



# UNIVERSIDAD TÉCNICA DE COTOPAXI

## DIRECCIÓN DE POSGRADO

### MAESTRÍA EN ELECTRICIDAD

#### MODALIDAD: INFORME DE INVESTIGACIÓN

**Título:**

---

Modelo matemático para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal.

---

Trabajo de titulación previo a la obtención del título de Magíster en Electricidad  
mención Sistemas Eléctricos de Potencia.

**Autora:**

Jara Páez Marcela Alejandra, Ing.

**Tutor:**

Pesantez Palacios Gabriel Napoleón, MSc

LATACUNGA –ECUADOR  
2024

## AVAL DEL TUTOR

En mi calidad de Tutor del Trabajo de Titulación “Modelo matemático para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal” presentado por Jara Páez Marcela Alejandra, para optar por el título magíster en Electricidad mención sistemas eléctricos de potencia.

### CERTIFICO

Que dicho trabajo de investigación ha sido revisado en todas sus partes y se considera que reúne los requisitos y méritos suficientes para ser sometido a la presentación para la valoración por parte del Tribunal de Lectores que se designe y su exposición y defensa pública.

Latacunga, noviembre del 2024

---




.....  
Pesantez Palacios Gabriel Napoleón, MSc  
C.I. 0301893889

## AVAL DEL TRIBUNAL

El trabajo de Titulación: “Modelo matemático para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal”, ha sido revisado, aprobado y autorizado su impresión y empastado, previo a la obtención del título de Magíster en Educación Inicial; el presente trabajo reúne los requisitos de fondo y forma para que el estudiante pueda presentarse a la exposición y defensa.

Latacunga, noviembre del 2024



.....  
Armando Salvador Freire Freire, MSc  
C.I. 0503842833  
Presidente del tribunal



.....  
Mauricio Eduardo Mullo Pallo, MSc  
C.I. 0503755183  
Lector 2



.....  
Carlos Iván Quinatoa Caiza, MSc  
C.I. 0503287864  
Lector 3

## **DEDICATORIA**

A mi familia por el amor y apoyo incondicional, han sido el pilar fundamental en mi vida, su confianza en mí me ha impulsado a alcanzar mis metas.

Marcela Alejandra Jara Páez

## **AGRADECIMIENTO**

A mi familia por su constante apoyo y motivación. A mi tutor por su tiempo y orientación en cada etapa de esta investigación. Asimismo, agradezco a la institución por brindarme las herramientas para alcanzar mis objetivos.

Marcela Alejandra Jara Páez

## RESPONSABILIDAD DE AUTORÍA

Quien suscribe, declara que asume la autoría de los contenidos y los resultados obtenidos en el presente trabajo de titulación.

Latacunga, noviembre 2024

  
.....  
Ing. Marcela Alejandra Jara Páez  
C.I. 0604075408

## RENUNCIA DE DERECHOS

Quien suscribe, cede los derechos de autoría intelectual total y/o parcial del presente trabajo de titulación a la Universidad Técnica de Cotopaxi.

Latacunga, noviembre 2024



.....  
Ing. Marcela Alejandra Jara Páez  
C.I. 0604075408

## AVAL DEL PRESIDENTE DEL TRIBUNAL

Quien suscribe, declara que el presente Trabajo de Titulación: Modelo matemático para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal, contiene las correcciones a las observaciones realizadas por los lectores en sesión científica del tribunal.

Latacunga, noviembre 2024



.....  
Armando Salvador Freire Freire, MSc  
C.I. 0503842833

**UNIVERSIDAD TÉCNICA DE COTOPAXI**  
**DIRECCIÓN DE POSGRADO**

**MAESTRÍA EN ELECTRICIDAD**  
**MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA**

**Título:**

Modelo matemático para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal.

**Autora:** Jara Páez Marcela Alejandra, Ing.

**Tutor:** Pesantez Palacios Gabriel Napoleón, MSc

**RESUMEN**

Esta investigación implementa un modelo de red neuronal artificial (RNA) para predecir la cargabilidad de transformadores en las zonas rurales del alimentador Chimbo, perteneciente a la Subestación Guaranda de la Corporación Nacional de Electricidad (CNEL EP) Unidad de Negocio Bolívar. En la actualidad, las mediciones aleatorias de calidad de energía no permiten identificar todos los transformadores críticos, lo que incrementa el riesgo de sobrecargas y fallas, adicionalmente la ausencia de un modelo matemático adecuado dificulta la estimación en tiempo real de la capacidad de carga de los transformadores. Por ello, el objetivo de este estudio es desarrollar una herramienta precisa que mejore dicha estimación.

La metodología incluye la implementación de una Red Neuronal Artificial (RNA) con arquitectura multicapa, utilizando la función de activación ReLU y optimizando el entrenamiento mediante el algoritmo Adam. Los datos fueron normalizados mediante el método Z-score, lo que mejoró la precisión del modelo. Los resultados obtenidos arrojaron un error absoluto medio (MAE) de 1,06 y un error cuadrático medio (MSE) de 2,38 en el conjunto de entrenamiento, mientras que en el conjunto de prueba se registraron un MAE de 1,83 y un MSE de 31,97.

Los resultados del modelo propuesto se compararon con el método REA y con las mediciones de los equipos analizadores de calidad de energía, demostrando que la RNA es una herramienta eficaz para la gestión de la cargabilidad en zonas rurales.

**PALABRAS CLAVE:** Red neuronal artificial, cargabilidad de transformadores, método REA, algoritmo Adam, ReLU.

**TECHNICAL UNIVERSITY OF COTOPAXI**  
**GRADUATE DEPARTMENT**  
**MASTER'S DEGREE IN ELECTRICITY**

**Topic:** Mathematical model for estimating the loadability of the distribution transformers in the Chimbo feeder of the Bolívar Business Unit, using a neural network

**Author:** Jara Páez Marcela Alejandra, Ing.

**Tutor:** Pesantez Palacios Gabriel Napoleón, Mg

**ABSTRACT**

The research implements an artificial neural network (ANN) model to predict the load capacity of transformers in the rural areas of the Chimbo feeder, belonging to the Guaranda Substation of the National Electricity Corporation (CNEL-EP) Bolívar Business Unit. Currently, random power quality measurements do not allow the identification of all critical transformers, which increases the risk of overloads and failures. Additionally, the absence of an adequate mathematical model makes it difficult to estimate the capacity of the transformers in real-time. Transformers. Therefore, the objective is to develop a precise tool that improves this estimation.


The methodology includes the implementation of an Artificial Neural Network (ANN) with multilayer architecture, using the ReLU activation function, and optimizing training using the Adam algorithm. The data were normalized using the Z-score method, which improved the model's accuracy. The results showed a mean absolute error (MAE) of 1.06 and a mean square error (MSE) of 2.38 in the training set, while in the test set an MAE of 1.83 and an MSE of 31.97.

The results of the proposed model were compared to the REA method and power quality analyzer measurements, showing that the ANN is a reliable tool for managing variability in rural areas.

**KEYWORDS:** Artificial neural network, transformer loadability, REA method, Adam algorithm, ReLU.

Yo Alvear Jiménez Tania Elizabeth con cédula de identidad número: 0503231763 Magíster en Lingüística Aplicada a la Enseñanza de Inglés como Lengua Extranjera con número de registro de la SENESCYT: 1020-2021-2354185; **CERTIFICO** haber revisado y aprobado la traducción al idioma Inglés del resumen del trabajo de investigación con el título: "Modelo matemático para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal." de: Jara Páez Marcela Alejandra, Ing. Aspirante a **Master en Electricidad Mención Sistemas Eléctricos de Potencia.**

Latacunga, 24 de octubre, 2024

  
Mg. Tania Alvear Jiménez  
CI 0503231763

## ÍNDICE DE CONTENIDOS

ÍNDICE DE CONTENIDOS .....	
ÍNDICE DE FIGURAS.....	
ÍNDICE DE ECUACIONES Y FÓRMULAS.....	
ÍNDICE DE TABLAS .....	
INTRODUCCIÓN .....	1
Planteamiento del problema .....	2
Formulación del problema.....	2
Objetivo General .....	3
Objetivos Específicos: .....	3
Justificación.....	5
Hipótesis.....	6
CAPÍTULO I.....	7
FUNDAMENTACIÓN TEORICA- METODOLOGICA.....	7
1.1    Antecedentes de la investigación o fundamentación del estado del arte..	7
1.2    Fundamentación Teórica .....	9
1.2.1    Sistema eléctrico de distribución .....	10
1.3    Redes Neuronales Artificiales .....	16
1.3.1    Conceptos, Definiciones .....	17
1.3.2    Funciones de activación .....	18
1.3.3    Clasificación de las redes neuronales.....	20
1.3.4    Topología de las redes neuronales .....	22
1.3.5    Proceso de entrenamiento .....	22
1.3.6    Validación .....	24
1.3.7    Métricas de Evaluación .....	26
1.3.8    Preprocesamiento de datos.....	28

1.3.9	Método REA (Rural Electrification Administration).....	30
1.4	Fundamentación metodológica.....	31
1.4.1	Enfoque de la investigación .....	31
1.4.2	Tipo de investigación .....	31
1.4.3	Técnica de recolección de información.....	32
1.4.4	Procedimientos empleados para la obtención y análisis de la información.....	33
1.5	Conclusiones Capítulo I .....	33
CAPÍTULO II .....		35
PROPUESTA.....		35
2.1	Título de la propuesta .....	35
2.2	Objetivo de la propuesta.....	35
2.3	Justificación de la propuesta.....	36
2.4	Fundamentación de la propuesta .....	36
2.5	Desarrollo de la metodología.....	38
2.5.1	Introducción .....	38
2.5.2	Construcción de la base de datos .....	39
2.5.3	Tratamiento de datos .....	41
2.5.4	Diseño e implementación del modelo de la red neuronal .....	41
2.5.5	Funciones de activación .....	43
2.5.6	Optimización del modelo .....	43
2.5.7	Entrenamiento del modelo .....	43
2.5.8	Evaluación y validación del modelo .....	45
2.5.9	Método REA .....	45
2.5.10	Comparaciones con metodologías tradicionales .....	45
CAPÍTULO III .....		47

APLICACIÓN Y/O VALIDACION DE LA PROPUESTA.....	47
3.1 Resultados de la base de datos .....	48
3.2 Red neuronal.....	51
3.2.1 Resultados de la normalización de datos .....	51
3.2.2 Resultados del entrenamiento de la red neuronal.....	54
3.2.3 Resultados generados por la red neuronal.....	57
3.2.4 Ejecutable GUI.....	60
3.3 Resultados del método REA.....	61
3.4 Comparación de Resultados: Modelo de Red Neuronal, Método REA y Mediciones del Analizador.....	62
Conclusiones .....	64
Recomendaciones.....	65
Referencias bibliográficas .....	66

## ÍNDICE DE FIGURAS

Figura 1.1. Diagrama unifilar de un sistema eléctrico de potencia [8] .....	10
Figura 1.2. Diagrama unifilar de un sistema eléctrico de distribución [8].....	10
Figura 1.3. Topología de una red eléctrica con configuración radial [8].....	11
Figura 1.4. Topología de una red eléctrica con configuración anillo [8].....	12
Figura 1.5. Topología de una red eléctrica con configuración mallada [8] .....	12
Figura 1.6. Representación de un circuito eléctrico trifásico de tres hilos [8].....	13
Figura 1.7. Representación de un circuito eléctrico trifásico de cuatro hilos [8]..	14
Figura 1.8. Representación de un circuito eléctrico monofásico de dos hilos [8]	14
Figura 1.9. Representación de un circuito eléctrico monofásico de un hilo [8] ...	15
Figura 1.10. Diagrama de un transformador de distribución monofásico [9].....	16
Figura 1.11. Configuraciones de un transformador de distribución trifásico [9]..	16
Figura 1.12. Arquitectura de una red neuronal [12].....	17
Figura 1.13. Funciones de activación de capas ocultas recomendadas de acuerdo al tipo de red neuronal [11] .....	20
Figura 1.14. Esquema de una red neuronal monocapa [11].....	22
Figura 1.15. Problemas de ajuste de datos [20] .....	25
Figura 2.1. Metodología de trabajo propuesta .....	39
Figura 2.2. Topología de la red neuronal implementada. Realizado con [31].....	42
Figura 2.3. División de los datos del modelo.....	44
Figura 3.1. Esquema geográfico del alimentador Chimbo.....	47
Figura 3.2. Gráfico de frecuencias .....	48
Figura 3.3. Porcentaje de usuarios .....	49
Figura 3.4. Consumos de usuarios Residenciales .....	49
Figura 3.5. Porcentaje de usuarios por consumo de energía .....	50
Figura 3.6. Consumo residencial (kWh-mes) .....	50
Figura 3.7. Resultados del proceso de entrenamiento de la red neuronal. a) MAE y b) MSE. ....	55
Figura 3.8. Gráfico de dispersión entre valores reales y predicciones.....	57
Figura 3.9. MAE de todo el conjunto de datos .....	58
Figura 3.10. GUI para el cálculo de cargabilidad .....	60

## ÍNDICE DE ECUACIONES Y FÓRMULAS

(1).....	26
(2).....	27
(3).....	27
(4).....	28
(5).....	29
(6).....	29
(7).....	30
(8).....	31

## ÍNDICE DE TABLAS

Tabla 1. Sistema de tareas en relación a los objetivos .....	3
Tabla 1.1. Revisión de trabajos similares .....	9
Tabla 1.2. Clasificación de los transformadores de distribución (kVA) [9] .....	15
Tabla 1.3. Funciones de activación más utilizadas [14].....	18
Tabla 1.4. Tipos de investigación utilizados en el estudio.....	31
Tabla 2.1. Estratificación de usuarios .....	40
Tabla 2.2. Base de datos.....	40
Tabla 3.1 Consumos específicos por tarifa .....	50
Tabla 3.2. Estadísticas descriptivas del conjunto de datos.....	52
Tabla 3.3. Normalización en los datos de entrenamiento .....	53
Tabla 3.4. Normalización en los datos de prueba .....	54
Tabla 3.5. Resumen de resultados de error en el proceso de entrenamiento de la red neuronal.....	55
Tabla 3.6. Transformadores con MAE superior a 15.....	59
Tabla 3.7. Resultados del método REA .....	62
Tabla 3.8. Comparación de la Cargabilidad de Transformadores: Método REA, Mediciones del Analizador y Modelo de Red Neuronal.....	62

## INTRODUCCIÓN

En la gestión de redes eléctricas, la estimación precisa de la cargabilidad de los transformadores de distribución es indispensable para garantizar un suministro eficiente y confiable de energía. En la Corporación Nacional de Electricidad Unidad de Negocio Bolívar, y específicamente en el alimentador Chimbo perteneciente a la subestación Guaranda, se requiere optimizar la operación de estos transformadores para mejorar la eficiencia y evitar sobrecargas. En este contexto la implementación de modelos matemáticos avanzados, basados en redes neuronales artificiales, constituyen herramientas precisas para estimar la cargabilidad, los cuales pueden compararse con los métodos tradicionales.

Este trabajo de investigación propone implementar un modelo matemático utilizando redes neuronales para estimar la cargabilidad de los transformadores en áreas rurales, específicamente en el alimentador Chimbo. Las redes neuronales, conocidas por su capacidad para modelar relaciones complejas y no lineales entre variables, se entrenarán con datos históricos de la CNEL EP Unidad de Negocio Bolívar. Aunque el modelo se diseñará considerando las características propias de las redes rurales, se aplicará a todos los transformadores del sistema. Sin embargo, su validación se centrará en los transformadores ubicados en zonas rurales, utilizando el método REA como referencia comparativa. Adicionalmente, los resultados del modelo serán comparados con mediciones reales de calidad de energía para evaluar su precisión.

La investigación está estructurada en tres capítulos principales. En el Capítulo I se desarrolla la Fundamentación Teórica y Metodológica, incluyendo los conceptos esenciales sobre redes neuronales y modelos matemáticos, así como la metodología para el desarrollo y entrenamiento del modelo. El Capítulo II presenta la propuesta de solución, detallando el diseño e implementación del modelo, sus objetivos, justificación y metodología. Finalmente, el Capítulo III se centra en la aplicación y validación de la propuesta, mostrando los resultados obtenidos y su efectividad en la estimación de la cargabilidad, con análisis y recomendaciones correspondientes.

