Reales

Análisis Descriptivo	
<b>Máximo</b>	4240,70
<b>Mínimo</b>	1527,42
<b>Rango</b>	2717,14
<b>Media</b>	2457,62
<b>Mediana</b>	2456,96

<b>Varianza</b>	417856,26
<b>Desviación Estándar</b>	674,11
<b>Coefficiente de Variación</b>	28,4%

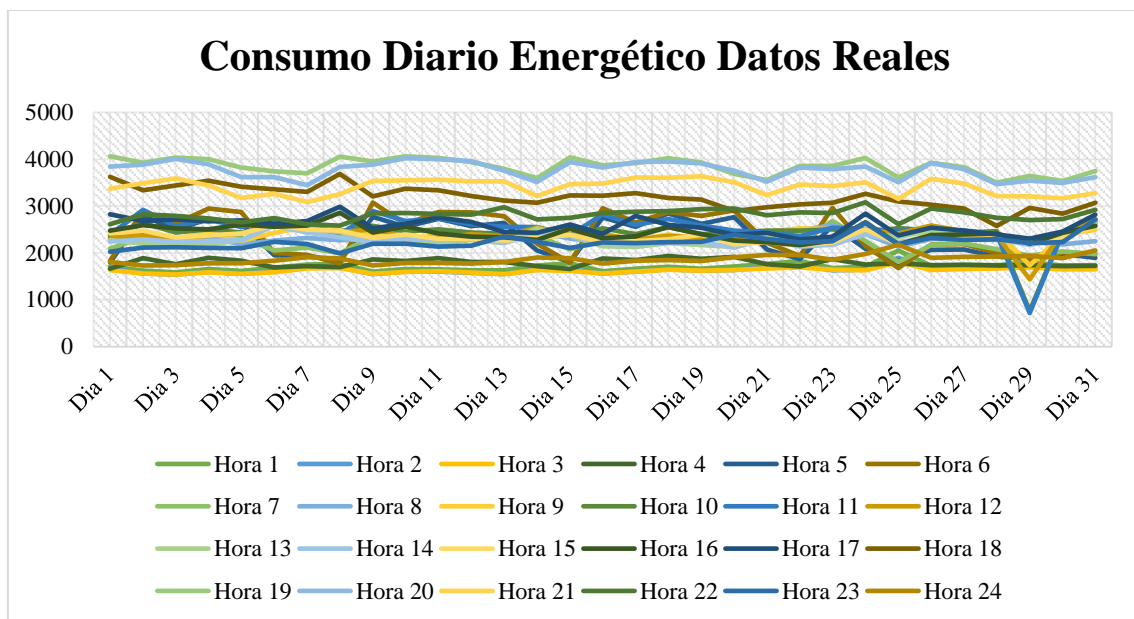
Al realizar los distintos cálculos el promedio o la media es de 2457,62 kWh es decir este valor representa la media del consumo energético que se realiza por cada hora del día, la mediana representa el valor central de la recopilación de datos, la mitad de estos se encuentran por debajo y la otra mitad se encuentra por encima de 2456,96 kWh, no se puede definir el valor de la moda ya que no se repite ningún dato. Las medidas de dispersión reflejan que tan lejos o cerca se encuentran los datos en referencia a la tendencia central. La varianza representa la inestabilidad que existe dentro del grupo de datos, en este caso la media que se obtiene es una cantidad sumamente elevada; la desviación estándar muestra que tan alejado o cercano están las cantidades con respecto al promedio, obteniendo un valor de 674,1 KW/h, es decir en base al coeficiente de variación se tiene el porcentaje de dispersión de los valores que es del 28,4% lo que quiere decir que no existe homogeneidad en los mismos.



**Figura 5.2:** Consumo del Mes de Enero en el Sector de San José de Cutuglahua Datos Reales

En la figura 5.3, se aprecia la curva del consumo real del consumo energético respecto a un mes que es en este caso enero de 2020, con intervalos de cada hora. Para esta situación el proceder dependerá de las variables; en la figura respectiva se puede verificar que el comportamiento del consumo eléctrico crece mientras transcurren las horas del día de forma progresiva llegando a su punto máximo entre la hora 19 y hora 20, y llegó a su punto más bajo entre la hora 3 del día.

Para visualizar el comportamiento de la curva pronosticada del consumo energético en la figura 5-4, se grafica datos de los días que corresponden al mes de enero de 2020 con los datos de la base real.




**Figura 5.3:** Consumo Energético Diario Datos Reales

### 5.1.2 Análisis del comportamiento del consumo eléctrico pronosticado

En la figura 5.5, se aprecia la curva del consumo mensual predicha en base a la red neuronal que se tomó del año 2020, del consumo energético, durante las 24 horas del día.





**Figura 5.4:** Gráfica Consumo Eléctrico Mes-Hora Predicción

En la tabla 5.3, se detalla los datos de estudio, los cuales pertenecen a los meses pronosticados de referencia para la toma de mediciones, se obtiene valores máximos y mínimos del consumo eléctrico donde nos presenta un intervalo de 2617,18 KWh, de igual forma que en los datos reales el cálculo de la frecuencia no se realiza ya que los datos difieren.

**Tabla 5.2:** Análisis descriptivo de los datos de predicción

Análisis Descriptivo	
<b>Máximo</b>	4140,60
<b>Mínimo</b>	1523,42
<b>Rango</b>	2617,18
<b>Media</b>	2458,96
<b>Mediana</b>	2455,96

<b>Varianza</b>	427856,26
<b>Desviación Estándar</b>	654,11
<b>Coefficiente de Variación</b>	27%

Al realizar los distintos cálculos el promedio o la media es de 2458,96 kWh es decir este valor representa la media del consumo energético que se realiza por cada hora del día, la mediana representa el valor central de la recopilación de datos, la mitad de estos se encuentran por debajo y la otra mitad se encuentra por encima de 2455,96 kWh, no se puede definir el valor de la moda ya que no se repite ningún dato. Las medidas de dispersión reflejan que tan lejos o cerca se encuentran los datos en referencia a la tendencia central. La varianza representa la inestabilidad que existe dentro del grupo de datos, en este caso la media que se obtiene es una cantidad muy alta; la desviación estándar muestra obtenida es de 654,1 KW/h, es decir en base al coeficiente de variabilidad se tiene el porcentaje de dispersión que es del 27% lo que quiere decir que no existe homogeneidad en los mismos.

## 5.2 INTERFASES GRÁFICAS DESARROLLADAS

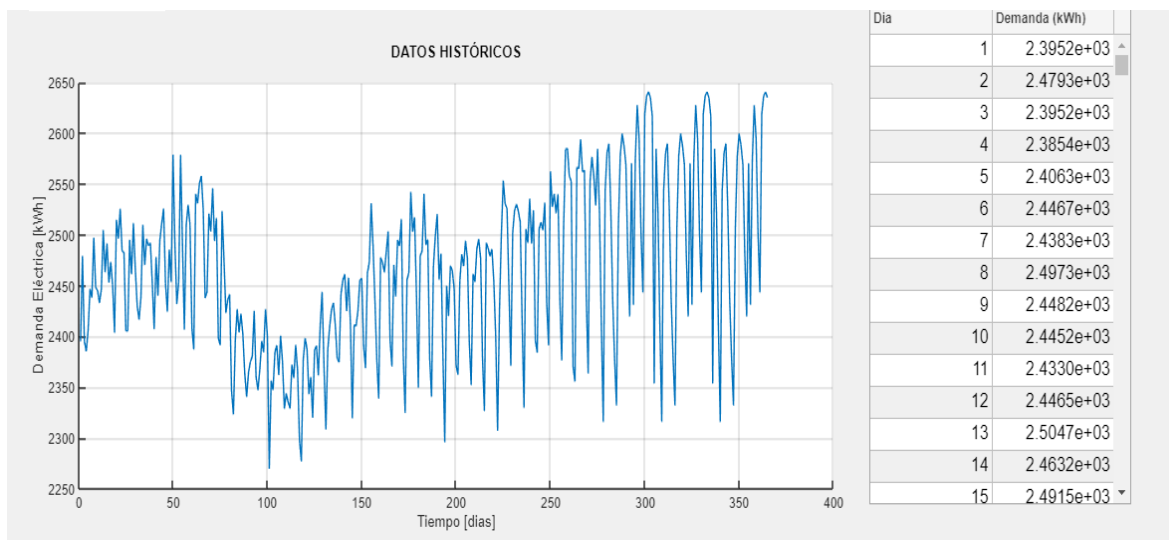
Esta subsección describe y valida el funcionamiento de una interfaz gráfica realizada en Matlab para el pronóstico del consumo eléctrico. Se obtiene los resultados de pronóstico en forma numérica y gráfica obtenidos para el caso estudiado que es la demanda eléctrica del Barrio San José de Cutuglahua.

