



# **UNIVERSIDAD TÉCNICA DE COTOPAXI**

## **DIRECCIÓN DE POSGRADO**

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

#### **PROYECTO DE INVESTIGACIÓN**

**“REDES NEURONALES ARTIFICIALES APLICADA AL ESTUDIO DE  
PERFILES DE CARGA ELÉCTRICA EN ALIMENTADORES PRIMARIOS  
DE UNA ARQUITECTURA DE DISTRIBUCIÓN”**

Trabajo de titulación previo a la obtención del título de magister en Electricidad  
mención sistemas eléctricos de potencia

**AUTOR:**

Ing. Katherine Andrea Díaz Reyes

**TUTOR:**

Ing. Carlos Iván Quinatoa Caiza MsC.

**LATACUNGA –ECUADOR**

**2023**

## **AVAL DEL TUTOR**

En mi calidad de Tutor del Trabajo de Titulación **“REDES NEURONALES ARTIFICIALES APLICADA AL ESTUDIO DE LA DISTRIBUCIÓN DE PERFILES DE CARGA ELÉCTRICA EN ALIMENTADORES DE UNA ARQUITECTURA DE DISTRIBUCIÓN.”** presentado por Díaz Reyes Katherine Andrea, 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, marzo, 27, 2023

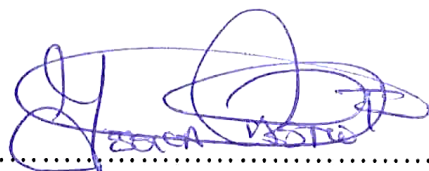


.....  
Ing. Carlos Iván Quinatoa Caiza MsC.  
CC.: 0503287864.

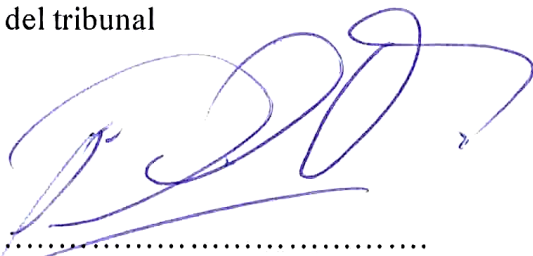
## AVAL DEL TRIBUNAL

El trabajo de Titulación “Redes Neuronales artificiales, aplicada al estudio de la distribución de perfiles de carga eléctrica en alimentadores de una arquitectura de distribución.”, ha sido revisado, aprobado y autorizado su impresión y empastado, previo a la obtención del título de Magíster en Electricidad Mención Sistemas Eléctricos de Potencia; el presente trabajo reúne los requisitos de fondo y forma para que el estudiante pueda presentarse a la exposición y defensa.

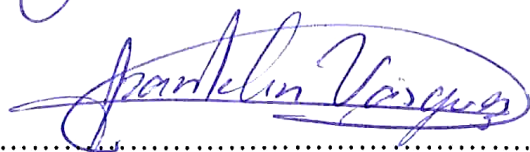
Latacunga, marzo, 27, 2023



.....  
Ing. Jessica Nataly Castillo Fiallos MsC.  
0604590216  
Presidente del tribunal



.....  
Ing. Jefferson Alberto Porras Reyes MsC.  
0704400449  
Lector 2



.....  
Ing. Franklin Hernán Vásquez Teneda MsC.  
1710434497  
Lector 3

## DEDICATORIA

Dedico esta tesis con todo mi amor y gratitud a Dios por su fidelidad, por regalarme satisfacciones que parecían lejanas y recordarme la promesa que me hizo de adolescente cuando me sentía desorientada.

A mi esposo Daniel, por su paciencia y amor incondicional, por ser una persona extraordinaria que me ha ayudado a crecer y madurar, enfocándome en lo que realmente importa, gracias por ser mi amigo y dejarme aprender de ti.

A mis padres, Enrique y Rosa por siempre apoyarme y animarme a seguir mis sueños, por darme de su sabiduría llena de amor y enseñarme a tomar decisiones de la mejor manera.

A mis hermanos, por ser siempre mi soporte incondicional, por reír, llorar y celebrar juntos.

Con mucho amor.

*Katherine.*

## AGRADECIMIENTO

Agradezco de manera profunda a todas las personas que me han ayudado a completar esta tesis y hacer realidad este proyecto.

A mi esposo por darme ese empujoncito para arriesgarme a realizar esta maestría y también para poder finalizarla.

A mis padres y hermanos por estar pendiente de mí con sus consejos y motivación diaria.

A mis profesores, por ser mi guía y por tener la paciencia de impartir sus conocimientos durante este espacio de mi vida.

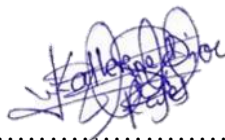
Y a todos los demás que han contribuido de alguna forma a este proyecto, mi más sincero agradecimiento. Gracias por su apoyo y por creer en mí y en mi trabajo.