## **Planteamiento del problema**

En la Corporación Nacional de Electricidad Unidad de Negocio Bolívar, aún no se han realizado estudios integrales sobre la cargabilidad de los transformadores de distribución. Actualmente, se realizan mediciones aleatorias de calidad de energía en los transformadores de acuerdo con el calendario establecido por la Regulación No. ARCERNNR 003/2023 “Calidad del servicio de distribución y comercialización de energía eléctrica” [1]. Este enfoque puede no detectar de manera adecuada todos los transformadores críticos en la red de distribución eléctrica, limitando la capacidad de realizar un seguimiento detallado de la cargabilidad en la red de distribución.

Basándonos en los históricos de la Corporación Nacional de Electricidad Unidad de Negocio Bolívar, se evidencia que una de las principales razones de las fallas y salidas de los transformadores en los últimos cinco años ha sido la sobrecarga. Esta observación concuerda con los hallazgos de [2] que subrayan la importancia de un análisis detallado del estado de carga para prevenir fallas. Sin embargo, la falta de un modelo matemático adecuado para estimar la cargabilidad en tiempo real impide una evaluación precisa de la capacidad de carga de los transformadores.

Por lo tanto, surge la necesidad de implementar un modelo matemático basado en redes neuronales artificiales para estimar la cargabilidad de los transformadores en el área rural del alimentador Chimbo. Este enfoque se centrará exclusivamente en la evaluación detallada de la cargabilidad de los transformadores en el área rural, proporcionando una evaluación precisa de su capacidad de carga.

## **Formulación del problema**

La falta de información precisa sobre la cargabilidad de los transformadores de distribución en las zonas rurales del alimentador Chimbo dificulta la evaluación de su estado de carga, aumentando así el riesgo de sobrecargas y fallas inesperadas.

## Objetivo General

Implementar un modelo matemático para estimar la cargabilidad de los transformadores de distribución rurales en el alimentador Chimbo de la Corporación Nacional de Electricidad Unidad de Negocio Bolívar, mediante una red neuronal.

## Objetivos Específicos:

1. Identificar el material bibliográfico referente a la presente temática.
2. Aplicar un método para la estimación de la cargabilidad de los transformadores de distribución.
3. Implementar un modelo de red neuronal para la estimación de la cargabilidad de los transformadores.
4. Evaluar el rendimiento y la precisión del modelo de red neuronal para conocer el porcentaje de certeza del estudio.

**Sistemas de tareas en relación a los objetivos específicos:** estas son las actividades que se realizarán para dar cumplimiento a cada objetivo específico planteado.

Tabla 1. Sistema de tareas en relación a los objetivos

Objetivos específicos	Actividad (tareas)	Resultado de la actividad	Descripción de la actividad (técnicas e instrumentos)
<b>Identificar el material bibliográfico referente a la presente temática.</b>	Revisión de bases de datos académicas y bibliotecas digitales relevantes.	Base bibliográfica que respalde el desarrollo del documento y la fundamentación teórica.	Bases de datos como IEE Xplore, ScienceDirect, Energies y documentos académicos.
	Aplicar términos de búsqueda específicos y operadores booleanos para depurar los resultados en motores de búsqueda académicos.	Documentos seleccionados que cumplen con los criterios de calidad y relevancia para el estudio.	Términos de búsqueda específicos y operadores booleanos para depurar los resultados.

	Analizar la información recopilada para determinar su aplicabilidad al estudio.	Resumen de los hallazgos más relevantes, destacando su relación con el tema de investigación.	
	Recolección de datos sobre el número de abonados y el consumo específico en kWh/mes.	Conjunto de datos sobre los abonados y consumos específicos necesarios para el análisis	Acceso a bases de datos de las variables técnicas específicas identificadas en el método REA.
<b>Aplicar un método para la estimación de la cargabilidad de los transformadores de distribución.</b>	Aplicación del método REA para calcular la demanda máxima y la cargabilidad de los transformadores.	Resultados de la demanda máxima y porcentaje de cargabilidad de cada transformador.	Uso de ecuaciones y factores específicos para calcular la demanda máxima y cargabilidad.
	Análisis de los resultados obtenidos y su comparación con los criterios de carga óptimos.	Detalle del rendimiento de cada transformador y su grado de carga.	
<b>Implementar un modelo de red neuronal para la estimación de la cargabilidad de los transformadores</b>	Implementación de una red neuronal funcional diseñada para la estimación de la cargabilidad de los transformadores de distribución.	Detalle de la arquitectura de la red neuronal, incluyendo la selección del tipo de red, número de capas, neuronas y parámetros utilizados durante la implementación.	Proceso de implementación, entrenamiento y validación de la red neuronal.
	Normalizar los datos recopilados para mejorar la precisión del modelo durante el proceso de entrenamiento.	Resultados del proceso de normalización, destacando el impacto del método utilizado.	

---

<p>Evaluar el rendimiento del modelo de red neuronal utilizando métricas de precisión, como el error absoluto medio (MAE) y el error cuadrático medio (MSE), en los conjuntos de entrenamiento y prueba.</p>	<p>Reporte de las métricas de rendimiento obtenidas (MAE y MSE), que permite evaluar de manera objetiva la capacidad predictiva del modelo.</p>
--	---

---

### **Justificación**

Este proyecto conduce a la obtención del grado de Magister en Electricidad, mención Sistemas Eléctricos de Potencia. Además, se encuentra alineado el proyecto formativo de la carrera de Electricidad de la Universidad Técnica de Cotopaxi titulado “Estrategias de planeación de sistemas eléctricos en el contexto de la transición energética.” y se ajusta a la línea de investigación: Energías alternativas y renovables, eficiencia energética y protección ambiental, específicamente se vincula con la sub línea de investigación sobre la Explotación y diseño de Sistemas Eléctricos de Potencia.

Esta investigación se centra en implementar un modelo matemático basado en redes neuronales artificiales para estimar con precisión la cargabilidad de los transformadores de distribución en el área rural del alimentador Chimbo. La importancia de este estudio radica en la necesidad de contar con herramientas que permitan evaluar de manera precisa el estado de carga de los transformadores, lo cual es esencial para predecir y mitigar el riesgo de sobrecargas y fallas inesperadas.

El uso de redes neuronales es óptimo para este tipo de análisis debido a su capacidad para identificar tendencias complejas y no lineales en grandes volúmenes de datos históricos y en tiempo real [3]. Al proporcionar estimaciones más precisas, este modelo permitirá un enfoque más efectivo y específico para la gestión de la cargabilidad en los transformadores del área rural del alimentador Chimbo.

Además, la validación del modelo se realizará mediante comparaciones con el método REA, que es ampliamente utilizado en zonas rurales, y con mediciones reales obtenidas de analizadores de calidad de energía. Estas comparaciones son esenciales para garantizar que el modelo basado en redes neuronales ofrezca resultados precisos y confiables en condiciones reales. De esta manera, se busca implementar una herramienta que calcule con precisión la cargabilidad de los transformadores de distribución, para optimizar la eficiencia y la confiabilidad del sistema eléctrico en las zonas rurales del alimentador Chimbo.

### **Hipótesis**

¿ La implementación de un modelo basado en redes neuronales para la estimación de la cargabilidad de los transformadores de distribución en las zonas rurales del alimentador Chimbo conducirá a una mejora significativa en la estimaciones de carga?

## **CAPÍTULO I**

### **FUNDAMENTACIÓN TEORICA- METODOLOGICA**

Este capítulo proporciona la Fundamentación Teórica – Metodológica del estudio. La Sección 1.1 presenta los antecedentes de la investigación, revisando estudios previos sobre la estimación de la cargabilidad de los transformadores de distribución. La Sección 1.2 aborda la fundamentación teórica, cubriendo los conceptos y principios clave que sustentan la investigación. La Sección 1.3 se centra en la fundamentación metodológica, describiendo en detalle el procedimiento de recolección de datos y su procesamiento, que serán fundamentales para la propuesta de solución al problema planteado. Finalmente, la Sección 1.4 resume las conclusiones del Capítulo I, las cuales consolidarán el desarrollo de los capítulos siguientes de esta investigación.

#### **1.1 Antecedentes de la investigación o fundamentación del estado del arte**

En el ámbito de la distribución de energía eléctrica, se han realizado investigaciones sobre la estimación de la cargabilidad de los transformadores de distribución a lo largo de los años. Estudios previos han enfatizado la importancia de comprender y prever la carga que estos transformadores pueden soportar antes de alcanzar niveles críticos que puedan provocar fallas en el sistema. Métodos convencionales, como el análisis de datos históricos y análisis estadísticos, se han usado para estimar la demanda de energía de transformadores y otros componentes del sistema de distribución [4]. Sin embargo, estos enfoques a menudo no reflejan adecuadamente cómo cambian y responden los transformadores en condiciones reales de operación. La metodología presentada en este artículo utiliza un análisis estadístico con datos

históricos, lo que permite una estimación más precisa sin necesidad de software avanzado.

En respuesta a las limitaciones de los métodos tradicionales, ha surgido interés en el uso de técnicas de inteligencia artificial, particularmente redes neuronales artificiales (RNA), para la estimación de la cargabilidad en los transformadores de distribución. En este contexto en la investigación desarrollada por [5], se ha empleado una red neuronal artificial (RNA) para modelar la relación entre variables de entrada, como el consumo mensual de energía y el tipo de usuario, y las variables de salida, como la curva de carga del transformador. Se utilizaron métricas de evaluación, como el error absoluto medio (MAE) y el error cuadrático medio (MSE), para medir la precisión de las estimaciones. Los resultados demostraron que la RNA puede alcanzar una precisión superior al 90% en la estimación de las curvas de carga, evidenciando su capacidad para modelar relaciones complejas y ofreciendo una herramienta efectiva para reducir costos en el análisis y planificación del sistema de distribución de energía.

En este estudio [6], se empleó una Red Neuronal Artificial (RNA) para estimar la demanda en transformadores de distribución, utilizando una metodología de prueba y error para su creación y parametrización. La RNA se ajustó y validó a través de procedimientos internos y externos, empleando métricas de evaluación como el Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE) para medir la precisión de las estimaciones. Los resultados indicaron que la RNA alcanzó una exactitud del 94% en la estimación de la demanda, demostrando ser una herramienta eficaz para suplir la falta de dispositivos de medición en transformadores.

En el artículo [7] se desarrolló un sistema IoT (Internet of Things) para monitorear transformadores de distribución en tiempo real utilizando técnicas de aprendizaje automático. Se empleó el algoritmo Isolation Forest (IF) para la detección de anomalías, superando a otros métodos como One-Class SVM y redes neuronales recurrentes (GRU) en precisión. El sistema recopiló datos de corriente, temperatura y niveles de aceite y los presentó a través de una aplicación móvil. Los resultados mostraron que el IF detectó todas las anomalías en grandes conjuntos de datos en tiempo real, proporcionando alertas precisas con 24 horas de anticipación. Las

métricas de evaluación, como MAE y MSE, confirmaron una alta precisión del sistema en comparación con métodos tradicionales.

Tabla 0.1. Revisión de trabajos similares

Ref.	Tema	Tipo de red neuronal	Métricas Evaluación
[5]	Estimación de curvas de carga en transformadores eléctricos mediante redes neuronales	Feedforward FNN	MAE, MSE
[6]	Estimación de curvas diarias de demanda eléctrica en transformadores de distribución mediante redes neuronales artificiales	Feedforward FNN	MAE, MSE
[7]	Machine Learning Approach for Smart Distribution Transformers Load Monitoring and Management System	Redes recurrentes RNN (GRU, LSTM)	MAE, MSE, RMSE y R2

En el contexto específico de la CNEL Unidad de Negocio Bolívar, se ha identificado la necesidad de mejorar la gestión del sistema eléctrico, particularmente en lo que respecta a la estimación de la cargabilidad de los transformadores de distribución del área rural. La ausencia de estudios que empleen técnicas avanzadas ha limitado la capacidad de pronosticar con precisión la carga en estos transformadores, lo que puede conllevar en enfoques menos eficientes en la gestión de la red eléctrica. Por lo tanto, es esencial implementar un enfoque más eficiente para la estimación de la cargabilidad de los transformadores en la Unidad de Negocio Bolívar. La aplicación de modelos matemáticos basados en redes neuronales ofrece una oportunidad para proporcionar una herramienta precisa y confiable para la gestión del sistema eléctrico y mejorar así la eficiencia operativa y la confiabilidad del servicio eléctrico en el alimentador Chimbo.

## 1.2 Fundamentación Teórica

A continuación, se describen los fundamentos teóricos relacionados con la estimación de la cargabilidad de los transformadores de distribución, enfocándose en el uso de redes neuronales artificiales para este propósito. Se buscan los conceptos sobre los principios de funcionamiento de las redes neuronales, y cómo estos modelos matemáticos pueden ser aplicados para mejorar la precisión en la

estimación de la cargabilidad. Además, se explican las metodologías en la evaluación de su desempeño.

### 1.2.1 Sistema eléctrico de distribución

Un sistema de distribución de energía eléctrica es el conjunto de componentes responsables de conducir la electricidad desde una subestación de potencia hasta el usuario final [8], que incluye las etapas de generación, transmisión y la distribución de energía, como se puede observar en la Figura 0.1.

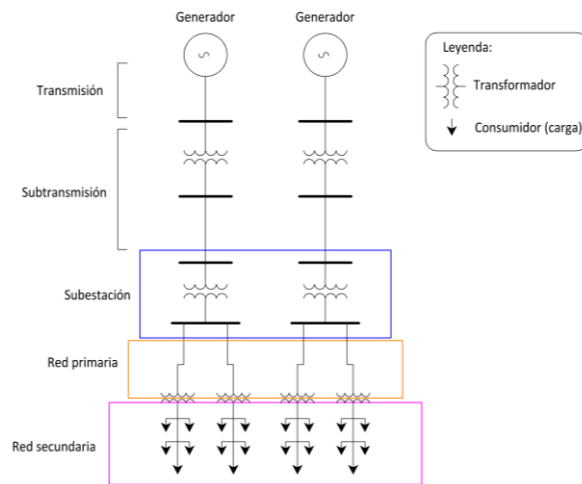


Figura 0.1. Diagrama unifilar de un sistema eléctrico de potencia [8]

La distribución de energía eléctrica incluye las redes primarias de distribución, los transformadores de distribución, las redes secundarias de distribución, así como las acometidas y medidores [8], como se puede observar en la Figura 0.2. En media tensión los voltajes que opera la CNEL EP Unidad de Negocio Bolívar son 13,8 kV y en baja tensión hasta 240 – 120 V.

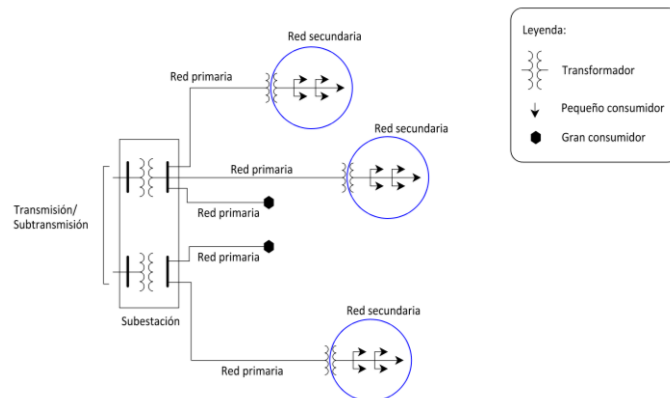


Figura 0.2. Diagrama unifilar de un sistema eléctrico de distribución [8]

A continuación, se detallan las topologías.

## Topologías

**Red Radial:** Esta estructura se caracteriza porque la energía fluye en una sola dirección, desde la fuente hasta la carga. Es común en líneas aéreas y redes subterráneas. En redes radiales con conexiones de respaldo, cada alimentador abastece una zona específica, manteniendo los dispositivos de conexión entre alimentadores abiertos durante la operación normal como se observa en la Figura 0.3. En caso de emergencia, estos dispositivos se cierran estratégicamente para transferir la carga y aislar la sección con fallas [8].




Figura 0.3. Topología de una red eléctrica con configuración radial [8]

**Red anillo:** Esta red se caracteriza por contar con una única troncal principal y no incluir ramales, como se observa en la Figura 0.4. Generalmente, recibe energía de dos puntos distintos, pero en la mayoría de los casos, se opera de manera radial con un punto que permanece normalmente abierto [8].