La interfaz gráfica desarrollada se divide en tres módulos: módulo “histórico de la demanda eléctrica”, módulo de “propiedades de red neuronal” y módulo de “predicciones”, cada modulo son consecuentes y permiten el buen funcionamiento de la predicción.

A continuación, se muestra cada módulo


### 5.2.1 Módulo “histórico de la demanda eléctrica”

Muestra la tendencia de la demanda eléctrica en lapso de 1 día así por los 365 días, y a más de ello podemos verificar en la parte izquierda la tabla de valores de los datos reales graficados




### 5.2.2 Módulo de “propiedades de red neuronal”

Muestra con qué tipo de aprendizaje la red va a entrenar, tenemos la opción de poner el número de capas, los algoritmos de entrenamiento, los datos de adiestramiento, los datos de validación y los datos de prueba, el número de neuronas y por último podemos visualizar la gráfica de la tendencia de la curva de los valores reales con la curva de entrenamiento.



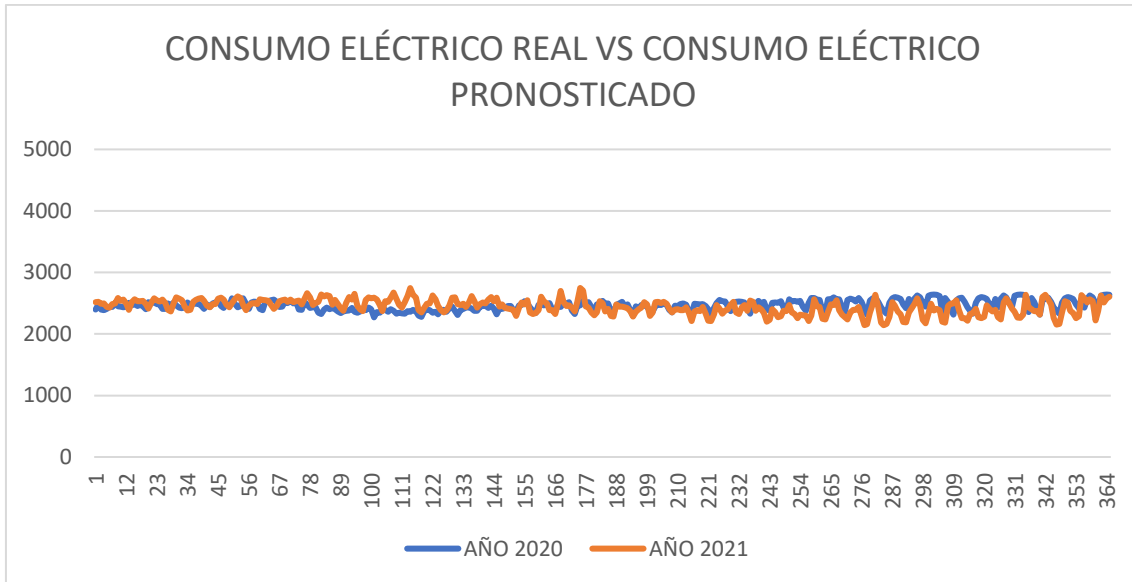
### 5.2.3 Módulo de “predicciones”

La finalidad del presente módulo es mostrar en una pantalla la interfaz gráfica de la curva de predicción arrojada por la red neuronal, un resultado numérico-gráfico que permite visualizar los datos de demanda eléctrica para años futuros.



COMPARACIÓN DE LA BASE DE DATOS REALES CON LOS DATOS PRONOSTICADOS DE LA RED NEURONAL

En la figura 5.8, se aprecia el comportamiento de la curva del consumo eléctrico con datos reales del año 2020 y también con el pronóstico del consumo eléctrico del año 2021, dentro del cual se verifica que actúan de manera similar en el crecimiento y reducción del consumo.



**Figura 5.5:** Curva del Consumo Eléctrico Real VS Pronosticada

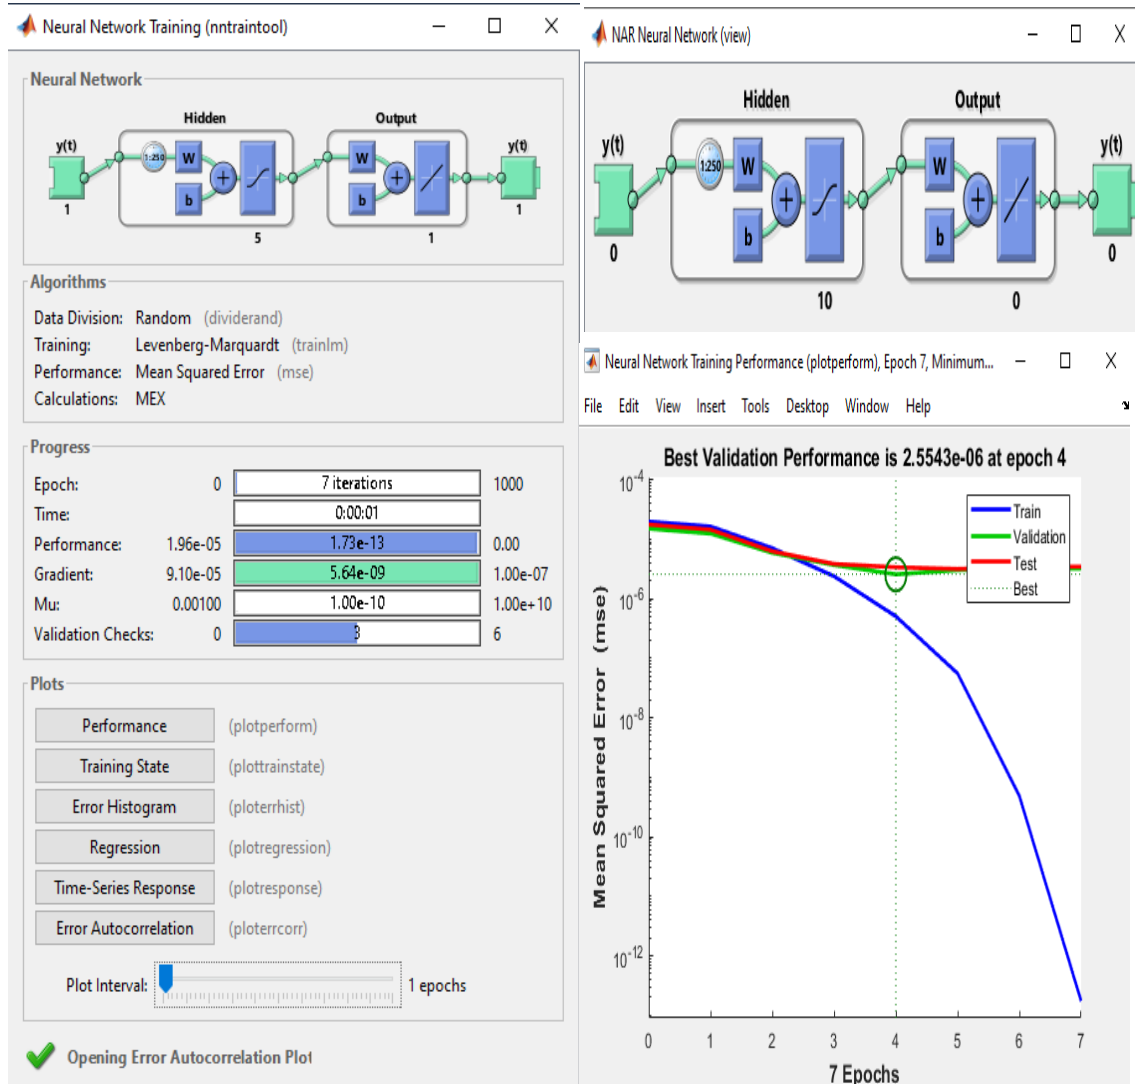
Por consiguiente, se representa el porcentaje de error de los datos reales y de la predicción de demanda, en la tabla 5-3, se aprecia el error de 4,06% que representa la comparación de valores de las dos curvas de la demanda de electricidad, por lo tanto, se determina que el pronóstico es eficiente.