**Red mallada:** La red mallada se caracteriza por tener alimentadores secundarios que forman una malla robusta, en la que el flujo de energía puede cambiar de dirección según la tensión y la carga. Los alimentadores primarios en esta red pueden ser radiales o en anillo, y conectan subestaciones de distribución que no están

eléctricamente cercanas para evitar que una falla afecte a toda una zona. Cada alimentador primario debe operar con un porcentaje de su capacidad nominal para que, si uno falla, los otros puedan asumir su carga y mantener el suministro [8], como se puede observar en la Figura 0.5.




Figura 0.4. Topología de una red eléctrica con configuración anillo [8]

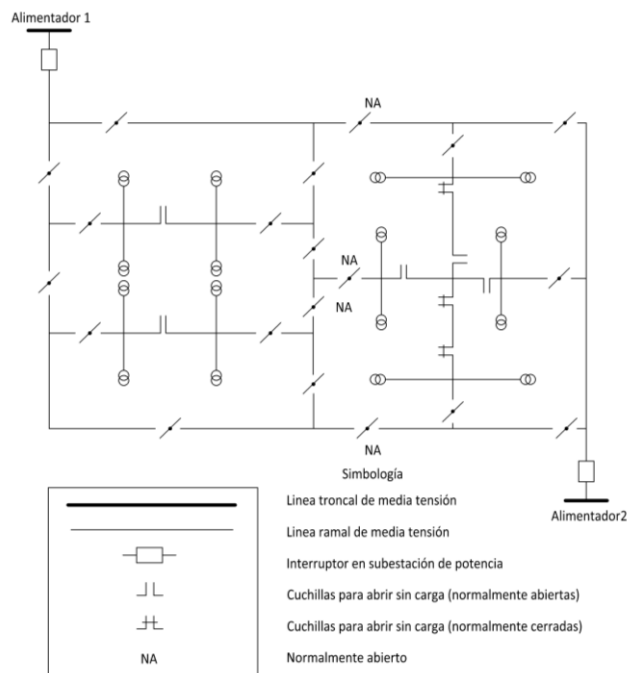


Figura 0.5. Topología de una red eléctrica con configuración mallada [8]

## Elementos Constitutivos de una Red Eléctrica de Distribución.

- Alimentadores primarios: Los alimentadores primarios de distribución están compuestos por conductores responsables de transportar la energía desde las subestaciones de potencia hasta los transformadores de distribución. La estructura de estos alimentadores incluye tanto troncales como ramales [8].

Las redes primarias se clasifican según el número de fases e hilos en:

- Trifásicas de tres hilos
- Trifásicas de cuatro hilos
- Monofásicas de dos hilos
- Monofásicas de un hilo

Trifásicas de tres hilos: Requieren menos inversión inicial que las de 4 hilos, ya que no cuentan con el cuarto hilo que actúa como neutro. Sin embargo, estos sistemas tienen un mayor coeficiente de aterrizamiento, por lo que los equipos deben tener menores niveles de aislamiento. Además, los transformadores de distribución conectados a estas líneas tienen un neutro flotante en el lado primario [8], así como se observa en la Figura 0.6.

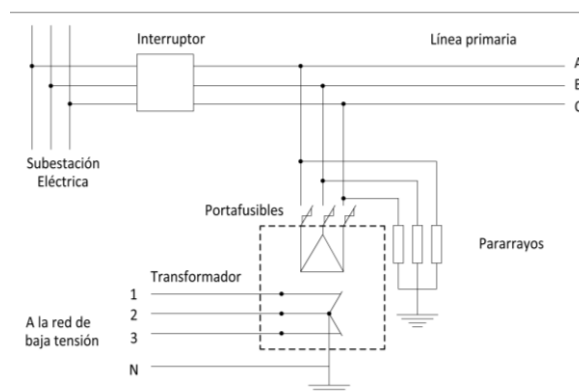


Figura 0.6. Representación de un circuito eléctrico trifásico de tres hilos [8]

Trifásicas de cuatro hilos: Requieren una mayor inversión inicial debido al costo adicional del cuarto hilo, que actúa como neutro. Sin embargo, estos sistemas tienen un coeficiente de aterrizamiento menor a uno, lo que permite usar equipos con

niveles de aislamiento más bajos y, por lo tanto, reducir el costo de inversión. Estas redes se caracterizan por tener transformadores con el neutro del primario conectado a tierra y transformadores monofásicos con tensión primaria de fase a neutro. Son comúnmente utilizadas en zonas urbanas [8], así como se observa en la Figura 0.7.

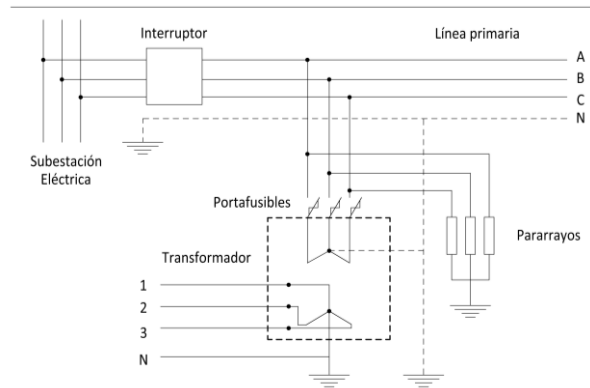


Figura 0.7. Representación de un circuito eléctrico trifásico de cuatro hilos [8]

Monofásicas de dos hilos: Se derivan de líneas trifásicas de 3 o 4 hilos, y se utilizan para alimentar transformadores monofásicos. Estos transformadores pueden recibir la tensión plena de fase (en líneas trifásicas de 3 hilos) o la tensión de fase-neutro (en líneas trifásicas de 4 hilos). Este sistema se emplea principalmente en zonas rurales o en áreas con baja densidad de carga [8], como se puede observar en la Figura 0.8.




Figura 0.8. Representación de un circuito eléctrico monofásico de dos hilos [8]

Monofásicas de un hilo: Las redes monofásicas de un hilo son derivaciones de redes trifásicas diseñadas para alimentar transformadores monofásicos, como se puede observar en la Figura 0.9

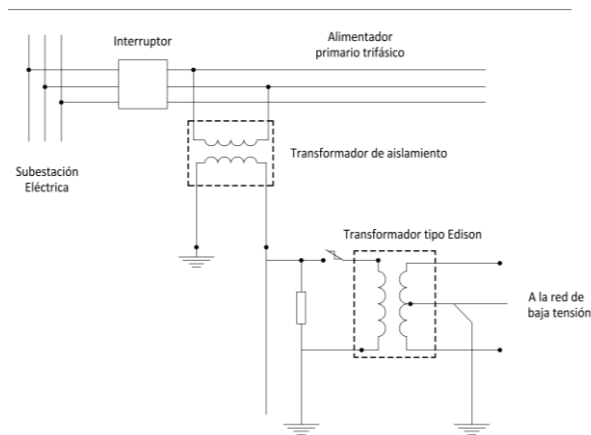


Figura 0.9. Representación de un circuito eléctrico monofásico de un hilo [8]

## Transformadores de Distribución

Los transformadores son componentes fundamentales en las redes de distribución de energía. Su función principal es distribuir la electricidad desde las estaciones generadoras hasta los consumidores de baja tensión, a través de un sistema de conductores que forman los alimentadores de transmisión. Estos alimentadores se diseñan teniendo en cuenta la capacidad de corriente que pueden manejar y la caída de voltaje que necesitan los transformadores. El sistema incluye un alimentador principal y varios alimentadores secundarios que conectan empresas comerciales y comunidades residenciales con la red eléctrica central. La capacidad operativa de los transformadores está definida por sus condiciones de clasificación, lo que garantiza una vida útil de entre 20 y 25 años [7].

En la Tabla 0.2 se presentan las capacidades y clasificaciones de voltaje estándar para transformadores.

Tabla 0.2. Clasificación de los transformadores de distribución (kVA) [9]

<b>Monofásicos</b>	5	10	15	25	37,5	50	75	100	167	250	333	500
<b>Trifásicos</b>	30	45	75	112,5	150	225	300	500				

Transformadores monofásicos: Los transformadores de distribución monofásicos tienen un devanado primario de alta tensión y dos devanados secundarios de baja tensión con una tensión nominal de 120 V [10], como se observa en la Figura 0.10.




Figura 0.10. Diagrama de un transformador de distribución monofásico [9].

Transformadores trifásicos: Los transformadores trifásicos son dispositivos eléctricos utilizados para transformar el voltaje en sistemas de energía trifásica, que es un tipo común de suministro de electricidad en aplicaciones industriales y comerciales. Los transformadores trifásicos se pueden conectar en varias configuraciones, como estrella o delta como se muestra en la Figura 0.11. Cada tipo de conexión tiene sus propias características y aplicaciones específicas [9].




Figura 0.11. Configuraciones de un transformador de distribución trifásico [9]

### 1.3 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNA) son sistemas computacionales inspirados en el funcionamiento del cerebro humano. Estas redes están compuestas por un gran número de nodos computacionales interconectados (denominados neuronas) que trabajan colectivamente para aprender a partir de los datos de entrada y optimizar la salida final [11].




Figura 0.12. Arquitectura de una red neuronal [12]

La estructura fundamental de una red neuronal artificial (RNA) se muestra en la Figura 0.12. En este modelo, los datos de entrada, generalmente son presentados como vectores multidimensionales, que se introducen en la capa de entrada. Esta capa distribuye la información a las capas ocultas, que luego toman decisiones basadas en la información recibida de la capa anterior y evalúan cómo los cambios internos afectan o mejoran el resultado final, a este proceso se le llama aprendizaje.

### 1.3.1 Conceptos, Definiciones

Niveles o capas de una red neuronal: Las neuronas dentro de una red neuronal se organizan en niveles o capas, cada una con una cantidad específica de neuronas. Dependiendo de su posición en la red, estas capas se clasifican en tres tipos [13]:

- Capa de entrada: Es la primera capa que recibe la información directamente de las fuentes externas.
- Capas ocultas: Estas capas están situadas dentro de la red y no tienen contacto directo con el entorno exterior. El número de capas ocultas puede variar desde ninguna hasta múltiples capas. La manera en que las neuronas de estas capas se interconectan entre sí, junto con la cantidad de capas, define las diferentes topologías de las redes neuronales.

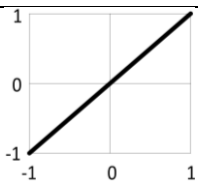
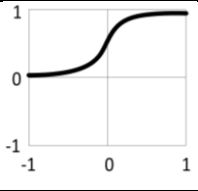
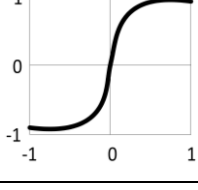
- Capa de salida: Es la capa que transmite la información procesada desde la red hacia el exterior.

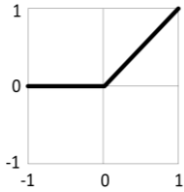
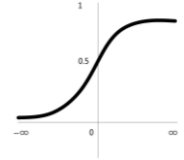
### 1.3.2 Funciones de activación

Las funciones de activación, tanto lineales como no lineales, determinan el nivel de actividad de una neurona al convertir la entrada global en un valor de activación. Este valor está dentro de un rango que va de 0 a 1 o de -1 a 1, dependiendo de la función. Dicho valor indica si la neurona está inactiva (0 ; -1) o activa (1) [13]. Cuando el valor de activación es 0 o -1, la neurona no está aportando a la salida de la red, es decir, está inactiva. En funciones como ReLU, si la entrada es negativa, la salida es 0, indicando que la neurona está "apagada". Por otro lado, un valor de activación de 1 significa que la neurona está activa y participando completamente, como ocurre en una función sigmoide cuando el valor está cerca de 1.

La función de activación depende del problema y suele ser determinada por el programador, a menudo mediante un proceso de prueba y error. Esta selección también se basa en los requisitos de precisión y velocidad, así como en el algoritmo de aprendizaje utilizado. Las funciones de activación más comúnmente empleadas se describen en la Tabla 0.3.

Tabla 0.3. Funciones de activación más utilizadas [14]

Función de Activación	Expresión Analítica	Representación gráfica
Lineal	$f(x) = x$	
Sigmoide	$\sigma(x) = \frac{1}{1 + e^{-x}}$	
Tangente hiperbólica	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	

Unidad lineal rectificada (ReLU)	$ReLU(x) = \max(0, x)$	
Softmax	$Softmax(x) = \frac{e^x}{\sum e^x}$	

La selección de la función de activación para la capa oculta es fundamental, ya que influye directamente en la capacidad del modelo de red para aprender de los datos de entrenamiento. Por otro lado, la función de activación elegida para la capa de salida determinará el tipo de predicciones que el modelo puede realizar.

La función de activación lineal. - se emplea cuando se desea que la salida del modelo refleje directamente las entradas, sin ninguna transformación no lineal. Esto implica que, si varias capas en la red utilizan esta función, el modelo está diseñado para resolver problemas de regresión lineal, donde la relación entre las variables de entrada y salida es lineal [11].

La función de activación sigmoide. - también conocida como función logística, transforma los valores de entrada reales en un rango de 0 a 1. A medida que el valor de entrada aumenta positivamente, la salida se aproxima a 1, mientras que, si el valor de entrada es negativo, la salida tiende a 0. Esta característica la hace ideal para situaciones en las que es necesario restringir las salidas de una red neuronal dentro del intervalo [0, 1], como en problemas de clasificación binaria. Por lo tanto, si se necesita que la salida de una red esté en este rango, se debe emplear la función de activación sigmoide en la capa de salida [11].

La función de activación tangente hiperbólica. - es similar en forma a la función sigmoide, pero en lugar de restringir las salidas al rango de 0 a 1, lo hace en el intervalo de -1 a 1. Los valores de entrada reales se transforman de manera que, a medida que el valor de entrada se vuelve más positivo, la salida se aproxima a 1; por el contrario, cuando el valor de entrada es muy negativo, la salida se acerca a -1. Aunque esta función es útil para centrar los datos en torno a cero y puede mejorar

el rendimiento en algunos casos, al igual que la función sigmoide, puede sufrir del problema conocido como "desvanecimiento del gradiente", donde los gradientes se vuelven muy pequeños durante el entrenamiento, lo que dificulta el aprendizaje eficaz en redes neuronales profundas [11].

La función ReLU (Unidad Lineal Rectificada). - es una función de activación que convierte todas las entradas negativas en cero, mientras que deja pasar las entradas positivas tal como son. En otras palabras, "rectifica" las señales, garantizando que las salidas siempre sean positivas. Este comportamiento simplificado permite un procesamiento más rápido y eficiente durante el entrenamiento de redes neuronales, lo que la hace muy popular en modelos modernos [14].

La función de activación softmax transforma un conjunto de valores en un vector de probabilidades, donde la suma de todas estas probabilidades es igual a 1. Esto permite interpretar cada valor como la probabilidad de que un elemento pertenezca a una clase específica. Es especialmente útil cuando se trabaja con problemas de clasificación multiclase, ya que ayuda a determinar a cuál de las varias clases posibles pertenece un elemento dado [14].




Figura 0.13. Funciones de activación de capas ocultas recomendadas de acuerdo al tipo de red neuronal [11]

En la Figura 0.13, se pueden observar las funciones de activación de capas ocultas recomendadas de acuerdo al tipo de red neuronal.

### 1.3.3 Clasificación de las redes neuronales

Las redes neuronales artificiales se pueden clasificar en varias categorías basadas en cómo los datos fluyen a través de la red y en la estructura de las conexiones entre las neuronas. A continuación, se presenta una breve clasificación:

### **Según la arquitectura**

Redes Neuronales Feedforward (FNN). – En estas redes, el flujo de datos es unidireccional, desde las neuronas de entrada hasta las neuronas de salida, pasando por capas ocultas si las hay. No existen conexiones de retroalimentación. Son las más simples y ampliamente utilizadas en tareas de clasificación y regresión [11].

Redes Recurrentes (RNN). – En este tipo de red, son efectivas para captar correlaciones ocultas en datos y son ideales para problemas de secuencia, como reconocimiento de voz y predicción de series temporales, debido a sus conexiones recurrentes que permiten utilizar tanto la información actual como la previamente adquirida [15].

Redes Convolucionales (CNN). – es una red neuronal profunda utilizada para tareas con alta correlación local, como imágenes, videos y categorización de texto. Son efectivas para manejar datos de alta dimensión, requieren poco procesamiento previo y destacan por su arquitectura de pesos compartidos e invariancia de traslación [15].

### **Según el aprendizaje**

Supervisado. – es un tipo de aprendizaje asociativo en el cual la red es entrenada proporcionándole datos de entrada y salida correspondientes. Estos datos de entrada y salida pueden ser proporcionados por un maestro externo o por el sistema que contiene la red, en un proceso llamado auto-supervisión [16].

No supervisado. – también llamado autoorganización, es un tipo de aprendizaje en el que una unidad de salida se entrena para identificar y responder a grupos de patrones en los datos de entrada. En este enfoque, el sistema es responsable de descubrir por sí mismo las características más importantes o destacadas de los datos. A diferencia del aprendizaje supervisado, en el que las categorías están predeterminadas, en el aprendizaje no supervisado no hay etiquetas ni categorías previas. El sistema debe aprender a crear su propia representación o categorización de los datos de entrada [16].

### 1.3.4 Topología de las redes neuronales

**Monocapa:** Las redes monocapa están compuestas únicamente por una capa de entrada y una capa de salida como se observa en la Figura 0.14. La capa de entrada recibe los datos y los pasa directamente a la capa de salida, que produce el resultado final. No hay capas intermedias entre la entrada y la salida. Un perceptrón simple es un tipo de red monocapa [11].




Figura 0.14. Esquema de una red neuronal monocapa [11]

**Multicapa:** Incluyen una o más capas ocultas entre la capa de entrada y la capa de salida, como se observa en la Figura 0.12. La capa de entrada envía información a las capas ocultas, y estas, a su vez, envían información a la capa de salida. Las capas ocultas permiten que la red aprenda representaciones más complejas de los datos. Un Perceptrón Multicapa (MLP) es una red neuronal multicapa [11].

### 1.3.5 Proceso de entrenamiento

El entrenamiento de una red neuronal artificial (RNA) es el proceso mediante el cual se ajustan los pesos de las conexiones entre neuronas para minimizar la diferencia entre las predicciones del modelo y las respuestas verdaderas. Los datos de entrenamiento se utilizan para enseñar al modelo las relaciones entre las entradas y salidas esperadas. Para este propósito se considera diferentes tipos de algoritmos de optimización [11].

Los algoritmos de optimización son técnicas utilizadas en el campo del aprendizaje automático y la estadística para ajustar los parámetros de un modelo con el objetivo de mejorar su rendimiento. Su propósito principal es encontrar los valores óptimos de los parámetros del modelo que minimicen o maximicen una función de pérdida o función objetivo, a continuación, se detallan los más utilizados [11]:

Descenso por Gradiente (Gradient Descent - GD). - utilizado para encontrar el mínimo de una función de pérdida. Este algoritmo ajusta iterativamente los parámetros del modelo al calcular el gradiente de la función de pérdida con respecto a los parámetros y actualizar estos parámetros en la dirección opuesta al gradiente. La magnitud del ajuste está determinada por una tasa de aprendizaje fija. Aunque es simple y ampliamente utilizado, su eficiencia puede verse afectada por la elección de la tasa de aprendizaje y la posible convergencia a mínimos locales en funciones de pérdida no convexas [17].

Estimación Adaptativa de Momentos (Adaptive Moment Estimation - ADAM). - es un algoritmo de optimización avanzado que mejora el Descenso por Gradiente ajustando las tasas de aprendizaje para cada parámetro del modelo. Adam calcula adaptativamente tasas de aprendizaje individuales utilizando estimaciones de los momentos primero (la media de los gradientes) y segundo (la varianza de los gradientes) de la función de pérdida. Este enfoque proporciona una actualización más robusta y eficiente de los parámetros, facilitando una convergencia más rápida y estable en comparación con el método tradicional de Descenso por Gradiente, especialmente en problemas con grandes cantidades de datos o parámetros [17].

Descenso de Gradiente Estocástico (Stochastic Gradient Descent - SGD). - es una variante del Descenso por Gradiente que mejora la eficiencia en la optimización al actualizar los parámetros del modelo utilizando solo un subconjunto aleatorio de datos, conocido como minibatch, en cada iteración. En lugar de calcular el gradiente de la función de pérdida sobre todo el conjunto de datos, SGD realiza actualizaciones más frecuentes y con menor costo computacional, ya que cada minibatch proporciona una estimación del gradiente. Aunque SGD puede converger más rápidamente en comparación con el Descenso por Gradiente tradicional, su trayectoria de actualización puede ser más ruidosa debido a la variabilidad en los

gradientes estimados. A pesar de esto, la actualización frecuente puede ayudar a escapar de mínimos locales y alcanzar una mejor solución global en funciones de pérdida complejas [18].

### **1.3.6 Validación**

La validación de datos se refiere al proceso de evaluar un modelo con un conjunto de datos diferente al utilizado durante su entrenamiento, con el fin de estimar su capacidad de generalización. El objetivo principal de la validación es evitar el sobreajuste, garantizando que el modelo no solo aprenda los detalles y el ruido del conjunto de entrenamiento, sino que también pueda generalizar bien en datos nuevos y no vistos [11].

Durante el entrenamiento, el conjunto de datos generalmente se divide en tres subconjuntos:

- Conjunto de Entrenamiento: Usado para ajustar los pesos del modelo.
- Conjunto de Validación: Empleado para monitorear el rendimiento del modelo y prevenir el sobreajuste.
- Conjunto de Prueba: Utilizado para evaluar el rendimiento final del modelo después del entrenamiento.

Mientras el modelo se entrena en el conjunto de entrenamiento, se evalúa periódicamente en el conjunto de validación para obtener una medida de su rendimiento en datos no vistos durante el entrenamiento. Este proceso garantiza que el modelo pueda generalizar correctamente cuando se aplique a datos nuevos [11].

### **Sobreajuste (Overfitting) y Subajuste (Underfitting)**

Sobreajuste (Overfitting). - El sobreajuste ocurre cuando un modelo se adapta demasiado a los datos de entrenamiento, aprendiendo no solo los datos generales sino también los detalles específicos y el ruido presente en esos datos. Esto resulta en un modelo que funciona bien en los datos de entrenamiento, pero que tiene un rendimiento deficiente cuando se enfrenta a nuevos datos que no ha visto antes. En otras palabras, el modelo pierde su capacidad de generalización [19] .

Subajuste (Underfitting). - El subajuste sucede cuando el modelo es demasiado simple para capturar los patrones importantes en los datos. Esto significa que no logra aprender adecuadamente ni siquiera de los datos de entrenamiento, lo que provoca un rendimiento pobre tanto en los datos de entrenamiento como en los de validación. Un modelo subajustado no ha aprendido lo suficiente para ser útil en predicciones [19].

El sobreajuste puede detectarse monitoreando el rendimiento del modelo en el conjunto de validación a lo largo del tiempo. Si el modelo continúa mejorando su rendimiento en el conjunto de entrenamiento, pero el rendimiento en el conjunto de validación empieza a deteriorarse o se estabiliza sin mejorar, es un indicio claro de que el modelo está sobreajustando. En este punto, el modelo ha comenzado a memorizar los datos de entrenamiento en lugar de aprender datos que puedan aplicarse a datos nuevos [11].

La Figura 0.15 ilustra gráficamente estos tres conceptos. El primer gráfico muestra un modelo subajustado (Underfitting), que es demasiado simple y no captura adecuadamente la tendencia de los datos. El segundo gráfico representa un modelo con un buen ajuste (Good Fit/Robust), que sigue la tendencia general de los datos sin capturar el ruido. El tercer gráfico muestra un modelo sobreajustado (Overfitting), que sigue demasiado de cerca los datos de entrenamiento, capturando incluso el ruido, lo que compromete su capacidad de generalización a nuevos datos.




Figura 0.15. Problemas de ajuste de datos [20]

### **Criterios de parada**

En el entrenamiento de modelos de aprendizaje automático, es esencial establecer criterios de parada para controlar la duración del proceso y evitar problemas como el sobreajuste. De acuerdo con [21] los criterios de parada más comunes incluyen:

- **Número Máximo de Épocas:** Establece un límite en el número total de iteraciones que el modelo realizará durante el entrenamiento, garantizando que el proceso no se extienda indefinidamente.
- **Early Stopping (Detención Temprana):** Detiene el entrenamiento si una métrica de validación, como la pérdida, no mejora durante un número específico de épocas consecutivas (patience), previniendo el sobreajuste y optimizando el tiempo de entrenamiento.
- **Callbacks de Monitoreo:** Utiliza herramientas para proporcionar retroalimentación continua durante el entrenamiento, facilitando el seguimiento del progreso y la gestión del proceso.

### 1.3.7 Métricas de Evaluación

En el contexto de la regresión, las métricas de evaluación se utilizan para medir el rendimiento y la precisión de un modelo predictivo. Estas métricas proporcionan una visión cuantitativa de cómo el modelo se ajusta a los datos y cómo se comporta en comparación con el modelo ideal. A continuación, se describen algunas de las métricas de evaluación más comunes para problemas de regresión:

**Error Cuadrático Medio MSE (Mean Squared Error):** Mide la media de los cuadrados de los errores, que son las diferencias entre los valores predichos por el modelo y los valores reales [22]. Se calcula como ecuación (1):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

Donde  $y_i$  es el valor real,  $\hat{y}_i$  es el valor predicho, y  $n$  es el número total de observaciones.

El MSE penaliza los errores grandes debido al término cuadrático. Un MSE bajo indica que el modelo tiene una buena capacidad predictiva, mientras que un MSE alto indica que el modelo no está ajustando bien los datos.

**Ventajas:** Sensible a errores grandes, lo que puede ser útil si los errores grandes son especialmente indeseables.

**Desventajas:** No tiene una unidad interpretable, ya que está en las unidades al cuadrado de la variable objetivo, y es sensible a valores atípicos.

**Error Absoluto Medio MAE (Mean Absolute Error):** Mide la media de los valores absolutos de los errores, es decir, las diferencias entre los valores predichos y los valores reales [22]. Se calcula como ecuación (2):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

El MAE proporciona una medida clara y directa de la magnitud promedio de los errores sin penalizar los errores grandes de manera tan rigurosa como el MSE. Un MAE bajo indica que el modelo tiene una buena precisión en sus predicciones.

**Ventajas:** Fácil de interpretar ya que está en las mismas unidades que la variable objetivo; menos sensible a valores atípicos comparado con el MSE.

**Desventajas:** No penaliza los errores grandes de manera significativa, por lo que puede ser menos útil si se desean evitar errores grandes.

**Error Cuadrático Medio Raíz RMSE (Root Mean Squared Error):** Mide la desviación promedio de los errores de predicción del modelo en las mismas unidades que la variable objetivo [23]. Se calcula como la raíz cuadrada del MSE, con la siguiente ecuación (3):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

El RMSE proporciona una medida de la magnitud promedio de los errores en las mismas unidades que la variable objetivo. Un RMSE bajo indica una buena precisión en las predicciones, mientras que un RMSE alto indica que el modelo no está ajustando bien los datos.

**Ventajas:** Está en las mismas unidades que la variable objetivo, facilitando su interpretación y penaliza los errores grandes, lo que puede ser útil si se desean evitar errores grandes.

**Desventajas:** Puede ser muy sensible a valores atípicos, ya que los errores grandes tienen un impacto desproporcionado y la magnitud del RMSE puede ser difícil de interpretar sin el contexto adecuado.

- Coeficiente de Determinación ( $R^2$ )

Mide la proporción de la variabilidad total en la variable dependiente que es explicada por el modelo [23]. Se calcula como ecuación (4):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (4)$$

Donde  $\bar{y}_i$  es la media de los valores reales.

El valor de  $R^2$  varía entre 0 y 1, donde un valor de 1 indica que el modelo explica toda la variabilidad de los datos y un valor de 0 indica que el modelo no explica nada de la variabilidad. Un valor  $R^2$  alto indica que el modelo tiene un buen ajuste a los datos.

**Ventajas:** Proporciona una medida de la cantidad de variabilidad explicada por el modelo, y es útil para comparar la calidad de diferentes modelos.

**Desventajas:** Un alto  $R^2$  no siempre garantiza un buen modelo, especialmente si el modelo es complejo, lo que podría indicar sobreajuste.

### 1.3.8 Preprocesamiento de datos

El preprocesamiento de datos es un paso fundamental en el desarrollo de modelos de aprendizaje automático, ya que garantiza que los datos estén en un formato adecuado para ser utilizados por los algoritmos de entrenamiento. Este proceso puede incluir varias técnicas, como la eliminación de valores faltantes, la codificación de variables categóricas y la normalización. El objetivo principal es

mejorar la calidad y consistencia de los datos para optimizar el rendimiento del modelo. Una de las técnicas más comunes en el preprocesamiento es la normalización, que se describe a continuación [24].

### Normalización

La normalización es una técnica de preprocesamiento de datos que ajusta los valores de diferentes variables para que se encuentren dentro de un rango común, generalmente entre 0 y 1. Esto es importante porque garantiza que todas las variables tengan la misma influencia en los modelos de aprendizaje automático, evitando que variables con valores grandes dominen el proceso de entrenamiento. La normalización ayuda a mejorar la precisión y la estabilidad de los modelos predictivos. Las técnicas más utilizadas son:

**Z-score:** Ajusta los datos para que tengan una media de 0 y una desviación estándar de 1, útil para datos con diferentes unidades o escalas [25]. Se utiliza la ecuación (5).

$$Z = \sum_{i=1}^n \frac{x_i - \mu}{\delta} \quad (5)$$

Donde  $x$  es el valor original,  $\mu$  es la media de la característica, y  $\delta$  es la desviación estándar. Este método es útil cuando las características tienen diferentes unidades o escalas y es necesario que todas sigan una distribución normal.

**Min-Max:** Este método ajusta los valores de los datos para que estén dentro de un rango específico, generalmente entre 0 y 1 [11]. Se utiliza la ecuación (6):

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (6)$$

Donde  $X$  representa el valor original de un dato particular dentro de un conjunto de datos,  $X_{min}$  es el valor mínimo de la variable considerada en el conjunto de datos y  $X_{max}$  es el valor máximo de esa misma variable en el conjunto.

### 1.3.9 Método REA (Rural Electrification Administration)

La Administración de Electrificación Rural (REA) se creó en 1935 para llevar electricidad a las zonas rurales de Estados Unidos. Fue muy exitosa, y para 1952, la mayoría de estas áreas ya contaban con electricidad [26].

Desde 1939, la REA ha calculado la capacidad necesaria para cargas futuras utilizando curvas que relacionan la demanda en kW con el número de consumidores y el consumo promedio de kWh [26].

Este método ha demostrado ser confiable y se ha adaptado con el tiempo a los cambios en la red. Para calcular la demanda en kW, se multiplican dos factores: el número de clientes y el consumo en kWh, los cuales pueden obtenerse de tablas predefinidas o calcularse matemáticamente [26].

#### **Cálculo de la demanda en kW**

El cálculo de la demanda en kW sigue un proceso en el que se consideran dos factores clave: el factor A, que representa la influencia del número de consumidores, y el factor B, que refleja la relación entre el consumo promedio y la demanda. El proceso inicia con la identificación del número de clientes (C) y el consumo específico promedio mensual (Ce) en kWh. Luego, se calcula el factor A utilizando la ecuación (7). A continuación, se determina el factor B mediante la ecuación (8), la cual refleja el impacto del consumo específico en la carga. Finalmente, la demanda total en kW se obtiene al multiplicar los factores A y B, permitiendo una proyección precisa de la demanda eléctrica.

El primer término se ha designado como factor de kWh o factor B, y el segundo término como factor de consumidores o factor A. Para calcular la demanda en kW para cualquier número de consumidores, simplemente se deben multiplicar los factores A y B [26].

El factor A es el factor del consumidor el cual refleja una mejora en la diversidad debido al incremento en el número de consumidores y se determina mediante la ecuación (7) .

$$\text{Factor A} = C[1 - 0,4C + 0,4(C^2 + 40)^{1/2}] \quad (7)$$

Donde:

C, es el número de clientes

El factor B es el factor de kWh el cual indica la tendencia en el factor de carga al presentarse un mayor consumo y se determina mediante la ecuación (8).

$$\text{Factor } B = 0,005925 \times C e^{0,885} \quad (8)$$

Donde:

Ce, es el consumo específico (promedio mensual en kWh de los clientes).

## 1.4 Fundamentación metodológica

### 1.4.1 Enfoque de la investigación

Este trabajo se enmarca en un enfoque cuantitativo [27] y busca implementar un modelo matemático basado en redes neuronales artificiales para estimar la cargabilidad de los transformadores del alimentador Chimbo. Primero, se entrenará la red neuronal con variables como la capacidad del transformador, el consumo de los usuarios y la potencia total de alumbrado público, utilizando datos históricos de CNEL EP Unidad de Negocio Bolívar.