**Tabla 5.3:** Error promedio anual entre demanda eléctrica real y pronosticada

<b>Error</b>	
<b>Error Promedio</b>	0,04062996
<b>Error Promedio %</b>	4,06%


En la figura 5.8, se aprecia el resultado de la simulación con los siguientes datos ingresados: número de retrasos 250, número de neuronas 5, entrenamiento de datos al

70%, prueba al 15% y de validación al 15%, la red bajo análisis considera un estado normal fitting, dado que se ingresan datos específicos. Según los resultados se visualiza el comportamiento del ajuste normal del entrenamiento de la red neuronal.




**Figura 5.8:** Red neuronal en normal fitting (ajuste normal).

En la figura 5.9, se observa el histograma de error, este está en el intervalo de -0,00113 a 0,000553, la mayor parte de valores están en  $5,53 \cdot 10^{-5}$ , así se evidencia un funcionamiento óptimo del consumo energético.



**Figura 5.9:** Histograma de error.

En la figura 5.10, se aprecia la pendiente de regresión que posee un ínfimo error, con un valor de adiestramiento de  $R= 0.99932$ , siendo un resultado eficiente para la predicción del caso.



**Figura 5.9:** Pendiente de regresión a 45° de la red neuronal (ajuste normal).

## 6 CONCLUSIONES Y RECOMENDACIONES

### 6.1 CONCLUSIONES

Dentro de la programación, se implementó librerías de redes neuronales de MATLAB, y para la predicción de series de tiempo, cuanta con la red NARNET, que tiene como datos de entrada los datos previos del consumo energético. Al realizar el entrenamiento de la red neuronal configurada, se visualizó tanto la configuración, así como la arquitectura de la misma, así como se implementó parámetros para el entrenamiento de la red neuronal para establecer la estimación de la demanda eléctrica requerida usando las librerías de MATLAB.

Comparar la demanda eléctrica actual con la demanda eléctrica de predicción entregada por la red neuronal.

Con los parámetros establecidos en base a revisión bibliográfica y la metodología, además de la implementación de herramientas, se pudo concretar el diseño y creación de una red neuronal que ayude en a predecir de forma eficaz el consumo energético que se tiene en el sector de San José de Cutuglahua de la Ciudad de Quito, beneficiando así a los moradores de este sector en las necesidades que puedan llegar a tener respecto a este tema.

Entre los métodos heurísticos empleados para resolver de problema de predicción de demanda eléctrica se encuentran en primer lugar, el algoritmo genético, que tiene la función de complementar el procedimiento que se ejecuta de forma manual sobre el control de demanda, denominado acomodo de cargas, con el fin de reducir al mínimo el consumo de energía en horarios determinados. Así como también, las redes neuronales o redes neuronales artificiales, no requiere un modelo de carga, que permite la predicción de demanda eléctrica.

La depuración de los datos obtenidos de la demanda eléctrica horaria del barrio San José Cutuglahua, se realizó luego de la creación de una base de datos en el software Excel, encontrando datos históricos del consumo kilowatt hora tanto por días y meses, dado que se analizó el comportamiento de los datos para en lo posterior definir cuáles se iban a emplear, dando como resultado, una base de datos formado por cifras reales mensuales del año 2020, tomando como referencia el mes de enero con sus 31 días calendario, caracterizada por tener intervalos de tiempo de horas de todo el día, siendo el pico más alto alrededor de la hora 19. Además, se obtuvo valores más elevados y bajos de la demanda eléctrica en un rango de 2717,14 KWh, media de 2457,62 kWh, correspondiente al consumo energético que se realizó por cada hora al día.

En base a los datos obtenidos del análisis del consumo energético del Sector de San José de Cutuglahua, en los meses del año 2020, tomando como referencia el mes de enero con sus 31 días calendario, se concluye que el modelo realizado a partir del método de redes neuronales artificiales, muestra un ajuste mejorado al comportamiento de los resultados analizados con un error porcentual del 4.06%, indicativo de niveles muy bajos, y con la ayuda del modelo, se mejora los pronósticos tanto a nivel diario como mensual, acorde a las necesidades que se presenten, aceptando la hipótesis planteada, es posible diseñar una red neuronal que pronostique la demanda de energía eléctrica haciendo uso de la información de datos históricos de demanda eléctrica con los que se cuenta y los modelos de Red Neuronal que se aplican a series de tiempo.



## **6.2 RECOMENDACIONES**

Se recomienda aumentar variables como los cambios climáticos, aspectos geográficos, hábitos de consumo, entre otros, que puedan afectar al consumo de energía, pero a la vez, permitan predecir de manera más adecuada este consumo de energía eléctrica.

Se sugiere realizar los análisis a través de software libres que no impliquen elevados gastos al investigador, como el caso de Python.

Es recomendable realizar investigaciones similares, empleando diversos campos de la inteligencia artificial, para establecer comparaciones.

## 7 BIBLIOGRAFÍA

- [1] E. J. M. Vásquez and S. G. Chávez, “Predicción del consumo de energía eléctrica residencial de la Región Cajamarca mediante modelos Holt -Winters/Prediction of residential electric power consumption in the Cajamarca Region through Holt -Winters models,” *Ingeniería Energética*, vol. 40, no. 3, pp. 181–191, Aug. 2019, Accessed: Dec. 29, 2021. [Online]. Available: <https://rie.cujae.edu.cu/index.php/RIE/article/view/569>
- [2] H. Albino, D. Guillermo, and G. Murillo, “Libro-Redes neuronales Related papers Redes Neuronales Art ificiales y sus Aplicaciones Ronald Mora REDES NEURONALES ART IFICIALES Y SUS APLICACIONES Tabla de Cont enidos”.
- [3] S. A. Velázquez, González Nápoles Julio Osvaldo, D. Peña Rodríguez, and D. Jaime García, “Consumo de energía eléctrica usando redes neuronales artificiales,” Aug. 14, 2014. Accessed: Dec. 28, 2021. [Online]. Available: <https://www.eumed.net/rev/tlatemoani/16/energia.html>
- [4] “INFORMACIÓN AMBIENTAL EN HOGARES,” 2012.
- [5] Carrión J, “Implementación de una Red Neuronal Artificial para la predicción de la Demanda Eléctrica a corto plazo,” *Revista Técnica Energía*, pp. 36–42, Dec. 16, 2016. Accessed: Dec. 28, 2021. [Online]. Available: <http://revistaenergia.cenace.gob.ec/index.php/cenace/article/view/5/4>
- [6] R. Ramos Lira, “Diseño de una red Neuronal Artificial para la predicción de la demanda eléctrica ,” Michoacán, 2011. Accessed: Dec. 28, 2021. [Online]. Available: [http://bibliotecavirtual.dgb.umich.mx:8083/xmlui/bitstream/handle/DGB\\_UMICH/5374/FIM-M-2011-0021.pdf?sequence=1&isAllowed=y](http://bibliotecavirtual.dgb.umich.mx:8083/xmlui/bitstream/handle/DGB_UMICH/5374/FIM-M-2011-0021.pdf?sequence=1&isAllowed=y)
- [7] G. X. Carpio Suárez and Daga López Paúl Alexander, “APLICACIÓN DE UNA RED NEURONAL A UN SISTEMA ELÉCTRICO DE DISTRIBUCIÓN MEDIANTE EL ANÁLISIS DE COMPORTAMIENTO DE SU CARGA EN BAJO VOLTAJE,” 2019.