El modelo calculará la cargabilidad de todos los transformadores, pero su validación se enfocará en los transformadores rurales. Para esto, se compararán los resultados del modelo con estimaciones obtenidas mediante el método REA y con mediciones reales de analizadores en un conjunto seleccionado de transformadores. Los resultados se presentarán en cuadros y gráficos estadísticos.

### 1.4.2 Tipo de investigación

En la Tabla 0.4, se resumen los tipos de investigación utilizados en el presente trabajo.

Tabla 0.4. Tipos de investigación utilizados en el estudio

<b>Tipo de Investigación</b>	<b>Descripción</b>
<b>Descriptiva</b>	La investigación tiene un enfoque descriptivo ya que analiza el consumo de energía y la distribución en el alimentador Chimbo para describir la variabilidad del consumo y la cargabilidad de los transformadores. Se han recopilado datos sobre cómo se distribuye el

	consumo entre estratos tarifarios y el rendimiento de los transformadores [27].
<b>Experimental</b>	La investigación incluye un componente experimental mediante la aplicación de un método basado en redes neuronales para estimar la cargabilidad de los transformadores en el alimentador Chimbo y comparar su eficacia con el método tradicional REA. Aunque no se manipulan directamente variables experimentales, la implementación y ajuste del modelo de red neuronal representan un enfoque experimental [28].
<b>Estudio de caso</b>	La investigación se centra en el análisis detallado del alimentador Chimbo, un caso específico dentro de la provincia Bolívar que cuenta con 600 transformadores. El estudio proporciona una evaluación de la cargabilidad de los transformadores en este alimentador [27].

### 1.4.3 Técnica de recolección de información

Para la recolección de información en esta investigación [27], se obtendrán datos específicos sobre el consumo de energía y el número de usuarios de los transformadores del alimentador Chimbo proporcionados por la CNEL EP Unidad de Negocio Bolívar. Estos datos incluirán variables como la capacidad del transformador, el consumo de los usuarios, y la potencia total de alumbrado público.

Con esta información, se entrenará una red neuronal artificial para calcular la cargabilidad de los transformadores. El modelo de redes neuronales se implementará utilizando estos datos históricos para aprender relaciones y estimar la cargabilidad en tiempo real. Además, para validar la precisión del modelo de redes neuronales, se compararán sus predicciones con estimaciones obtenidas mediante el Método REA (Administración de Electrificación Rural), el cual se aplicará para calcular la cargabilidad de los transformadores en el área rural del alimentador Chimbo. También se realizarán comparaciones con mediciones reales obtenidas de analizadores de calidad de energía. Esta comparación permitirá evaluar la efectividad del modelo de redes neuronales y su precisión en la estimación de la cargabilidad.

#### **1.4.4 Procedimientos empleados para la obtención y análisis de la información.**

Para el desarrollo de este estudio, se utilizará la información disponible en el Sistema de Información Geográfica (SIG) y el sistema comercial CIS/CRM (Customer Information System/ Customer Relationship Management) de CNEL Bolívar. Con estos datos, se construirá una base de datos que servirá como entrada para el entrenamiento de la red neuronal. El modelo será validado utilizando la metodología REA y los análisis de calidad de energía realizados entre los años 2022 y 2024. Finalmente, los resultados serán analizados y presentados en tablas, con el fin de evaluar la precisión y viabilidad del modelo, obteniendo así información para procesos de planificación a mediano y largo plazo.

#### **1.5 Conclusiones Capítulo I**

- La elección de la topología de la red neuronal, ya sea monocapa o multicapa, influye significativamente en la capacidad de un modelo para aprender relaciones complejas y hacer predicciones precisas. Las redes multicapa, al incluir capas ocultas, permiten al modelo identificar relaciones más complejas que las redes monocapa, lo que es clave para tareas de estimación y predicción. Además, el proceso de entrenamiento y los algoritmos de optimización, como el Descenso por Gradiente Estocástico (SGD) y ADAM, son importantes en el ajuste de los parámetros del modelo para minimizar errores y mejorar la capacidad de generalización. Por eso, es fundamental elegir y ajustar bien tanto la estructura de la red como los métodos de optimización para obtener modelos precisos y confiables.
- El sobreajuste y el subajuste son problemas que afectan la precisión de los modelos predictivos. El sobreajuste ocurre cuando el modelo funciona muy bien con los datos de entrenamiento, pero falla con nuevos datos porque aprende detalles irrelevantes. El subajuste sucede cuando el modelo es demasiado simple y no puede captar las relaciones importantes, lo que produce predicciones inexactas. Ambos problemas pueden llevar a decisiones equivocadas. Para evitarlos, es importante validar correctamente

el modelo y usar métricas como MAE y MSE, que aseguran un buen balance entre precisión y generalización.

- La combinación de métodos tradicionales como el REA y redes neuronales ofrece un enfoque completo para estimar la cargabilidad de los transformadores rurales en el alimentador Chimbo. El método REA estima la demanda en kW con factores predefinidos, mientras que las redes neuronales capturan patrones más complejos usando datos históricos. Al comparar las predicciones de las redes neuronales con los cálculos del REA y mediciones reales, se asegura la precisión del modelo, mostrando que combinar ambos métodos son útiles para este tipo de análisis.

## **CAPÍTULO II**

### **PROPUESTA**

Este capítulo se encuentra dividido en 4 secciones, en donde la Sección 2.1 presenta el título del trabajo de investigación, en la Sección 2.2 se establece como objetivo de la propuesta la implementación de un modelo matemático para estimar la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la CNEL EP Unidad de Negocio Bolívar, mediante una red neuronal. La Sección 2.3 enfatiza la importancia de la propuesta en el uso de redes neuronales para la estimación de la cargabilidad de los transformadores de distribución, destacando su utilidad en la planificación y gestión de la infraestructura eléctrica. En la Sección 2.4 se mencionan aspectos fundamentales que respaldan la ejecución de la propuesta, haciendo hincapié en la aplicación de diferentes herramientas adecuadas para el desarrollo de la misma. Por último, en la Sección 2.5 se detalla el desarrollo de la metodología, abordando la construcción y tratamiento de datos, así como aspectos clave de la red neuronal y del método REA.

#### **2.1 Título de la propuesta**

Modelo matemático para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal.

#### **2.2 Objetivo de la propuesta**

Implementar un modelo matemático para estimar la cargabilidad de los transformadores de distribución en el alimentador Chimbo de la Unidad de Negocio Bolívar, mediante una red neuronal.

### **2.3 Justificación de la propuesta**

El cálculo preciso de la cargabilidad de los transformadores de distribución es esencial para garantizar su funcionamiento dentro de los límites operativos adecuados. En el alimentador Chimbo de la Unidad de Negocio Bolívar, es indispensable contar con herramientas que permitan realizar estas estimaciones de manera efectiva y confiable.

El uso de un modelo matemático basado en redes neuronales ofrece una solución avanzada. Este modelo permitirá realizar cálculos precisos de la cargabilidad, basados en el análisis de datos históricos y actuales, lo que garantizará que los transformadores operen dentro de parámetros seguros.

El modelo propuesto ha sido implementado para estimar la cargabilidad de todos los transformadores del sistema. Sin embargo, dado que el método REA es específicamente aplicable a transformadores rurales, la validación del modelo se centrará en comparar sus resultados con este método para los transformadores rurales.

Además, se compararán los resultados obtenidos por el modelo con las mediciones realizadas por equipos analizadores en un conjunto de transformadores. Aunque las mediciones disponibles son limitadas, proporcionan un punto de referencia importante para evaluar la precisión del modelo en condiciones reales.

Finalmente, la implementación de este modelo matemático en el alimentador Chimbo representa una herramienta valiosa para la gestión de transformadores rurales. La validación mediante la comparación con el método REA y las mediciones reales permitirá garantizar su efectividad en estos contextos específicos.

### **2.4 Fundamentación de la propuesta**

En primer lugar, la propuesta de implementar un modelo matemático basado en redes neuronales artificiales para estimar la cargabilidad de los transformadores de distribución en el alimentador Chimbo surge de la necesidad de superar las limitaciones de los métodos tradicionales de medición y estimación. En la

actualidad, los métodos convencionales para la evaluación de la cargabilidad pueden no proporcionar la precisión necesaria. La implementación de un modelo basado en redes neuronales ofrece una solución que permite un análisis más detallado, para garantizar el funcionamiento seguro y eficiente de los transformadores.

En segundo lugar, utilizando datos históricos y actuales proporcionados por CNEL EP Unidad de Negocio Bolívar, el modelo de red neuronal puede realizar predicciones más precisas sobre la cargabilidad de los transformadores. Esta metodología es capaz de ofrecer una visión más dinámica y exacta del estado de carga de los transformadores en comparación con los métodos tradicionales [29].

En tercer lugar, partiendo del método REA (Rural Electrification Administration) que ha sido seleccionado como referencia para la validación del modelo propuesto. Aunque el REA no se utilizará directamente en el desarrollo del modelo, su uso consolidado en la evaluación de sistemas eléctricos rurales proporciona una base para comparar los resultados obtenidos con la red neuronal. Este método ofrece una estructura comprobada para la evaluación de la capacidad de los transformadores, teniendo en cuenta factores clave como el número de abonados y el consumo específico [26]. Comparar las estimaciones del modelo de redes neuronales con las del REA permitirá verificar la exactitud y fiabilidad del modelo en un contexto práctico.

Posteriormente, se incorporará una comparación adicional utilizando mediciones obtenidas de equipos analizadores de calidad de energía [30]. Aunque las mediciones disponibles son limitadas, servirán como un punto de referencia valioso para evaluar la precisión del modelo en condiciones reales.


Finalmente, la propuesta de utilizar redes neuronales para la estimación de la cargabilidad de los transformadores está justificada por la necesidad de herramientas más precisas y avanzadas. La combinación de la validación mediante el método REA y las mediciones reales proporcionará una base para confirmar la efectividad y aplicabilidad del modelo en el alimentador Chimbo.

## 2.5 Desarrollo de la metodología

La metodología se centra en implementar un modelo de red neuronal artificial para estimar la cargabilidad de todos los transformadores de distribución en el alimentador Chimbo. Se construyó una base de datos con registros de consumo de siete meses, organizados en ocho estratos de consumo para cuatro categorías distintas. El modelo de red neuronal fue diseñado considerando la arquitectura, funciones de activación, métodos de optimización y parámetros de entrenamiento adecuados. Para validar la precisión del modelo, se compararon los resultados obtenidos con los del método REA, que se utiliza específicamente para transformadores rurales, y con mediciones reales de equipos analizadores de calidad de energía, lo que permitió evaluar la precisión y del modelo en condiciones reales.

### 2.5.1 Introducción

El enfoque metodológico propuesto para la estimación de la cargabilidad de los transformadores de distribución en el alimentador Chimbo se describe de manera estructurada en la Figura 0.1.






Figura 0.1. Metodología de trabajo propuesta

A continuación, se describen detalladamente las etapas del proceso:

### 2.5.2 Construcción de la base de datos

La base de datos utilizada en este estudio se construyó a partir de dos fuentes principales: SIG y el sistema comercial CIS/CRM. El SIG proporcionó información detallada sobre los 600 transformadores del alimentador Chimbo. Por otro lado, los datos de consumo de siete meses de los 6536 usuarios conectados a este alimentador, de los cuales 6042 son usuarios residenciales, lo que corresponde al 92.44% de todos los usuarios, esta información se recopiló utilizando el sistema

CIS/CRM. Además, en base a un cruce de tablas que permitió asociar cada usuario con su respectivo transformador.

Dado que existen diferentes categorías tarifarias con consumos diversos, los usuarios se estratificaron en ocho grupos de consumo: Cero, E1, E, D, C, B, A y A1, que cubren las categorías: Residencial (R), Comercial (C), Industrial Artesanal (IA) y Otros. Esta estratificación permite diferenciar los datos de consumo y las demandas específicas de cada tipo de consumidor, según su tarifa correspondiente, como se puede observar en la Tabla 0.1.

Tabla 0.1. Estratificación de usuarios

<b>Estrato</b>	<b>Rango</b>	<b>R</b>	<b>C</b>	<b>IA</b>	<b>Otros</b>
<b>Cero</b>	0	269	7	0	15
<b>E1</b>	1-12	942	24	1	28
<b>E</b>	12-50	1.772	48	2	21
<b>D</b>	50-110	1.991	40	2	40
<b>C</b>	110-200	838	48	2	26
<b>B</b>	200-300	173	24	3	24
<b>A</b>	300-500	48	27	3	21
<b>A1</b>	>500	9	60	0	28

Además, para calcular la potencia total de alumbrado público, se llevó a cabo un cruce de tablas entre el número de transformador y la potencia de cada una de las luminarias asociadas a cada uno. Esto permitió calcular con precisión la potencia total correspondiente a cada transformador.

El resultado final es una base de datos en formato Excel que recopila información como el número de transformador, su capacidad en kVA, el total de usuarios conectados, el consumo promedio de estos usuarios y la potencia total de alumbrado público, Estos datos se utilizarán como entradas para la red neuronal, en la Tabla 0.2 se presentan cinco ejemplos.

Tabla 0.2. Base de datos

<b>N° de Transformador</b>	<b>Capacidad (kVA)</b>	<b>N° Usuarios</b>	<b>Consumo (kWh)</b>	<b>Potencia Total AP (kW)</b>
<b>304141</b>	10	6	132	0
<b>304088</b>	37,5	28	1489	1,45
<b>301471</b>	15	11	203	0,9
<b>301160</b>	25	34	2107	1,9
<b>303609</b>	10	7	461	0

### 2.5.3 Tratamiento de datos

**Limpieza de datos:** En esta etapa, se llevó a cabo la identificación y corrección de valores atípicos o erróneos, como los transformadores que no poseen ninguna cuenta asociada. Se consideró la eliminación de estos transformadores, dado que las cuentas asociadas no se encontraban ingresadas en el sistema comercial y la imputación de los valores faltantes no fue viable dada la dificultad de predecir con precisión del tipo de cuentas y de los consumos de las mismas. Adicionalmente, se realizó una verificación de la consistencia de los datos para garantizar su integridad y fiabilidad en etapas posteriores del análisis [8].

**Normalización de datos:** Se realizó una normalización de los datos utilizando el método Z-score para mejorar el rendimiento y la estabilidad del modelo de red neuronal. Esta técnica ajusta los valores de las variables restando la media y dividiendo por la desviación estándar, lo que centra los datos alrededor de 0 y los escala en función de su dispersión. Esto ayuda a evitar problemas relacionados con las grandes diferencias en los rangos de las variables. La normalización Z-score garantiza que las actualizaciones de los pesos durante el entrenamiento sean más estables y que ninguna variable con valores grandes domine el proceso de aprendizaje, proporcionando así un entrenamiento más eficaz y robusto del modelo [8].

### 2.5.4 Diseño e implementación del modelo de la red neuronal

#### Arquitectura del modelo

La red neuronal diseñada es una red completamente conectada (Fully Connected Network, FCN), en la que cada nodo de una capa está conectado a todos los nodos de las capas vecinas. La arquitectura específica de la red es la siguiente:

- Configuración de Capas:
  - Entrada: 4 nodos de entrada.
  - Capas Ocultas: Cuatro capas ocultas con 128, 128, 64 y 64 nodos respectivamente.
  - Salida: 1 nodo de salida.

Esta configuración se estableció mediante pruebas experimentales para ajustar el número de neuronas y capas ocultas, con el objetivo de optimizar la capacidad del modelo para aprender de los datos.

A continuación, en la Figura 0.2 se muestra un diagrama de la arquitectura de la red neuronal para verificar la disposición de las capas y los nodos:




Figura 0.2. Topología de la red neuronal implementada. Realizado con [31]

- Variables del Modelo: Las variables de entrada son:
  - Capacidad del transformador (kVA)
  - Total de consumo de usuarios (kWh)
  - Total de usuarios
  - Potencia total de alumbrado público (kW)

La variable objetivo, que se predice con el modelo, es:

- Cargabilidad del transformador (%)

Esta estructura permite que el modelo capture y aprenda patrones complejos en los datos, lo que permite al modelo aprender patrones complejos y realizar predicciones precisas de cargabilidad.

### **2.5.5 Funciones de activación**

En nuestra red neuronal, se utiliza la función de activación ReLU en todas las capas ocultas. Esta elección se basa en su capacidad para introducir no linealidades en el modelo de manera eficiente y ayudar a prevenir problemas durante el entrenamiento, como el desvanecimiento del gradiente.

La función ReLU, definida como  $f(x) = \max(0, x)$ , que permite que cada neurona active solo si el valor de entrada es positivo, lo cual facilita un aprendizaje más rápido y estable.

Para la capa de salida, que en nuestro caso es una tarea de regresión, no se aplica ninguna función de activación específica. Esto permite que el modelo genere una salida continua, que en nuestro caso representa la cargabilidad del transformador en porcentaje.

### **2.5.6 Optimización del modelo**

Para mejorar la eficiencia y precisión del proceso de aprendizaje de la red neuronal, se utilizó el algoritmo de optimización Adam, que se caracteriza por adaptar de manera dinámica la tasa de aprendizaje para cada parámetro del modelo. Esto permite un proceso de optimización más eficiente y estable en comparación con métodos más simples. Adam es computacionalmente eficiente y adecuado para trabajar con grandes cantidades de datos o parámetros. En este caso, se emplearon los valores predeterminados del algoritmo, lo que garantizó una convergencia rápida y estable durante el entrenamiento del modelo sin necesidad de ajuste adicional de los hiperparámetros.

### **2.5.7 Entrenamiento del modelo**

El entrenamiento de un modelo de red neuronal implica varias etapas, iniciando con la separación de los datos y seguido por un proceso iterativo de ajuste de parámetros. Para garantizar una evaluación equitativa y evitar problemas de sobreajuste (Overfitting), se utilizó el método hold-out para dividir el conjunto de datos completo en subconjuntos con funciones específicas:

- **Conjunto de entrenamiento (training dataset):** Contiene el 80% de los datos originales y se utiliza para ajustar los parámetros del modelo. Dentro de este conjunto, se realizó una subdivisión adicional, reservando un 20% de los datos para la validación.
- **Conjunto de validación (validation dataset):** Este subconjunto representa el 20% del conjunto de entrenamiento y se emplea durante el proceso de ajuste para evaluar el rendimiento del modelo y detectar posibles problemas de subajuste (Underfitting) o sobreajuste (Overfitting).
- **Conjunto de pruebas (test dataset):** Compuesto por el 20% restante de los datos originales, este subconjunto se reserva exclusivamente para la evaluación final del rendimiento del modelo.

En términos prácticos, de los 600 transformadores disponibles en el conjunto de datos, se destinaron 480 ejemplos para el proceso de entrenamiento y validación (384 para entrenamiento y 96 para validación), mientras que los 120 ejemplos restantes se utilizaron para pruebas, como se observa en la Figura 0.3.




Figura 0.3. División de los datos del modelo

El proceso de entrenamiento de la red neuronal es iterativo. En cada epoch o iteración, se actualizan los pesos de todos los nodos según la función de pérdida, que cuantifica la diferencia entre el resultado calculado y el esperado. Para este proceso, se empleó el error cuadrático medio MSE, que calcula el promedio de todos los errores al cuadrado.

El número de iteraciones puede ser fijo o adaptativo, continuando hasta que el modelo determine que ya no hay mejoras significativas en el rendimiento dentro de un rango histórico de iteraciones. Durante el entrenamiento, se evalúa

continuamente el rendimiento del modelo utilizando el conjunto de validación, lo cual es decisivo para identificar y corregir problemas de ajuste antes de proceder con la evaluación final utilizando el conjunto de pruebas.

### **2.5.8 Evaluación y validación del modelo**

Para evaluar cuantitativamente el desempeño del modelo, se calcularon dos métricas principales: el Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE). El MAE proporciona una medida del error promedio absoluto entre las predicciones del modelo y los valores reales de cargabilidad, mientras que el MSE cuantifica el error cuadrático promedio. Estas métricas son útiles para entender la precisión del modelo y comparar su rendimiento.

### **2.5.9 Método REA**

El Método REA es utilizado para la estimación de la cargabilidad de transformadores en redes rurales. El proceso de cálculo en esta metodología implica la estratificación de los usuarios por rangos de consumo y tipos de tarifa, y posteriormente la aplicación de las ecuaciones (7) y (8) que permiten calcular la demanda total y la cargabilidad de cada transformador. En esta investigación, el Método REA será utilizado como punto de referencia para validar el modelo de RNA.

### **2.5.10 Comparaciones con metodologías tradicionales**

**Comparación con el Método REA:** Se llevará a cabo una comparación entre los porcentajes de cargabilidad obtenidos mediante el Método REA y los valores del modelo de RNA para los transformadores rurales. Esta comparación proporcionará una visión clara de cómo las predicciones del modelo se alinean con los valores obtenidos por la metodología tradicional, reflejando los porcentajes de cargabilidad en ambos casos.

**Validación con Mediciones Reales:** Para validar la precisión del modelo en condiciones reales, se compararán las predicciones obtenidas por la RNA con las mediciones reales de cargabilidad realizadas con equipos analizadores instalados en los transformadores rurales. Esta comparación proporcionará una evaluación

final de la efectividad del modelo bajo condiciones reales, permitiendo validar la precisión del modelo en condiciones reales.

## CAPÍTULO III

### APLICACIÓN Y/O VALIDACION DE LA PROPUESTA

El presente estudio se implementa en el alimentador Chimbo de la parroquia Chimbo, perteneciente a la CNEL EP Unidad de Negocio Bolívar, con la finalidad de analizar la cargabilidad de los transformadores de distribución en las zonas rurales, dicho alimentador se encuentra en la provincia Bolívar, el área geográfica de este alimentador de tipo rural tiene una longitud de 221,74 Km de red, siendo este uno de los más extensos, con un total de 600 transformadores.

En la Figura 0.1 se observa un esquema geográfico del alimentador, que muestra la red de medio voltaje del alimentador. Esta figura proporciona una visión clara de cómo se distribuye la red y ayuda a tener una mejor idea de su estructura y extensión.



Figura 0.1. Esquema geográfico del alimentador Chimbo

### 3.1 Resultados de la base de datos

La diversidad del consumo de energía eléctrica en los usuarios del alimentador se aprecia en la siguiente gráfica de frecuencias, donde se observa una curva que relaciona el número de consumidores y sus consumos energéticos. Esta curva presenta un sesgo a la derecha [32], lo que indica que la distribución de los consumos está concentrada en los rangos bajos como se observa en la Figura 0.2, entre 60 y 90 kWh/mes, con frecuencias que se aproximan a los 3000 casos en estos rangos. Este sesgo a la derecha significa que la mayoría de los consumidores tienen consumos relativamente bajos, pero hay una extensión hacia la derecha con algunos consumidores que tienen consumos significativamente mayores. En otras palabras, mientras que la mayor parte de los datos se agrupan en el extremo izquierdo del gráfico, hay una parte que se alarga hacia el lado derecho, mostrando que hay menos consumidores en los rangos de consumo más altos. Este tipo de distribución es importante para entender cómo se distribuye el consumo de energía y puede influir en la planificación y gestión de la infraestructura eléctrica.

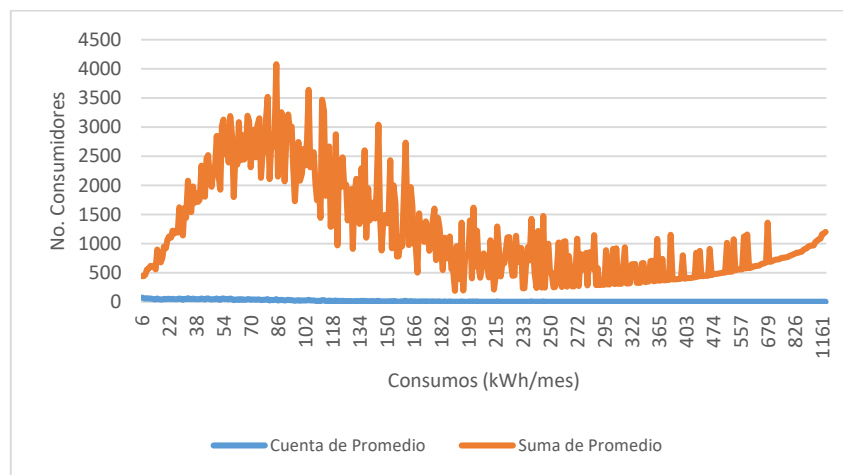


Figura 0.2. Gráfico de frecuencias

#### Por usuarios

La diversidad de consumos se presenta en todas las categorías tarifarias, por lo que resulta fundamental distinguirlas según el tipo de consumidor y su respectiva tarifa. En este estudio, se ha llevado a cabo por primera vez una estratificación de los consumidores del alimentador. En este sentido, se han identificado ocho estratos de consumo, clasificados en las siguientes categorías: Residencial (R), Comercial (C),

Industrial Artesanal (IA) y Otros. La distribución de los consumidores en estos estratos se muestra en la Tabla 0.1.

En términos generales, la mayoría de los usuarios del alimentador se encuentran clasificados bajo la tarifa residencial, con un total de 6,042, representando el 92,4% del total de usuarios; mientras que 278 usuarios están categorizados bajo la tarifa comercial, equivalente al 4,3%. Además, se identifican 13 usuarios industriales y, entre otros, 203 de las demás tarifas, que representan el 3,1% del total, como se observa en la Figura 0.3.




Figura 0.3. Porcentaje de usuarios

Según la distribución de usuarios en los diferentes estratos de consumo, como se observa en la Figura 0.4 se destacan dos estratos que concentran la mayor cantidad de usuarios: el estrato E con 1,772 usuarios, con un consumo mensual entre 50 y 110 kWh, y el estrato D con 1,991 usuarios, cuyo consumo mensual se encuentra en el rango de 12 a 50 kWh.

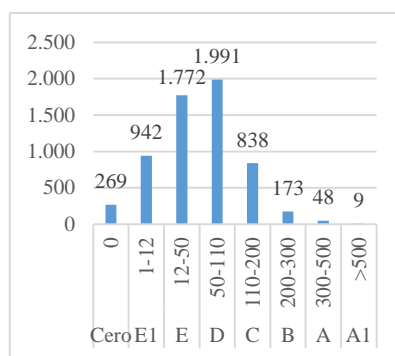


Figura 0.4. Consumos de usuarios Residenciales

### Por consumos de energía

Revisando los datos y analizando los resultados obtenidos, se observa en la Figura 0.5 que la carga del alimentador está mayormente determinada por el

comportamiento de los consumidores residenciales, quienes representan el 67,36% del consumo total mensual. Dentro de este grupo, los estratos de mayor consumo son el D (50-110 kWh-mes) con 152.873 kWh-mes y el C (110-200 kWh-mes) con 121.414, como se observa en la Figura 0.6.




Figura 0.5. Porcentaje de usuarios por consumo de energía

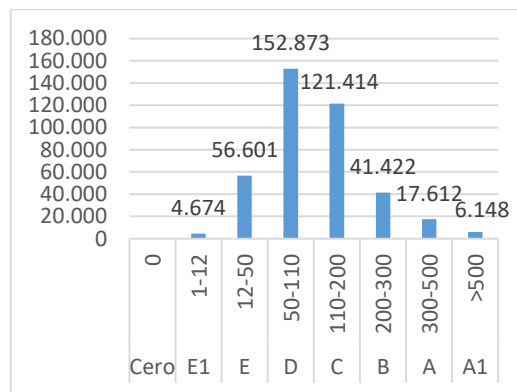


Figura 0.6. Consumo residencial (kWh-mes)

### Por consumos específicos

Al relacionar el consumo mensual de energía con el número de usuarios, se determina el consumo específico o consumo por cliente, siendo este un parámetro adicional que también caracteriza a cada estrato de consumo. Es decir que, se manifiesta el gran predominio del usuario residencial. La mayoría de los estratos tienen valores coincidentes, a excepción del estrato A1 (>500 kWh-mes), como se aprecia en la Tabla 0.1.

Tabla 0.1 Consumos específicos por tarifa

Estrato	Rango	R	C	IA	Otros
Cero	0				
E1	1-12	5	5	7	4
E	12-50	32	27	19	29

<b>D</b>	50-110	77	79	73	63
<b>C</b>	110-200	145	156	122	137
<b>B</b>	200-300	239	251	173	225
<b>A</b>	300-500	367	374	269	351
<b>A1</b>	>500	683	1.383	0	2.202

El manejo estratificado de los consumos específicos tiene por objeto disponer de un parámetro de cálculo diferenciado que permita mejorar la determinación de la demanda y el dimensionamiento óptimo de los transformadores de distribución. Considerando los resultados del análisis realizado sobre el alimentador Guaranda-Chimbo, se observa que la presencia de los usuarios residenciales es predominante, tanto en número como en consumo de energía.

Además, se observa que el consumo específico de los usuarios comerciales e industrial artesanal es similar al de los residenciales en casi todos los estratos, exceptuando el estrato de consumos superiores a 500 kWh. Esto indica que, básicamente, todas estas categorías se ajustan a la característica de carga residencial, a pesar de sus actividades comerciales o industriales artesanales.

## **3.2 Red neuronal**

### **3.2.1 Resultados de la normalización de datos**

Es importante analizar las estadísticas descriptivas de las variables involucradas. Estas estadísticas proporcionan información sobre la distribución de los datos y ayudan a identificar posibles sesgos, dispersión o valores extremos que podrían influir en el rendimiento del modelo. Las estadísticas descriptivas incluyen medidas de tendencia central (como la media y la mediana), de dispersión (como la desviación estándar), y percentiles, que ofrecen una visión más detallada sobre la distribución de los valores [32].

En la Tabla 0.2, se presentan las estadísticas descriptivas de las variables antes de la normalización. El número 600 que aparece en la columna "Cant." (cantidad) indica el total de datos que fueron recopiladas para cada una de las variables. Esto significa que el conjunto de datos contiene información de 600 transformadores en cuanto a su capacidad, consumo total, número de usuarios conectados, y la potencia total de alumbrado público. Este tamaño de muestra es significativo porque permite

analizar una cantidad variada de transformadores, lo que ayuda a mejorar la representatividad y la robustez del modelo de predicción que se está desarrollando.

Tabla 0.2. Estadísticas descriptivas del conjunto de datos.

	<b>Cant.</b>	<b>mean</b>	<b>std</b>	<b>min</b>	<b>25%</b>	<b>50%</b>	<b>75%</b>	<b>max</b>
<b>Capacidad (kVA)</b>	600	20,10	20,46	3	10	15	25	150
<b>Total_consumo (kWh)</b>	600	968,11	1.819,04	0	109,50	342,50	977	21.662
<b>Total_usuarios</b>	600	10,87	14,51	1	1	6	14	156
<b>Potencia_AP (kW)</b>	600	0,79	1,11	0	0	0,35	1,20	7,15

La capacidad media de los transformadores en el conjunto de datos es de 20,10 kVA, con una desviación estándar de 20,46 kVA, es decir, refleja una distribución bastante dispersa. El valor mínimo registrado es de 3 kVA, mientras que el máximo alcanza los 150 kVA. Al analizar el percentil 25, la mediana (percentil 50) y el percentil 75, se observa que la mayoría de los transformadores tienen capacidades relativamente bajas, concentradas en valores entre 10 y 25 kVA.

En cuanto al consumo total, la media es de 968,11 kWh, pero la desviación estándar de 1819,04 kWh indica que hay una gran dispersión en los valores. El valor mínimo de consumo es 0 kWh, mientras que el máximo llega a 21662 kWh, reflejando la presencia de valores extremos. Los percentiles muestran que el 75% de los transformadores tienen un consumo de hasta 977 kWh, con una mediana de 342,5 kWh.

El número de usuarios conectados a cada transformador tiene una media de 10,87 usuarios, con una desviación estándar de 14,48. El valor mínimo es de 1 usuario, mientras que el máximo registrado es de 156 usuarios. Al analizar la distribución, se observa que la mayoría de los transformadores tienen entre 1 y 14 usuarios conectados, con una mediana de 6 usuarios.

La potencia de alumbrado público, presenta una media de 0,79 kW y una desviación estándar de 1,11 kW. Los valores oscilan entre un mínimo de 0 kW y un máximo de 7.15 kW. El análisis de los percentiles revela que la mayoría de los transformadores tienen una potencia baja, con una mediana de 0,35 kW y un percentil 75 de 1,18 kW.