- [8] D. Montero and G. Ku Leuven, “HERRAMIENTA PARA PREDECIR EL CONSUMO DE ENERGÍA ELÉCTRICA MEDIANTE REDES NEURONALES ARTIFICIALES,” 2014, Accessed: Dec. 28, 2021. [Online]. Available: <https://www.researchgate.net/publication/301552355>
- [9] J. A. Guamán Pachacama and G. B. Segura Muñoz, “Red neuronal Long Short-Term Memory (LSTM) Aplicada a series temporales para pronosticar Consumo energético en edificaciones.,” 2020, Accessed: Dec. 28, 2021. [Online]. Available: <http://repositorio.ug.edu.ec/bitstream/redug/52643/1/B-CISC-PTG-1894-2021%20Guam%c3%a1n%20Pachacama%20Jos%c3%a9%20Arturo%20-%20Segura%20Mu%c3%b1oz%20G%c3%a9nesis%20Brigitte.pdf>
- [10] J. A. Cano, A. A. Correa-Espinal, and R. A. Gómez-Montoya, “Solución del Problema de Conformación de Lotes en Almacenes utilizando Algoritmos Genéticos Solving the Order Batching Problem in Warehouses using Genetic Algorithms,” *Información Tecnológica*, vol. 29, no. 6, pp. 235–244, 2018, doi: 10.4067/S0718-07642018000600235.
- [11] J. A. Diego-Más, “Optimización de la distribución en planta de instalaciones industriales mediante algoritmos genéticos,” 2006. Accessed: Jan. 10, 2022. [Online]. Available: <https://riunet.upv.es/bitstream/handle/10251/135821/Tesis.pdf?sequence=2>
- [12] J. Cevallos Ampuero and R. Eyzaguirre Tejada, “MEJORA DE PROCESOS UTILIZANDO RESPUESTAS CUALITATIVAS MEDIANTE EL USO DE REDES NEURONALES (1),” 2005.
- [13] J. M. Ortiz-Rodríguez, M. R. Martínez-Blanco, and H. R. Vega-Carrillo, “Robust design of artificial neural networks applying the taguchi methodology and DoE,” *Proceedings - Electronics, Robotics and Automotive Mechanics Conference, CERMA 2006*, vol. 2, pp. 131–136, 2006, doi: 10.1109/CERMA.2006.83.
- [14] N. Obregón and S. Garavito, “PREDICCIÓN DE SERIES DE TIEMPO HIDRICAS MEDIANTE MODELOS DE REDES NEURONALES ARTIFICIALES Y MODELOS DE ARBOLES DE DECISION,” 2012, Accessed: Jan. 10, 2022. [Online]. Available: [www.stowa-nn.ihe.nl/index.html](http://www.stowa-nn.ihe.nl/index.html),

- [15] C. G. Origel Rivas, E. R. Rendón Lara, I. M. Abundez Barrera, and R. A. Eleuterio, “Redes neuronales artificiales y árboles de decisión para la clasificación con datos categóricos,” *Computing Science*, vol. 8, pp. 541–554, 2020, Accessed: Jan. 10, 2022. [Online]. Available: [https://rcs.cic.ipn.mx/2020\\_149\\_8/Redes%20neuronales%20artificiales%20y%20arboles%20de%20decision%20para%20la%20clasificacion%20con%20datos%20categoricos.pdf](https://rcs.cic.ipn.mx/2020_149_8/Redes%20neuronales%20artificiales%20y%20arboles%20de%20decision%20para%20la%20clasificacion%20con%20datos%20categoricos.pdf)
- [16] H. Naula and D. Oscurio, “Predicción De La Demanda De Energía Eléctrica A Corto Plazo Utilizando Redes Neuronales Artificiales,” Universidad Técnica de Cotopaxi, 2021.
- [17] J. Alvarado, “Carga, demanda y energía eléctrica: Conceptos fundamentales para la distribución de electricidad,” *Artículos técnicos*, 2017. <https://www.sectorelectricidad.com/17597/carga-demanda-y-energia-electrica-conceptos-fundamentales-para-la-distribucion-de-electricidad/>
- [18] Agencia de Regulación y Control de Electricidad, “PLIEGO TARIFARIO PARA LAS EMPRESAS ELÉCTRICAS DE DISTRIBUCIÓN SERVICIO PÚBLICO DE ENERGÍA ELÉCTRICA Periodo: Enero-Diciembre 2018,” 2018.
- [19] Catedras, “Curva de Carga o Demanda,” 2017.
- [20] C. Luévano, “Análisis de la reconfiguración de sistemas eléctricos de distribución,” 2020. Accessed: Mar. 29, 2022. [Online]. Available: [https://rinacional.tecnm.mx/bitstream/TecNM/1610/2/G12070470\\_donacion\\_tesis\\_bib\\_CSL\\_Tesis.pdf](https://rinacional.tecnm.mx/bitstream/TecNM/1610/2/G12070470_donacion_tesis_bib_CSL_Tesis.pdf)
- [21] L. Calvo, “Comparación de demandas de diseño en sistemas eléctricos de distribución.,” Quito, 1980.
- [22] B. Mayorga, “PRONÓSTICO ESPACIAL DE DEMANDA ELÉCTRICA MEDIANTE LA TÉCNICA DE AGRUPAMIENTO (CLUSTERING) DE CURVAS S HISTÓRICAS - APLICACIÓN A LA EMPRESA ELÉCTRICA AMBATO REGIONAL CENTRO NORTE S.A.,” ESCUELA POLITÉCNICA NACIONAL, 2018.

- [23] D. A. Ortiz Parra, “APLICACIÓN DE REDES NEURONALES ARTIFICIALES EN EL PRONÓSTICO DE LA DEMANDA ELÉCTRICA A CORTO PLAZO EN EL SNAI,” Quito, 2014. Accessed: Mar. 03, 2022. [Online]. Available: <https://dspace.ups.edu.ec/bitstream/123456789/6672/7/UPS%20-%20KT00835.pdf>
- [24] J. San Miguel Salas, “Desarrollo con MATLAB de una Red Neuronal para estimar la demanda de Energía Eléctrica,” 2016. Accessed: Mar. 03, 2022. [Online]. Available: <https://uvadoc.uva.es/bitstream/handle/10324/18120/TFM-P-400.pdf?sequence=1&isAllowed=y>
- [25] D. Barrero González, “Implementación de una Red Neuronal Elman para el modelado de contaminantes aéreos PM y O<sub>3</sub>,” Santiago de Querétaro, 2021. Accessed: Mar. 03, 2022. [Online]. Available: <http://ri-ng.uaq.mx/bitstream/123456789/3327/1/IGLIN-163743-1121-1121-David%20Barrero%20Gonz%c3%a1lez%20%20-A.pdf>
- [26] R. Fagundo Mesa, “Software para el monitoreo en tiempo real del consumo de energía eléctrica,” Matanzas, 2020. Accessed: Mar. 03, 2022. [Online]. Available: [http://cict.umcc.cu/repositorio/tesis/Trabajos%20de%20Diploma/Ingenier%C3%ADa%20Inform%C3%A1tica/2020/Software%20para%20el%20monitoreo%20en%20tiempo%20real%20del%20consumo%20de%20energ%C3%ADa%20el%C3%A9ctrica%20\(Renier%20Fagundo%20Mesa\).pdf](http://cict.umcc.cu/repositorio/tesis/Trabajos%20de%20Diploma/Ingenier%C3%ADa%20Inform%C3%A1tica/2020/Software%20para%20el%20monitoreo%20en%20tiempo%20real%20del%20consumo%20de%20energ%C3%ADa%20el%C3%A9ctrica%20(Renier%20Fagundo%20Mesa).pdf)
- [27] P. Larrañaga, I. Inza, and A. Moujahid, “Tema 8. Redes Neuronales,” 2011. Accessed: Mar. 03, 2022. [Online]. Available: <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales.pdf>
- [28] N. Rizkalla and P. Hildgen, “Artificial Neural Networks: Comparison of two programs for modeling a process of nanoparticle preparation,” *Drug Development and Industrial Pharmacy*, vol. 31, no. 10, pp. 1019–1033, Dec. 2005, doi: 10.1080/03639040500306294.
- [29] A. Fojnica, A. Osmanović, and A. Badnjević, “Dynamical model of Tuberculosis-Multiple Strain Prediction based on artificial neural network,” in *2016 5th Mediterranean Conference on Embedded Computing, MECO 2016 - Including*