El uso de percentiles es importante en este análisis porque permite identificar cómo están distribuidos los valores dentro del conjunto de datos y si existen concentraciones en ciertos rangos. Esto facilita la detección de valores extremos o patrones que podrían influir en el comportamiento de los modelos predictivos. El percentil 25% indica que el 25% de los datos tienen un valor menor o igual al valor mostrado, mientras que el percentil 75% refleja que el 75% de los datos tienen un valor menor o igual al correspondiente. Estos cuartiles son útiles para visualizar la dispersión y concentración de los datos sin depender únicamente de la media, que podría verse distorsionada por valores extremos.

Se llevó a cabo la normalización de las variables independientes del conjunto de datos utilizando el método Z-score. Este método consiste en transformar los valores de las variables de modo que su media se desplace a 0 y su desviación estándar se ajuste a 1. De esta forma, se logró homogeneizar la escala de las variables, lo que facilita el proceso de entrenamiento del modelo de red neuronal al evitar que variables con valores numéricamente grandes dominen el proceso de aprendizaje.

En la Tabla 0.3 se presentan la normalización en los 480 datos de entrenamiento, estos datos se utilizan para ajustar el modelo y deben ser normalizados para evitar sesgos [32] debido a la magnitud de las variables.

Tabla 0.3. Normalización en los datos de entrenamiento

	<b>Cant.</b>	<b>mean</b>	<b>std</b>	<b>min</b>	<b>25%</b>	<b>50%</b>	<b>75%</b>	<b>max</b>
<b>Capacidad</b>	480	-3,15	1	-0,82	-0,72	-0,20	0,22	6,18
<b>Total consumo</b>	480	0,00	1	-0,53	-0,41	0,34	0	11,43
<b>Total usuarios</b>	480	-4,44	1	-0,66	-0,66	-0,31	0,23	10,11
<b>Potencia_AP</b>	480	-2,20	1	-0,7	-0,7	-0,39	0,33	5,67

El proceso de normalización no solo ayuda a evitar sesgos, sino que también mejora la capacidad del modelo para aprender de manera equilibrada y eficiente. Las variables con magnitudes muy diferentes pueden interferir en la optimización del modelo, ya que los algoritmos de aprendizaje tienden a priorizar las características con valores más grandes. Al normalizar los datos, cada variable contribuye de manera equitativa al proceso de aprendizaje.

Por otro lado, los datos de prueba se normalizan usando la misma escala que los de entrenamiento, para asegurar que los valores con los que se evalúa el modelo sean

comparables a los usados durante el entrenamiento. Esto garantiza la coherencia en la evaluación y evita posibles errores derivados de diferencias en la magnitud de las variables. En la Tabla 0.4, se muestra la normalización en los 120 datos de prueba:

Tabla 0.4. Normalización en los datos de prueba

	<b>Cant.</b>	<b>mean</b>	<b>std</b>	<b>min</b>	<b>25%</b>	<b>50%</b>	<b>75%</b>	<b>max</b>
<b>Capacidad</b>	120	-0,03	0,87	-0,82	-0,48	-0,48	0,22	4,99
<b>Total_consumo</b>	120	0,01	1,03	-0,53	-0,46	-0,33	0,01	6,75
<b>Total_usuarios</b>	120	0,09	1,04	-0,66	-0,52	-0,17	0,32	6,28
<b>Potencia_AP</b>	120	0,00	0,97	-0,70	-0,70	-0,43	0,36	5,00

El uso de la misma escala para la normalización de los datos de prueba es fundamental, ya que de lo contrario el modelo podría generar predicciones incorrectas debido a las diferencias entre los datos de entrenamiento y los de prueba. Esto permite que la evaluación del rendimiento del modelo sea real y basada en datos nuevos que no han sido utilizados durante el entrenamiento.

### 3.2.2 Resultados del entrenamiento de la red neuronal

El entrenamiento de una red neuronal depende de la inicialización de los parámetros y del algoritmo de optimización que se utiliza para minimizar la función de pérdida. En este caso, se utilizó el algoritmo de optimización Adam (Adaptive Moment Estimation), que es ampliamente usado por su capacidad para ajustar dinámicamente el tamaño de los pasos de aprendizaje en función de las derivadas de primer y segundo orden. Aunque los resultados pueden variar ligeramente en cada ejecución debido a la aleatoriedad en la inicialización, la red neuronal tiende a converger a un estado óptimo, en el que los errores de predicción son mínimos.

El modelo fue entrenado durante 140 iteraciones, y los resultados del proceso de entrenamiento se presentan en la Figura 0.7 y en la Tabla 0.5. En esta última, se observa cómo los valores de MAE y MSE disminuyen progresivamente a medida que el modelo aprende de los datos:

Después de 140 iteraciones el modelo logró valores finales de MAE de 1,06 y un MSE de 2,38 para el conjunto de entrenamiento, y un MAE de 2,30 y un MSE de 37,12 para el conjunto de validación. Estos resultados muestran que el error del modelo disminuyó considerablemente durante el proceso de entrenamiento, tanto

para el conjunto de entrenamiento como para el conjunto de validación. Además, la diferencia relativamente pequeña entre el error en ambos conjuntos indica que no hay señales de sobreajuste (Overfitting), un problema común en modelos de aprendizaje automático que ocurre cuando el modelo se ajusta demasiado a los datos de entrenamiento y no generaliza bien en datos nuevos.




Figura 0.7. Resultados del proceso de entrenamiento de la red neuronal. a) MAE y b) MSE.

El proceso de entrenamiento también mostró una convergencia adecuada, lo que significa que los errores (MAE y MSE) se estabilizaron en valores bajos después de varias iteraciones. Esto indica que el modelo ha alcanzado un punto de ajuste óptimo, donde las modificaciones en los parámetros ya no mejoran significativamente el desempeño del modelo.

Tabla 0.5. Resumen de resultados de error en el proceso de entrenamiento de la red neuronal.

Epoch	MAE_Train	MSE_Train	MAE_Val	MSE_Val
<b>0</b>	32,61	1865,13	33	1965,34
<b>1</b>	30,11	1719,86	28,96	1593,42
<b>2</b>	25,75	1310,07	21,73	995
<b>3</b>	20,75	895,70	20,91	1060,69
<b>4</b>	18,82	725,97	18,87	749,57
<b>136</b>	0,89	1,79	2,74	47,55

<b>137</b>	1,055	2,21	2,44	38,96
<b>138</b>	1,05	2,39	2,32	37,17
<b>139</b>	1,06	2,48	2,42	44,12
<b>140</b>	1,06	2,38	2,30	37,12

Finalmente, luego de todo el proceso de entrenamiento, se guardó la topología de la red neuronal entrenada, los pesos de la misma y las medias y desviaciones estándar del conjunto de entrenamiento. Esto permite reutilizar el modelo en el futuro para hacer predicciones sin necesidad de volver a entrenar la red desde cero.

### **Evaluación en el conjunto de prueba**

El siguiente paso fue evaluar el desempeño del modelo sobre el conjunto de prueba. Para ello, se utilizó la misma normalización aplicada en los datos de entrenamiento. Los resultados obtenidos mostraron un MAE de 1,83 y un MSE de 31,97, lo que indica que el modelo tiene una buena capacidad para generalizar los datos nuevos, no vistos durante el entrenamiento.

El gráfico de dispersión [32] presentado en la Figura 0.8, se compara los valores reales de cargabilidad con los valores pronosticados por el modelo. La línea negra diagonal en el gráfico representa la línea ideal, en la que las predicciones serían exactamente iguales a los valores reales, es decir, el error sería cero. Se observa una alta concentración de puntos cercanos a esta diagonal, lo que confirma que las predicciones del modelo son precisas y están bien alineadas con los valores reales, especialmente en los rangos de cargabilidad más bajos (entre 0 y 50).

Sin embargo, en valores más altos (mayores a 50), algunos puntos comienzan a alejarse de la línea ideal, lo que indica que el error aumenta conforme la cargabilidad se incrementa. Esto se observa con mayor claridad en los casos donde la cargabilidad excede los 100.

Además, Se identifican algunos valores atípicos en la parte superior derecha del gráfico, donde las predicciones del modelo están significativamente alejadas de los valores reales. Estos puntos extremos pueden estar afectando de manera notable

tanto el MAE como el MSE, indicando que el modelo tiene mayores dificultades para predecir correctamente los valores extremos de cargabilidad.

El MAE de 1,83 indica que, en promedio, el modelo comete pequeños errores en las predicciones, los valores atípicos contribuyen al incremento tanto el MAE como el MSE, lo que indica que es importante analizar estos puntos de forma más detallada.

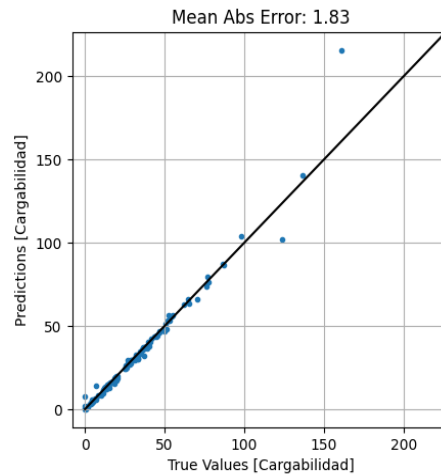


Figura 0.8. Gráfico de dispersión entre valores reales y predicciones.

- La mayoría de los puntos en el gráfico se agrupan cerca de la línea diagonal, lo que confirma la alta precisión del modelo para la mayoría de los casos.
- En rangos más altos de cargabilidad, se observa un aumento en el error de predicción, reflejado en la separación de los puntos respecto a la línea ideal.
- Algunos valores atípicos en el gráfico sugieren dificultades en la predicción de cargabilidad en transformadores con demanda más alta.

En resumen, estos resultados demuestran que la red neuronal ha sido entrenada correctamente y que tiene un buen rendimiento tanto en los datos de entrenamiento como en los datos de prueba, lo que indica su capacidad para generalizar y predecir con precisión en diferentes escenarios, aunque con la necesidad de mejorar en la predicción de casos extremos.

### 3.2.3 Resultados generados por la red neuronal

Adicionalmente, se establecieron rangos para interpretar los resultados de cargabilidad. Cuando los valores son inferiores al 50%, se considera que el

transformador está subutilizado. Este rango indica que hay capacidad sobrante en el transformador, por lo cual se puede optimizar la distribución de la carga o reubicar los transformadores. Los valores entre el 50% y el 100% indican que el transformador opera dentro de un rango óptimo. En este intervalo se garantiza una utilización eficiente del transformador. Finalmente, los valores superiores al 100% indican que el transformador está sobrecargado, lo que requiere atención urgente, ya que puede llevar a un deterioro acelerado del equipo o a fallas. En estos casos, se sugiere realizar una revisión y considerar la instalación de transformadores adicionales o la redistribución de la carga.

El gráfico de la Figura 0.9 muestra el Error Absoluto Medio (MAE) para todo el conjunto de datos.




Figura 0.9. MAE de todo el conjunto de datos

Este gráfico permite evaluar la precisión del modelo para cada transformador, e indica que en la mayoría de las predicciones están dentro de los márgenes de error aceptables. Sin embargo, algunos transformadores presentan un MAE superior a 15, lo que indica un error significativamente mayor en esas predicciones. Estos valores atípicos pueden deberse a varios factores, y es crucial realizar un análisis detallado de las posibles causas.

La Tabla 0.6 lista los transformadores con un MAE superior a 15. De estos, dos están ubicados en zonas urbanas, uno cerca de la zona urbana, y otro en una zona más alejada. Estos transformadores, con valores de cargabilidad que superan en algunos casos el 200%, deben ser revisados en sitio para determinar las razones de las diferencias significativas en las predicciones. Es posible que estos errores se

deban a una desactualización en el SIG. Por ejemplo, en algunos casos, el transformador que aparece en los registros podría haber sido reemplazado por otro de mayor capacidad, y los datos reflejados en el SIG no han sido actualizados.

Tabla 0.6. Transformadores con MAE superior a 15.

<b>N° de Transformador</b>	<b>Capacidad (kVA)</b>	<b>Total consumo (kWh)</b>	<b>Total usuarios</b>	<b>Potencia Total AP (kW)</b>	<b>Cargabilidad (%)</b>	<b>Estado</b>
<b>0307115</b>	25	8271	19	7,15	220,51	Sobrecargado
<b>0303296</b>	10	2345	39	1,80	102,27	Sobrecargado
<b>0303936</b>	10	1247	9	0,55	97,07	Funcionamiento óptimo
<b>0303955</b>	25	8404	10	0	215,69	Sobrecargado

El transformador 0307115, ubicado en una zona urbana, que presenta una cargabilidad del 220,51%, indicando una sobrecarga significativa por lo que se requiere una revisión inmediata, ya que puede estar contribuyendo al alto error en las predicciones. Otro caso notable es el del transformador 0303955, situado en una zona más alejada, con una cargabilidad del 215,69%, que también muestra una sobrecarga significativa. En ambos casos, es necesario investigar si los datos del SIG están desactualizados o si efectivamente las demandas han superado la capacidad de los transformadores instalados.

En cuanto al transformador 0303296, ubicado en una zona urbana, se observa una cargabilidad del 102,27%, lo que también lo clasifica como sobrecargado. Aunque el modelo maneja mejor esta predicción, sigue siendo necesario revisar si este transformador ha sido reemplazado por uno de mayor capacidad o si hay una variabilidad alta en la demanda que el modelo no ha capturado correctamente.

Finalmente, el transformador 0303936, que está cercano de la zona urbana con una cargabilidad del 97,07%, está dentro de un rango óptimo. Sin embargo, el MAE elevado indica que también puede haber fluctuaciones significativas en la demanda en esta zona, que podrían estar afectando la precisión del modelo.

Además de estos análisis, es importante considerar que las demandas variables en las zonas urbanas y cercanas pueden estar contribuyendo al incremento del MAE. Las zonas urbanas suelen experimentar cambios rápidos en la demanda debido a fluctuaciones en el consumo residencial y comercial, lo que podría hacer que las predicciones sean menos precisas. A su vez, es necesario que se realicen

inspecciones de campo para confirmar si los transformadores mencionados han sido cambiados o actualizados, lo que explicaría los errores más altos en las predicciones.

### 3.2.4 Ejecutable GUI

La versatilidad de los notebooks de Google Colab permite crear un entorno de trabajo amigable para el usuario final, facilitando la implementación de una interfaz gráfica de usuario (GUI) básica. Esta GUI permite a cualquier usuario manipular y ejecutar tareas sin necesidad de interactuar directamente con el código. A continuación, se explican en detalle los componentes y resultados generados por la GUI.

La GUI está compuesta por dos campos de entrada. En el primero, el usuario puede definir el nombre del modelo de red neuronal que se va a utilizar. En el ejemplo presentado en la Figura 0.10, el modelo seleccionado es `model_nn`, que corresponde a la red previamente entrenada y guardada. Este campo permite la flexibilidad de elegir entre diferentes modelos de redes neuronales que se pudieran haber generado y guardado durante el proceso de experimentación. El segundo campo solicita el código del transformador a analizar, en este caso, el 0304088. Este código es indispensable, ya que la red neuronal utiliza la información asociada al transformador para calcular su estado de cargabilidad.

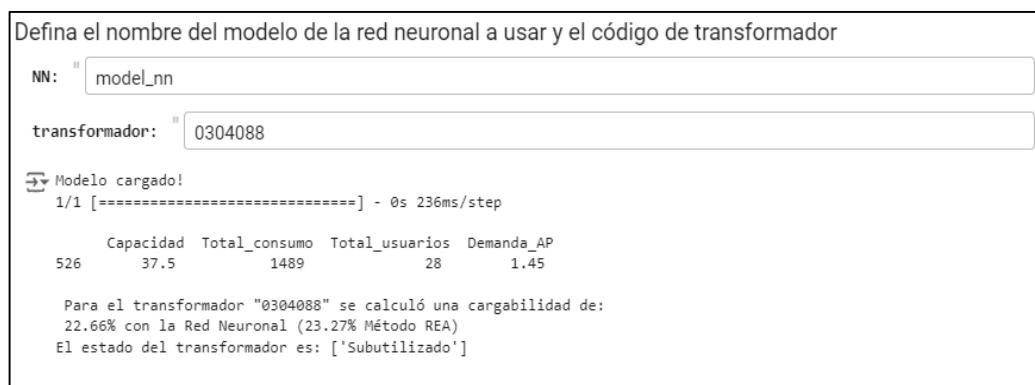


Figura 0.10. GUI para el cálculo de cargabilidad

Una vez que el usuario ingresa los datos solicitados y ejecuta la consulta, la GUI responde en aproximadamente 236 milisegundos, lo que demuestra su alta eficiencia y capacidad de procesamiento en tiempo real. Este tiempo de respuesta

es ideal cuando se requiera evaluar múltiples transformadores rápidamente. La eficiencia de la herramienta permite a los usuarios obtener resultados inmediatos.

Los resultados que arroja la GUI son completos y presentan una visión clara del estado actual del transformador. En primer lugar, se muestra una tabla que detalla la capacidad del transformador (37,5 kVA), el consumo total (1489 kWh), el número de usuarios conectados (28) y la potencia total de alumbrado público (1.45 kW). Con estos datos se evalúa el estado operativo del transformador y su rendimiento en relación con su capacidad nominal. Además, se presenta un cálculo de la cargabilidad estimada por la red neuronal (22.66%) y la cargabilidad obtenida por el Método REA (23.27%). La concordancia entre ambos valores indica que la predicción del modelo es precisa y confiable.

El estado del transformador también es evaluado automáticamente por la GUI. En este caso, el sistema clasifica el transformador como "Subutilizado", ya que su cargabilidad se encuentra por debajo del 50%, lo que indica que está operando por debajo de su capacidad nominal.

Finalmente, la flexibilidad de la GUI permite que, en futuras implementaciones, se puedan realizar actualizaciones al modelo de red neuronal. Esta capacidad de ajuste asegura que la herramienta pueda evolucionar conforme el sistema eléctrico se expanda o cambien las demandas, manteniendo su utilidad a largo plazo.

### **3.3 Resultados del método REA**

Se detallan los resultados obtenidos al aplicar el Método REA para analizar la cargabilidad de los transformadores de distribución rurales en el alimentador Chimbo. Este método estima la demanda máxima y evalúa la capacidad de carga de los transformadores, basándose en el número de abonados y el consumo específico en kWh/mes.

Una vez realizada la estratificación de usuarios por rangos de consumo y tipos de tarifa, se aplican los Factores A y B para cada uno de los transformadores. A partir de la información mostrada en la Tabla 0.2, que incluye información sobre los consumidores y sus consumos específicos, se aplica la ecuación (7) y la ecuación (8) para calcular la demanda máxima, se suma la potencia total de alumbrado

público, se considera un factor de potencia de 0,987 y se obtiene la cargabilidad de cada transformador. Los resultados obtenidos se resumen en la Tabla 0.7.

Tabla 0.7. Resultados del método REA

N° de Transformador	Capacidad KVA	Factor A	Factor B	Demanda (kWh)	Potencia Total AP (kW)	Demanda Total (kW)	Cargabilidad (%)
304141	10	12,52	0,09	1,14	0,00	1,14	12%
304088	37,5	35,90	0,20	7,16	1,45	8,61	23%
301471	15	18,43	0,08	1,44	0,90	2,34	16%
301160	25	41,93	0,23	9,58	1,90	11,48	47%
303609	10	13,82	0,24	3,33	0,00	3,33	34%

Se observa que la mayoría de los transformadores evaluados presentan niveles de cargabilidad relativamente bajos. Por ejemplo, el transformador 304141 tiene una cargabilidad del 12%, lo que indica que está subutilizado, ya que está operando muy por debajo de su capacidad nominal. El transformador 301160, presenta una cargabilidad del 47%, lo que lo ubica cerca del rango óptimo (50%).

### 3.4 Comparación de Resultados: Modelo de Red Neuronal, Método REA y Mediciones del Analizador

Se realiza una comparación entre los resultados obtenidos a partir del modelo de red neuronal, el Método REA y las mediciones del analizador de cargabilidad para evaluar la precisión de la cargabilidad de los transformadores de distribución de las zonas rurales en el alimentador Chimbo. Los datos se han tomado en diferentes años, lo que permite analizar la evolución de la cargabilidad a lo largo del tiempo y las posibles variaciones en la demanda de cada transformador.

La Tabla 0.8 muestra las estimaciones de cargabilidad para cinco transformadores en distintos años.

Tabla 0.8. Comparación de la Cargabilidad de Transformadores: Método REA, Mediciones del Analizador y Modelo de Red Neuronal

Año de medición (analizador)	N° Transformador	Capacidad (kVA)	Método REA (%)	Mediciones analizador (%)	RNA (%)
2022	304141	10	11,59%	12,44%	11,29%
2022	304088	37,5	23,27%	22,86%	22,66%
2023	301471	15	15,81%	11,78%	14,96%
2024	301160	25	46,53%	48,59%	46,13%

2024	303609	10	33,74%	30,49%	31,42%
------	--------	----	--------	--------	--------

A continuación, se analiza en detalle cada transformador:

- Transformador 304141 (10 kVA, 2022): Los tres métodos (REA, RNA y mediciones) coinciden con una cargabilidad del 12% (REA y mediciones) y 11% (RNA), indica que, para este transformador, tanto el método tradicional como el modelo de red neuronal y las mediciones reflejan con precisión que este transformador está sobredimensionado para la demanda actual.
- Transformador 304088 (37,5 kVA, 2022): Se observa una completa coincidencia en la cargabilidad estimada por todos los métodos, que es del 23%, lo que indica que la evaluación del transformador es precisa, esto indica que no son necesarios ajustes en la metodología.
- Transformador 301471 (15 kVA, 2023): Aquí se observan ligeras diferencias: el método REA estima una cargabilidad del 16%, mientras que las mediciones del analizador reportan un 12% y el modelo de red neuronal 15%. La pequeña variación entre los métodos puede deberse a factores como variaciones temporales en la demanda que el modelo de red neuronal pudo captar mejor.
- Transformador 301160 (25 kVA, 2024): En este caso, las mediciones del analizador muestran una cargabilidad ligeramente superior (49%), en comparación con el 47% del método REA y el 46% de la RNA. Aunque las diferencias son mínimas, la medición más alta podría indicar un aumento reciente en la demanda que los métodos teóricos aún no reflejan completamente.
- Transformador 303609 (10 kVA, 2024): En este caso, el método REA estima un 34% de cargabilidad, mientras que las mediciones y la RNA reportan 30% y 31%, respectivamente. La diferencia indica que el método REA podría estar sobreestimando la demanda en este caso particular, mientras que el modelo de RNA, al igual que las mediciones, brindan una estimación más precisa.

## Conclusiones

- La arquitectura de la red neuronal empleada, basada en un modelo multicapa con una función de activación no lineal (ReLU), y optimizada con algoritmos de descenso de gradiente, fue efectiva para modelar la complejidad de las relaciones entre las variables. El uso de varias capas ayudó al modelo a identificar patrones difíciles de captar, mientras que la función ReLU permitió que el entrenamiento fuera más rápido. Además, el algoritmo de optimización Adam hizo que el proceso de ajuste del modelo fuera más estable y eficiente, logrando buenos resultados con pocas repeticiones.
- La normalización de los datos utilizando el método Z-score ha mostrado una mejora significativa en la precisión del modelo de red neuronal. Los datos de entrenamiento normalizados tienen un MAE de 1,06 y un MSE de 2,38, mientras que los datos de prueba normalizados muestran un MAE de 1,83 y un MSE de 31,97. Estos resultados muestran la efectividad de la normalización en la reducción de errores durante el entrenamiento.
- La red neuronal artificial (RNA) demostró la capacidad para predecir la cargabilidad de los transformadores con alta precisión, acercándose en la mayoría de los casos a los resultados obtenidos por el método REA y las mediciones del analizador. Las ligeras diferencias observadas en algunos casos, como en el transformador 301471, donde la RNA identificó mejor las variaciones temporales en la demanda, indican que este tipo de modelos pueden ser una herramienta más robusta frente a variaciones en los comportamientos de consumo a largo plazo.
- La implementación de la red neuronal artificial ha mostrado una mejora significativa en la estimación de la cargabilidad de los transformadores de las zonas rurales, con resultados que se alinean más estrechamente con las mediciones directas en comparación con el Método REA. El error promedio del modelo de Red Neuronal en comparación con las mediciones reales es de 1.6%, mientras que el Método REA presenta un error promedio de 2%, lo que demuestra que el modelo basado en RNA es más preciso en la estimación de la cargabilidad

## Recomendaciones

- Evaluar la eficacia de otras funciones de activación, como tanh o leaky ReLU, así como de algoritmos de optimización avanzados como RMSProp o AdaGrad, para implementar configuraciones aún más óptimas.
- En investigaciones futuras se puede considerar aplicar técnicas de normalización como la Min-Max, para determinar cuál proporciona un mejor rendimiento, además, sería útil complementar las métricas actuales, como MAE y MSE, con RMSE, MAPE y  $R^2$ . Estas métricas adicionales proporcionarán una evaluación más completa del modelo, ayudando a mejorar la precisión y robustez de las estimaciones y así evitar problemas de sobreajuste.
- Ajustar el modelo para que pueda manejar la mayor complejidad de los datos de usuarios urbanos, posiblemente mediante la incorporación de características adicionales como datos temporales y geoespaciales, así como información demográfica y ambiental, el uso de técnicas de preprocesamiento más sofisticadas o modelos avanzados que puedan capturar patrones más complejos en los datos.

## Referencias bibliográficas

- [1] ARCERNNR, “REGULACIÓN Nro. ARCERNNR 002/20 (Codificada),” vol. 20, p. 35, 2023, [Online]. Available: [www.controlrecursosyenergia.gob.ec](http://www.controlrecursosyenergia.gob.ec)
- [2] L. I. Alvarez, C. A. Lozano, and D. A. Bravo, “Metodología para el mantenimiento predictivo de transformadores de distribución basada en aprendizaje automático,” pp. 1–16, 2022.
- [3] X. B. Olabe, *REDES NEURONALES ARTIFICIALES Y SUS APLICACIONES*. Bilbao, 1998.
- [4] L. A. Gallego, A. Francisquini, and O. G. Carmona, “Estimación de curvas de demanda de consumidores, transformadores de distribución y alimentadores primarios en sistemas de distribución,” no. 35, pp. 107–112, 2007.
- [5] X. González-ramírez, Á. M. Perea-meneses, G. N. Caicedo, and F. Castro, “Estimación de curvas de carga en transformadores eléctricos mediante redes neuronales,” vol. 86, no. 2, pp. 75–86, 2008.
- [6] D. Orbe Jativa, G. Salazar Yopez, and P. Vasquez Miranda, “Estimación de curvas diarias de demanda eléctrica en transformadores de distribución mediante redes neuronales artificiales,” *2022 IEEE Bienn. Congr. Argentina, ARGENCON 2022*, 2022, doi: 10.1109/ARGENCON55245.2022.9939965.
- [7] J. Ramesh, S. Shahriar, A. R. Al-Ali, A. Osman, and M. F. Shaaban, “Machine Learning Approach for Smart Distribution Transformers Load Monitoring and Management System,” *Energies*, vol. 15, no. 21, pp. 1–19, 2022, doi: 10.3390/en15217981.
- [8] J. A. Y. Morón, *Sistemas eléctricos de distribución*, Reverté. Mexico, 2009.
- [9] T. A. Short, *Electric Power Distribution Handbook, Second Edition*, no. C. 2014. doi: 10.1201/b16747.
- [10] T. Gonen, *Electric Power Distribution Engineering - Third Edition*, vol.

1999, no. December. 2006.

- [11] G. I. M. Isasi Pedro, *Redes de neuronas artificiales*. Madrid: PEARSON Prentice Hall, 2004.
- [12] A. Saxena, “An Introduction to Convolutional Neural Networks,” *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 10, no. 12, pp. 943–947, 2022, doi: 10.22214/ijraset.2022.47789.
- [13] M. Damián, “Redes Neuronales: Conceptos Básicos y Aplicaciones.,” *Historia Santiago.*, p. 55, 2001, [Online]. Available: <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>
- [14] A. A. Vorobioff Juan, Cerrota Santiago, Morel Nicolas, *Inteligencia Artificial y Redes Neuronales: Fundamentos, ejercicios y aplicaciones con Phyton y Matlab*, no. April. Buenos Aires, 2022.
- [15] C. Tian, J. Ma, C. Zhang, and P. Zhan, “A deep neural network model for short-term load forecast based on long short-term memory network and convolutional neural network,” *Energies*, vol. 11, no. 12, 2018, doi: 10.3390/en11123493.
- [16] G. Montavon, “Introduction to Neural Networks,” *Lect. Notes Phys.*, vol. 968, no. January 1993, pp. 37–62, 2020, doi: 10.1007/978-3-030-40245-7\_4.
- [17] D. Yi, S. Ji, and S. Bu, “An enhanced optimization scheme based on gradient descent methods for machine learning,” *Symmetry (Basel).*, vol. 11, no. 7, pp. 1–17, 2019, doi: 10.3390/sym11070942.
- [18] C. Gulcehre, M. Moczulski, and Y. Bengio, “ADASECANT: Robust Adaptive Secant Method for Stochastic Gradient,” no. April, 2014, [Online]. Available: <http://arxiv.org/abs/1412.7419>
- [19] J. A. Gerber, “UC Berkeley UC Berkeley Electronic Theses and Dissertations,” *DNA Mediat. Assem. Protein Heterodimers Membr. Surfaces*, p. 67, 2020, [Online]. Available: <https://escholarship.org/uc/item/98384265>

- [20] A. Kumar, “Hold-out Method for Training Machine Learning Models,” *Reimagining Data-driven Society with Data Science & AI*. Vitaflux.com. [Online]. Available: <https://vitalflux.com/hold-out-method-for-training-machine-learning-model/>
- [21] Y. Yao, L. Rosasco, and A. Caponnetto, “On early stopping in gradient descent learning,” *Constr. Approx.*, vol. 26, no. 2, pp. 289–315, 2007, doi: 10.1007/s00365-006-0663-2.
- [22] C. J. Willmott and K. Matsuura, “Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance,” *Clim. Res.*, vol. 30, no. 1, pp. 79–82, 2005, doi: 10.3354/cr030079.
- [23] B. Yildiz, J. I. Bilbao, and A. B. Sproul, “A review and analysis of regression and machine learning models on commercial building electricity load forecasting,” *Renew. Sustain. Energy Rev.*, vol. 73, no. February, pp. 1104–1122, 2017, doi: 10.1016/j.rser.2017.02.023.
- [24] P. Storage, “¿Qué es el preprocesamiento de datos para el aprendizaje automático?” Accessed: Oct. 02, 2024. [Online]. Available: <https://www.purestorage.com/la/knowledge/what-is-data-preprocessing.html>
- [25] M. Aliyari and Y. Z. Ayele, “Application of Artificial Neural Networks for Power Load Prediction in Critical Infrastructure: A Comparative Case Study,” *Appl. Syst. Innov.*, vol. 6, no. 6, 2023, doi: 10.3390/asi6060115.
- [26] S. J. Vest, “Estimating Kw Demand for Future Loads on Rural Distribution Systems,” *Trans. Am. Inst. Electr. Eng. Part III Power Appar. Syst.*, vol. 76, no. 3, pp. 652–655, 1957, doi: 10.1109/AIEEPAS.1957.4499631.
- [27] R. Sampieri and C. Mendoza, *Metodologías de la investigación, las Rutas cuantitativas, cualitativas*, vol. 10, no. 18. 2018.
- [28] A. Sans and L. R. B. Atenea Alonso Serrano, Lorena García Sanz, Irene León Rodrigo, Elisa García Gordo, Belén Gil Álvaro, “Métodos de investigación

- de enfoque experimental,” *Metodol. la Investig. Educ.*, pp. 167–193, 2012, [Online]. Available: <http://www.postgradoune.edu.pe/documentos/Experimental.pdf>
- [29] A. A. Téllez, A. Robayo, G. López, L. Ortiz, I. Isaac, and J. González, “Optimal sizing of distribution transformers using exhaustive search algorithm,” *2019 FISE-IEEE/CIGRE Conf. - Living Energy Transition, FISE/CIGRE 2019*, 2019, doi: 10.1109/FISECIGRE48012.2019.8984965.
- [30] Ecamec, “PQ3 plus Analizador de red.” Buenos Aires, pp. 1–23, 2020.
- [31] A.Lenail, “NN SVG Publication-ready NN-architecture schematics.” Accessed: Sep. 07, 2024. [Online]. Available: <https://alexlenail.me/NN-SVG/>
- [32] M. F. Triola, *Estadística. Décima edición*, vol. 163, no. 50. 2009. [Online]. Available: <http://dx.doi.org/10.1016/j.ijpe.2015.02.016%0Ahttp://revistaeconomia.unam.mx/index.php/ecu/article/view/524>