- ECyPS 2016, BIOENG.MED 2016, MECO: Student Challenge 2016*, Jul. 2016, pp. 290–293. doi: 10.1109/MECO.2016.7525763.
- [30] W. Rivas, A. Bertha, and M. Olivo, *Redes neuronales artificiales aplicadas al reconocimiento de patrones*, 1st ed., vol. 1. 2018. Accessed: Feb. 08, 2022. [Online]. Available: [https://www.researchgate.net/profile/Bertha-Mazon-Olivo/publication/327703478\\_Capitulo\\_1\\_Generalidades\\_de\\_las\\_redes\\_neuronales\\_artificiales/links/5b9fe3c0299bf13e6038a1d8/Capitulo-1-Generalidades-de-las-redes-neuronales-artificiales.pdf](https://www.researchgate.net/profile/Bertha-Mazon-Olivo/publication/327703478_Capitulo_1_Generalidades_de_las_redes_neuronales_artificiales/links/5b9fe3c0299bf13e6038a1d8/Capitulo-1-Generalidades-de-las-redes-neuronales-artificiales.pdf)
- [31] F. Villada, N. Muñoz, and E. García, “Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro,” *Información tecnológica*, vol. 27, no. 5, pp. 143–150, 2016, doi: 10.4067/S0718-07642016000500016.
- [32] E. Andrade, “Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación ,” Cuenca, 2016. Accessed: Feb. 08, 2022. [Online]. Available: <https://1library.co/document/y91mdnlq-universidad-polit%C3%A9cnica-salesiana-sede-cuenca.html>
- [33] H. Gómez, “Definición, ventajas y desventajas de las redes neuronales,” 2019. <http://redes-neuronales.wikidot.com/definicion-ventajas-desventajas> (accessed Feb. 08, 2022).
- [34] H. Moya, “Características de las redes neuronales,” 2016. <https://thales.cica.es/rd/Recursos/rd98/TecInfo/07/capitulo3.html> (accessed Feb. 08, 2022).
- [35] M. Villanueva, “Las Redes Neuronales Artificiales y su importancia como herramienta en la toma de decisiones,” pp. 1–3, 2019, Accessed: Feb. 08, 2022. [Online]. Available: [https://sisbib.unmsm.edu.pe/bibvirtualdata/Tesis/Basic/Villanueva\\_EM/enPDF/Cap4.pdf](https://sisbib.unmsm.edu.pe/bibvirtualdata/Tesis/Basic/Villanueva_EM/enPDF/Cap4.pdf)
- [36] D. Calvo, “Clasificación de redes neuronales artificiales,” Jul. 12, 2017. <https://www.diegocalvo.es/clasificacion-de-redes-neuronales-artificiales/> (accessed Feb. 08, 2022).

- [37] H. Hopfield, “Redes Neuronales,” pp. 1–8, 2017, Accessed: Feb. 08, 2022.  
[Online]. Available: <https://webs.ucm.es/info/pslogica/redesdoc.pdf>

## 8 ANEXOS

**Tabla 8.1:** Transformadores instalados en el Primario “C” 37 SANTA ROSA

TIPO	Código Puesto	Potencia (KVA)	Voltaje	Parroquia (Barrio)	TOTAL CLIENTES
Transformador Monofásico en Poste	37199	50	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	36872	37,5	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	37306	37,5	13.16 kV	CUTUGLAHUA	46
Transformador Monofásico en Poste	37347	37,5	13.16 kV	CUTUGLAHUA	49
Transformador Monofásico en Poste	R168628	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	44546	37,5	13.16 kV	CUTUGLAHUA	40
Transformador Monofásico en Poste	37994	37,5	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	167750	50	13.16 kV	CUTUGLAHUA	58
Transformador Monofásico en Poste	168644	10	13.16 kV	CUTUGLAHUA	5
Transformador Monofásico en Poste	36122	37,5	13.16 kV	CUTUGLAHUA	33
Transformador Monofásico en Poste	41065	37,5	13.16 kV	CUTUGLAHUA	28
Transformador Monofásico en Poste	39228	50	13.16 kV	CUTUGLAHUA	36
Transformador Monofásico en Poste	22313	37,5	13.16 kV	CUTUGLAHUA	54
Transformador Monofásico en Poste	42708	25	13.16 kV	CUTUGLAHUA	11
Transformador Monofásico en Poste	49758	37,5	13.16 kV	CUTUGLAHUA	47
Transformador Monofásico en Poste	42790	25	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	170337	25	13.16 kV	CUTUGLAHUA	8
Transformador Trifásico en Poste	172016	50	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	172119	30	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	25129	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	173625	75	13.16 kV	CUTUGLAHUA	67
Transformador Monofásico en Poste	173909	75	13.16 kV	CUTUGLAHUA	36
Transformador Monofásico en Poste	173160	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	173163	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	163554	50	13.16 kV	CUTUGLAHUA	60
Transformador Monofásico en Poste	167461	50	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	37755	37,5	13.16 kV	CUTUGLAHUA	38
Transformador Monofásico en Poste	43750	37,5	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	37517	37,5	13.16 kV	CUTUGLAHUA	58
Transformador Monofásico en Poste	37509	37,5	13.16 kV	CUTUGLAHUA	65
Transformador Monofásico en Poste	40996	10	13.16 kV	CUTUGLAHUA	68
Transformador Monofásico en Poste	37211	50	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	15049	50	13.16 kV	CUTUGLAHUA	63
Transformador Monofásico en Poste	37363	37,5	13.16 kV	CUTUGLAHUA	75
Transformador Monofásico en Poste	39592	37,5	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	45299	50	13.16 kV	CUTUGLAHUA	69
Transformador Monofásico en Poste	44505	25	13.16 kV	CUTUGLAHUA	50
Transformador Monofásico en Poste	38098	25	13.16 kV	CUTUGLAHUA	55
Transformador Monofásico en Poste	37146	25	13.16 kV	CUTUGLAHUA	30



Transformador Monofásico en Poste	44708	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	37126	25	13.16 kV	CUTUGLAHUA	52
Transformador Monofásico en Poste	37120	25	13.16 kV	CUTUGLAHUA	22
Transformador Monofásico en Poste	40639	25	13.16 kV	CUTUGLAHUA	45
Transformador Monofásico en Poste	101280	37,5	13.16 kV	CUTUGLAHUA	33
Transformador Monofásico en Poste	39725	50	13.16 kV	CUTUGLAHUA	23
Transformador Monofásico en Poste	168910	25	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	173041	75	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	172796	50	13.16 kV	CUTUGLAHUA	15
Transformador Monofásico en Poste	45886	50	13.16 kV	CUTUGLAHUA	55
Transformador Monofásico en Poste	173159	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175064	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	108524	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175063	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175065	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	40195	15	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	48356	50	13.16 kV	CUTUGLAHUA	47
Transformador Monofásico en Poste	22319	37,5	13.16 kV	CUTUGLAHUA	67
Transformador Monofásico en Poste	70778	37,5	13.16 kV	CUTUGLAHUA	40
Transformador Monofásico en Poste	22314	37,5	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	21364	37,5	13.16 kV	CUTUGLAHUA	75
Transformador Monofásico en Poste	41489	25	13.16 kV	CUTUGLAHUA	16
Transformador Monofásico en Poste	39403	37,5	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	44627	37,5	13.16 kV	CUTUGLAHUA	38
Transformador Monofásico en Poste	70721	37,5	13.16 kV	CUTUGLAHUA	57
Transformador Monofásico en Poste	70773	50	13.16 kV	CUTUGLAHUA	45
Transformador Monofásico en Poste	50931	37,5	13.16 kV	CUTUGLAHUA	104
Transformador Monofásico en Poste	45739	37,5	13.16 kV	CUTUGLAHUA	26
Transformador Monofásico en Poste	116060	37,5	13.16 kV	CUTUGLAHUA	47
Transformador Monofásico en Poste	24767	37,5	13.16 kV	CUTUGLAHUA	67
Transformador Monofásico en Poste	39366	25	13.16 kV	CUTUGLAHUA	42
Transformador Monofásico en Poste	51353	37,5	13.16 kV	CUTUGLAHUA	76
Transformador Monofásico en Poste	44444	25	13.16 kV	CUTUGLAHUA	26
Transformador Monofásico en Poste	44500	25	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	22322	25	13.16 kV	CUTUGLAHUA	32
Transformador Monofásico en Poste	22318	25	13.16 kV	CUTUGLAHUA	45
Transformador Monofásico en Poste	37112	25	13.16 kV	CUTUGLAHUA	31
Transformador Monofásico en Poste	37108	25	13.16 kV	CUTUGLAHUA	34
Transformador Trifásico en Cabina	166525	125	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	168913	25	13.16 kV	CUTUGLAHUA	68
Transformador Monofásico en Poste	168909	25	13.16 kV	CUTUGLAHUA	10
Transformador Trifásico en Poste	169675	125	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	167337	37,5	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	171988	37,5	13.16 kV	CUTUGLAHUA	12
Transformador Monofásico en Poste	49415	37,5	13.16 kV	CUTUGLAHUA	19

Transformador Monofásico en Poste	173908	75	13.16 kV	CUTUGLAHUA	32
Transformador Monofásico en Poste	39604	50	13.16 kV	CUTUGLAHUA	40
Transformador Monofásico en Poste	173162	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	35872	15	13.16 kV	CUTUGLAHUA	14
Transformador Monofásico en Poste	42506	15	13.16 kV	CUTUGLAHUA	22
Transformador Monofásico en Poste	34838	15	13.16 kV	CUTUGLAHUA	36
Transformador Monofásico en Poste	42611	37,5	13.16 kV	CUTUGLAHUA	55
Transformador Monofásico en Poste	162053	37,5	13.16 kV	CUTUGLAHUA	34
Transformador Monofásico en Poste	168149	37,5	13.16 kV	CUTUGLAHUA	82
Transformador Monofásico en Poste	41538	37,5	13.16 kV	CUTUGLAHUA	34
Transformador Monofásico en Poste	22770	37,5	13.16 kV	CUTUGLAHUA	83
Transformador Monofásico en Poste	37207	50	13.16 kV	CUTUGLAHUA	41
Transformador Monofásico en Poste	45729	25	13.16 kV	CUTUGLAHUA	31
Transformador Monofásico en Poste	15055	25	13.16 kV	CUTUGLAHUA	72
Transformador Monofásico en Poste	41175	25	13.16 kV	CUTUGLAHUA	42
Transformador Monofásico en Poste	39341	25	13.16 kV	CUTUGLAHUA	49
Transformador Monofásico en Poste	44480	25	13.16 kV	CUTUGLAHUA	11
Transformador Monofásico en Poste	40258	25	13.16 kV	CUTUGLAHUA	51
Transformador Monofásico en Poste	32493	25	13.16 kV	CUTUGLAHUA	30
Transformador Monofásico en Poste	22320	25	13.16 kV	CUTUGLAHUA	40
Transformador Monofásico en Poste	169512	37,5	13.16 kV	CUTUGLAHUA	79
Transformador Monofásico en Poste	169222	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	47242	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	171732	50	13.16 kV	CUTUGLAHUA	9
Transformador Monofásico en Poste	170363	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	172255	50	13.16 kV	CUTUGLAHUA	3
Transformador Monofásico en Poste	49424	37,5	13.16 kV	CUTUGLAHUA	27
Transformador Monofásico en Poste	49389	37,5	13.16 kV	CUTUGLAHUA	32
Transformador Monofásico en Poste	172795	37,5	13.16 kV	CUTUGLAHUA	10
Transformador Monofásico en Poste	172794	25	13.16 kV	CUTUGLAHUA	6
Transformador Trifásico en Poste	173006	50	22.8 kV	CUTUGLAHUA	69
Transformador Monofásico en Poste	73831	10	13.16 kV	CUTUGLAHUA	0
Transformador Monofásico en Poste	173907	75	13.16 kV	CUTUGLAHUA	14
Padmounted Monofásico en Cabina	174801	75	13.16 kV	CUTUGLAHUA	6
Transformador Monofásico en Poste	34884	15	13.16 kV	CUTUGLAHUA	18
Transformador Trifásico en Poste	109773	90	22.8 kV	CUTUGLAHUA	3
Transformador Monofásico en Poste	15043	50	13.16 kV	CUTUGLAHUA	40
Transformador Monofásico en Poste	43769	37,5	13.16 kV	CUTUGLAHUA	28
Transformador Monofásico en Poste	39581	37,5	13.16 kV	CUTUGLAHUA	23
Transformador Monofásico en Poste	44578	37,5	13.16 kV	CUTUGLAHUA	29
Transformador Monofásico en Poste	24765	25	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	50036	15	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	20981	15	13.16 kV	CUTUGLAHUA	18
Transformador Monofásico en Poste	50162	50	13.16 kV	CUTUGLAHUA	95
Transformador Monofásico en Poste	37200	50	13.16 kV	CUTUGLAHUA	35

Transformador Monofásico en Poste	19027	37,5	13.16 kV	CUTUGLAHUA	58
Transformador Monofásico en Poste	15048	50	13.16 kV	CUTUGLAHUA	59
Transformador Monofásico en Poste	40315	50	13.16 kV	CUTUGLAHUA	31
Transformador Monofásico en Poste	168660	37,5	13.16 kV	CUTUGLAHUA	64
Transformador Monofásico en Poste	48330	50	13.16 kV	CUTUGLAHUA	33
Transformador Monofásico en Poste	39227	50	13.16 kV	CUTUGLAHUA	19
Transformador Monofásico en Poste	15045	50	13.16 kV	CUTUGLAHUA	136
Transformador Monofásico en Poste	24764	37,5	13.16 kV	CUTUGLAHUA	50
Transformador Monofásico en Poste	39679	37,5	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	25332	37,5	13.16 kV	CUTUGLAHUA	0
Transformador Trifásico en Poste	170845	112,5	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	45744	37,5	13.16 kV	CUTUGLAHUA	45
Transformador Monofásico en Poste	49755	37,5	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	173161	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	41373	15	13.16 kV	CUTUGLAHUA	6
Transformador Monofásico en Poste	42516	15	13.16 kV	CUTUGLAHUA	28
Transformador Monofásico en Poste	37322	37,5	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	44638	37,5	13.16 kV	CUTUGLAHUA	48
Transformador Monofásico en Poste	37973	37,5	13.16 kV	CUTUGLAHUA	27
Transformador Monofásico en Poste	37361	37,5	13.16 kV	CUTUGLAHUA	22
Transformador Monofásico en Poste	46610	15	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	22324	50	13.16 kV	CUTUGLAHUA	79
Transformador Monofásico en Poste	27693	37,5	13.16 kV	CUTUGLAHUA	73
Transformador Monofásico en Poste	37569	50	13.16 kV	CUTUGLAHUA	89
Transformador Monofásico en Poste	42349	15	13.16 kV	CUTUGLAHUA	50
Transformador Monofásico en Poste	15051	25	13.16 kV	CUTUGLAHUA	48
Transformador Monofásico en Poste	73755	25	13.16 kV	CUTUGLAHUA	7
Transformador Monofásico en Poste	22315	25	13.16 kV	CUTUGLAHUA	42
Transformador Monofásico en Poste	22323	25	13.16 kV	CUTUGLAHUA	79
Transformador Monofásico en Poste	169963	25	13.16 kV	CUTUGLAHUA	22
Transformador Monofásico en Poste	170413	25	13.16 kV	CUTUGLAHUA	17
Transformador Monofásico en Poste	49419	5	13.16 kV	CUTUGLAHUA	11
Transformador Monofásico en Poste	172852	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	39532	50	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	49752	37,5	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	49754	37,5	13.16 kV	CUTUGLAHUA	27
Transformador Trifásico en Poste	46321	50	22.8 kV	CUTUGLAHUA	73
Transformador Monofásico en Poste	49300	15	13.16 kV	CUTUGLAHUA	2
Transformador Monofásico en Poste	34885	15	13.16 kV	CUTUGLAHUA	32
Transformador Trifásico en Poste	38293	50	22.8 kV	CUTUGLAHUA	86
Transformador Monofásico en Poste	163557	25	13.16 kV	CUTUGLAHUA	18
Transformador Monofásico en Poste	49738	37,5	13.16 kV	CUTUGLAHUA	18
Transformador Monofásico en Poste	38345	37,5	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	24389	37,5	13.16 kV	CUTUGLAHUA	14
Transformador Monofásico en Poste	173843	50	13.16 kV	CUTUGLAHUA	76

Transformador Monofásico en Poste	15042	50	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	163553	37,5	13.16 kV	CUTUGLAHUA	45
Transformador Monofásico en Poste	163555	37,5	13.16 kV	CUTUGLAHUA	75
Transformador Monofásico en Poste	39730	50	13.16 kV	CUTUGLAHUA	30
Transformador Monofásico en Poste	43325	37,5	13.16 kV	CUTUGLAHUA	43
Transformador Monofásico en Poste	15044	50	13.16 kV	CUTUGLAHUA	133
Transformador Monofásico en Poste	15054	25	13.16 kV	CUTUGLAHUA	70
Transformador Monofásico en Poste	15052	25	13.16 kV	CUTUGLAHUA	42
Transformador Monofásico en Poste	48619	37,5	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	38071	25	13.16 kV	CUTUGLAHUA	38
Transformador Monofásico en Poste	116033	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	41164	25	13.16 kV	CUTUGLAHUA	53
Transformador Monofásico en Poste	36841	25	13.16 kV	CUTUGLAHUA	53
Transformador Monofásico en Poste	168957	37,5	13.16 kV	CUTUGLAHUA	89
Transformador Monofásico en Poste	39359	25	13.16 kV	CUTUGLAHUA	45
Transformador Monofásico en Poste	49413	37,5	13.16 kV	CUTUGLAHUA	26
Transformador Trifásico en Poste	173005	75	22.8 kV	CUTUGLAHUA	67
Transformador Monofásico en Poste	49751	37,5	13.16 kV	CUTUGLAHUA	20
Transformador Monofásico en Poste	107911	15	13.16 kV	CUTUGLAHUA	6
Transformador Monofásico en Poste	44076	15	13.16 kV	CUTUGLAHUA	9
Transformador Monofásico en Poste	24768	50	13.16 kV	CUTUGLAHUA	66
Transformador Monofásico en Poste	24766	50	13.16 kV	CUTUGLAHUA	111
Transformador Monofásico en Poste	14492	50	13.16 kV	CUTUGLAHUA	47
Transformador Monofásico en Poste	37353	37,5	13.16 kV	CUTUGLAHUA	16
Transformador Monofásico en Poste	37512	37,5	13.16 kV	CUTUGLAHUA	66
Transformador Monofásico en Poste	39382	37,5	13.16 kV	CUTUGLAHUA	34
Transformador Monofásico en Poste	37197	50	13.16 kV	CUTUGLAHUA	56
Transformador Monofásico en Poste	17171	37,5	13.16 kV	CUTUGLAHUA	91
Transformador Monofásico en Poste	15047	50	13.16 kV	CUTUGLAHUA	20
Transformador Monofásico en Poste	39360	25	13.16 kV	CUTUGLAHUA	12
Transformador Monofásico en Poste	44501	25	13.16 kV	CUTUGLAHUA	39
Transformador Monofásico en Poste	37494	25	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	37926	25	13.16 kV	CUTUGLAHUA	22
Transformador Monofásico en Poste	168911	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	32491	37,5	13.16 kV	CUTUGLAHUA	67
Transformador Monofásico en Poste	172182	50	13.16 kV	CUTUGLAHUA	39
Transformador Monofásico en Poste	173910	75	13.16 kV	CUTUGLAHUA	63
Transformador Trifásico en Poste	164628	50	22.8 kV	CUTUGLAHUA	3
Transformador Trifásico en Poste	16534	45	22.8 kV	CUTUGLAHUA	84
Transformador Monofásico en Poste	39392	37,5	13.16 kV	CUTUGLAHUA	34
Transformador Monofásico en Poste	37478	37,5	13.16 kV	CUTUGLAHUA	105
Transformador Trifásico en Poste	171863	100	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	161811	15	13.16 kV	CUTUGLAHUA	2
Transformador Monofásico en Poste	115735	37,5	13.16 kV	CUTUGLAHUA	49
Transformador Monofásico en Poste	51999	50	13.16 kV	CUTUGLAHUA	117

Transformador Monofásico en Poste	28859	25	13.16 kV	CUTUGLAHUA	32
Transformador Monofásico en Poste	51359	37,5	13.16 kV	CUTUGLAHUA	52
Transformador Monofásico en Poste	27899	25	13.16 kV	CUTUGLAHUA	67
Transformador Trifásico en Cabina	170122	200	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	100340	25	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	48020	37,5	13.16 kV	CUTUGLAHUA	19
Transformador Monofásico en Poste	173823	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175153	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176512	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	115739	50	13.16 kV	CUTUGLAHUA	69
Transformador Monofásico en Poste	25134	50	13.16 kV	CUTUGLAHUA	145
Transformador Trifásico en Poste	41626	50	22.8 kV	CUTUGLAHUA	1
Transformador Trifásico en Poste	50284	50	22.8 kV	CUTUGLAHUA	80
Transformador Monofásico en Poste	73748	37,5	13.16 kV	CUTUGLAHUA	47
Transformador Monofásico en Poste	51328	37,5	13.16 kV	CUTUGLAHUA	75
Transformador Monofásico en Poste	32897	10	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	27881	37,5	13.16 kV	CUTUGLAHUA	7
Transformador Monofásico en Poste	25131	37,5	13.16 kV	CUTUGLAHUA	16
Transformador Monofásico en Poste	45936	37,5	13.16 kV	CUTUGLAHUA	22
Transformador Monofásico en Poste	174842	37,5	13.16 kV	CUTUGLAHUA	39
Transformador Monofásico en Poste	73757	25	13.16 kV	CUTUGLAHUA	28
Transformador Monofásico en Poste	42825	25	13.16 kV	CUTUGLAHUA	15
Transformador Monofásico en Poste	37427	25	13.16 kV	CUTUGLAHUA	26
Transformador Monofásico en Poste	37462	25	13.16 kV	CUTUGLAHUA	65
Transformador Monofásico en Poste	30305	25	13.16 kV	CUTUGLAHUA	49
Transformador Monofásico en Poste	32437	25	13.16 kV	CUTUGLAHUA	12
Transformador Monofásico en Poste	27898	25	13.16 kV	CUTUGLAHUA	64
Transformador Monofásico en Poste	50260	15	13.16 kV	CUTUGLAHUA	1
Transformador Trifásico en Poste	49542	50	22.8 kV	CUTUGLAHUA	68
Transformador Monofásico en Poste	172798	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175184	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	172713	50	13.16 kV	CUTUGLAHUA	65
Transformador Monofásico en Poste	70771	15	13.16 kV	CUTUGLAHUA	20
Transformador Monofásico en Poste	49870	50	13.16 kV	CUTUGLAHUA	23
Transformador Monofásico en Poste	35188	50	13.16 kV	CUTUGLAHUA	28
Transformador Trifásico en Poste	167886	30	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	39614	50	13.16 kV	CUTUGLAHUA	84
Transformador Monofásico en Poste	39210	50	13.16 kV	CUTUGLAHUA	34
Transformador Monofásico en Poste	37506	37,5	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	32050	25	13.16 kV	CUTUGLAHUA	26
Transformador Monofásico en Poste	99101164	10	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	42972	37,5	13.16 kV	CUTUGLAHUA	95
Transformador Monofásico en Poste	28592	50	13.16 kV	CUTUGLAHUA	57
Transformador Monofásico en Poste	25133	37,5	13.16 kV	CUTUGLAHUA	48
Transformador Monofásico en Poste	27896	25	13.16 kV	CUTUGLAHUA	73

Transformador Monofásico en Poste	161812	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	28858	25	13.16 kV	CUTUGLAHUA	19
Transformador Monofásico en Poste	30303	25	13.16 kV	CUTUGLAHUA	43
Transformador Monofásico en Poste	27893	25	13.16 kV	CUTUGLAHUA	43
Transformador Monofásico en Poste	115732	37,5	13.16 kV	CUTUGLAHUA	30
Transformador Monofásico en Poste	32210	37,5	13.16 kV	CUTUGLAHUA	65
Transformador Trifásico en Poste	165550	45	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	34668	25	13.16 kV	CUTUGLAHUA	32
Transformador Monofásico en Poste	44559	37,5	13.16 kV	CUTUGLAHUA	21
Transformador Monofásico en Poste	175215	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176061	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176517	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176516	50	13.16 kV	CUTUGLAHUA	1
Transformador Trifásico en Poste	42924	150	22.8 kV	CUTUGLAHUA	130
Transformador Monofásico en Poste	42928	50	13.16 kV	CUTUGLAHUA	57
Transformador Monofásico en Poste	32440	37,5	13.16 kV	CUTUGLAHUA	13
Transformador Monofásico en Poste	70785	37,5	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	42829	25	13.16 kV	CUTUGLAHUA	5
Transformador Monofásico en Poste	25132	37,5	13.16 kV	CUTUGLAHUA	96
Transformador Monofásico en Poste	115736	37,5	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	30301	25	13.16 kV	CUTUGLAHUA	48
Transformador Monofásico en Poste	49687	37,5	13.16 kV	CUTUGLAHUA	45
Transformador Monofásico en Poste	28862	25	13.16 kV	CUTUGLAHUA	102
Transformador Monofásico en Poste	73876	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	169075	25	13.16 kV	CUTUGLAHUA	31
Transformador Monofásico en Poste	38762	15	13.16 kV	CUTUGLAHUA	18
Transformador Monofásico en Poste	172704	37,5	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	173158	10	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	24358	15	13.16 kV	CUTUGLAHUA	41
Transformador Monofásico en Poste	33357	15	13.16 kV	CUTUGLAHUA	18
Transformador Trifásico en Poste	41639	75	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	52011	50	13.16 kV	CUTUGLAHUA	54
Banco de 2 Transformadores en Poste	39130;R_39129	50	13.16 kV	CUTUGLAHUA	41
Transformador Monofásico en Poste	27932	37,5	13.16 kV	CUTUGLAHUA	22
Transformador Monofásico en Poste	115733	37,5	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	73871	15	13.16 kV	CUTUGLAHUA	6
Transformador Monofásico en Poste	30151	25	13.16 kV	CUTUGLAHUA	31
Transformador Monofásico en Poste	40765	25	13.16 kV	CUTUGLAHUA	37
Transformador Monofásico en Poste	34670	25	13.16 kV	CUTUGLAHUA	42
Transformador Monofásico en Poste	30149	25	13.16 kV	CUTUGLAHUA	49
Transformador Monofásico en Poste	169074	25	13.16 kV	CUTUGLAHUA	56
Transformador Monofásico en Poste	52492	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	172703	37,5	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	172797	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	45735	37,5	13.16 kV	CUTUGLAHUA	61

Transformador Monofásico en Poste	49756	37,5	13.16 kV	CUTUGLAHUA	2
Transformador Monofásico en Poste	175216	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176395	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176511	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	168646	25	13.16 kV	CUTUGLAHUA	1
Transformador Trifásico en Poste	177429	75	22.8 kV	CUTUGLAHUA	1
Transformador Trifásico en Poste	172019	75	22.8 kV	CUTUGLAHUA	151
Transformador Trifásico en Poste	14710	75	22.8 kV	CUTUGLAHUA	171
Transformador Monofásico en Poste	28698	25	13.16 kV	CUTUGLAHUA	84
Transformador Monofásico en Poste	39390	37,5	13.16 kV	CUTUGLAHUA	35
Transformador Monofásico en Poste	39384	37,5	13.16 kV	CUTUGLAHUA	47
Transformador Monofásico en Poste	163384	5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	73752	37,5	13.16 kV	CUTUGLAHUA	34
Transformador Monofásico en Poste	36594	37,5	13.16 kV	CUTUGLAHUA	82
Transformador Monofásico en Poste	30140	25	13.16 kV	CUTUGLAHUA	24
Transformador Monofásico en Poste	34669	25	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	27894	25	13.16 kV	CUTUGLAHUA	52
Transformador Monofásico en Poste	28861	25	13.16 kV	CUTUGLAHUA	32
Transformador Monofásico en Poste	112313	25	13.16 kV	CUTUGLAHUA	3
Transformador Monofásico en Poste	R_33598	15	13.16 kV	CUTUGLAHUA	29
Transformador Monofásico en Poste	175155	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175213	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175188	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175154	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176396	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	76814	15	13.16 kV	CUTUGLAHUA	21
Transformador Trifásico en Poste	100661	45	22.8 kV	CUTUGLAHUA	2
Transformador Monofásico en Poste	39393	37,5	13.16 kV	CUTUGLAHUA	30
Transformador Monofásico en Poste	30142	37,5	13.16 kV	CUTUGLAHUA	31
Transformador Monofásico en Poste	49999	25	13.16 kV	CUTUGLAHUA	34
Transformador Monofásico en Poste	100753	10	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	38680	50	13.16 kV	CUTUGLAHUA	21
Transformador Monofásico en Poste	24865	50	13.16 kV	CUTUGLAHUA	67
Transformador Monofásico en Poste	39406	37,5	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	115734	37,5	13.16 kV	CUTUGLAHUA	24
Transformador Monofásico en Poste	115737	37,5	13.16 kV	CUTUGLAHUA	46
Transformador Monofásico en Poste	161813	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	40342	15	13.16 kV	CUTUGLAHUA	3
Transformador Monofásico en Poste	39363	25	13.16 kV	CUTUGLAHUA	30
Transformador Monofásico en Poste	37437	25	13.16 kV	CUTUGLAHUA	56
Transformador Monofásico en Poste	37463	25	13.16 kV	CUTUGLAHUA	15
Transformador Monofásico en Poste	30304	25	13.16 kV	CUTUGLAHUA	29
Transformador Monofásico en Poste	103230	25	13.16 kV	CUTUGLAHUA	4
Transformador Monofásico en Poste	41499	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	R-168999	25	13.16 kV	CUTUGLAHUA	2

Transformador Monofásico en Poste	47644	50	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	39398	37,5	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	14830	25	13.16 kV	CUTUGLAHUA	1
Transformador Trifásico en Poste	172232	75	22.8 kV	CUTUGLAHUA	109
Transformador Monofásico en Poste	175152	10	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	175186	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	R_170162	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176515	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	34665	15	13.16 kV	CUTUGLAHUA	14
Transformador Trifásico en Poste	43350	50	22.8 kV	CUTUGLAHUA	80
Transformador Monofásico en Poste	115738	50	13.16 kV	CUTUGLAHUA	71
Transformador Monofásico en Poste	6107	37,5	13.16 kV	CUTUGLAHUA	44
Transformador Monofásico en Poste	50007	25	13.16 kV	CUTUGLAHUA	32
Transformador Trifásico en Poste	47216	100	22.8 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	39379	37,5	13.16 kV	CUTUGLAHUA	31
Transformador Monofásico en Poste	167459	25	13.16 kV	CUTUGLAHUA	8
Transformador Monofásico en Poste	25141	25	13.16 kV	CUTUGLAHUA	53
Transformador Monofásico en Poste	38666	37,5	13.16 kV	CUTUGLAHUA	61
Transformador Monofásico en Poste	161814	15	13.16 kV	CUTUGLAHUA	3
Transformador Monofásico en Poste	27907	15	13.16 kV	CUTUGLAHUA	3
Transformador Monofásico en Poste	45216	25	13.16 kV	CUTUGLAHUA	25
Transformador Monofásico en Poste	39376	25	13.16 kV	CUTUGLAHUA	48
Transformador Monofásico en Poste	30150	25	13.16 kV	CUTUGLAHUA	14
Transformador Monofásico en Poste	37433	25	13.16 kV	CUTUGLAHUA	13
Transformador Monofásico en Poste	34666	25	13.16 kV	CUTUGLAHUA	11
Transformador Monofásico en Poste	27895	25	13.16 kV	CUTUGLAHUA	32
Transformador Monofásico en Poste	30148	25	13.16 kV	CUTUGLAHUA	51
Transformador Monofásico en Poste	105311	15	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	169391	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	171121	50	13.16 kV	CUTUGLAHUA	107
Transformador Monofásico en Poste	49995	25	13.16 kV	CUTUGLAHUA	24
Transformador Monofásico en Poste	176514	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	176513	50	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	177488	25	13.16 kV	CUTUGLAHUA	1
Transformador Monofásico en Poste	177489	25	13.16 kV	CUTUGLAHUA	1
<b>TOTAL</b>					13207