*Katherine Andrea Díaz Reyes*

## **RESPONSABILIDAD DE AUTORÍA**

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

Latacunga, marzo, 27, 2023

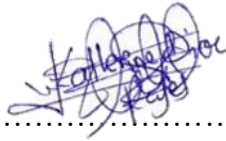
A handwritten signature in blue ink, appearing to read 'Katherine Andrea Díaz Reyes', written over a dotted line.

.....  
Ing. Katherine Andrea Díaz Reyes  
C.I.: 1718355843

## **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, marzo, 27, 2023

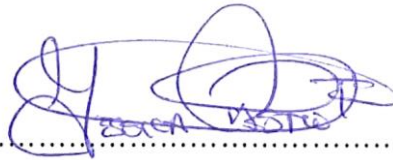
A handwritten signature in blue ink, appearing to read 'Katherine Andrea Díaz Reyes', written over a dotted line.

.....  
Ing. Katherine Andrea Díaz Reyes  
C.I.: 1718355843

## **AVAL DEL PRESIDENTE DEL TRIBUNAL**

Quien suscribe, declara que el presente Trabajo de Titulación: “REDES NEURONALES ARTIFICIALES, APLICADA AL ESTUDIO DE LA DISTRIBUCIÓN DE PERFILES DE CARGA ELÉCTRICA EN ALIMENTADORES DE UNA ARQUITECTURA DE DISTRIBUCIÓN”, contiene las correcciones a las observaciones realizadas por los lectores en sesión científica del tribunal.

Latacunga, marzo, 27, 2023

A handwritten signature in blue ink, appearing to read 'JESSICA CASTILLO', is written over a horizontal dotted line.

Ing. Jessica Nataly Castillo Fiallos MsC.

C.I.: 0604590216

**UNIVERSIDAD TÉCNICA DE COTOPAXI  
DIRECCIÓN DE POSGRADO**

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

**Título:** “Redes neuronales artificiales, aplicada al estudio de la distribución de perfiles de carga eléctrica en alimentadores de una arquitectura de distribución”

**Autor:** Katherine Andrea Díaz Reyes

**Tutor:** Ing. Carlos Iván Quinatoa Caiza MSc.

**RESUMEN**

El pronóstico de la demanda eléctrica es una tarea importante en la gestión de la energía eléctrica, ya que permite prever la cantidad de energía que se requerirá en un futuro cercano. Esto es esencial para planificar la producción y distribución de energía eléctrica, y para asegurar que se cumpla la demanda de energía de los usuarios. En este trabajo se propuso el uso de inteligencia artificial mediante el uso de redes neuronales artificiales para el desarrollo de un modelo de predicción enfocado en el estudio de perfiles de carga en redes de energía eléctrica, usando el software Python. Inicialmente se realizó la investigación de modelos adecuados de RNA para el acercamiento predictivo de los perfiles de carga, posterior a esto se desarrolló la descripción y ajuste de la base de datos de series de tiempo que corresponde a los meses de noviembre y diciembre de 2022, con esto listo se propuso 4 arquitecturas diferentes para el modelo, finalmente se evaluó la eficacia de los modelos desarrollados mediante diferentes tipos de error para determinar su capacidad de predecir correctamente los patrones de demanda en los perfiles de carga eléctrica y por último se seleccionó el mejor modelo, con el cual se generó la predicción de los 7 primeros días del mes de enero de 2023.

**PALABRAS CLAVE:** Redes Neuronales Artificiales, Red De Distribución Eléctrica, Perfil De Carga Eléctrica, Alimentador Primario, Predicción.

**UNIVERSIDAD TECNICA DE COTOPAXI  
DIRECCION DE POSGRADO**

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

**Title:** “Artificial neural networks, applied to the study of the distribution of electric load profiles in feeders of a distribution architecture”

**Autor:** Katherine Andrea Díaz Reyes

**Tutor:** Ing. Carlos Iván Quinatoa Caiza MsC.

**ABSTRACT**

The forecast of electric demand is an important task in the management of electrical energy, as it allows predicting the amount of energy that will be required in the near future. This is essential for planning the production and distribution of electrical energy, and to ensure that the energy demand of users is met. In this work, the use of artificial intelligence was proposed through the use of artificial neural networks for the development of a prediction model focused on the study of load profiles in electrical energy networks, using Python software. Initially, research was conducted on suitable ANN models for the predictive approach of load profiles. After this, the description and adjustment of the time series database corresponding to the months of November and December 2022 were developed. With this ready, 4 different architectures for the model were proposed, and finally, the effectiveness of the developed models was evaluated using different types of errors to determine their ability to correctly predict demand patterns in electrical load profiles. Lastly, the best model was selected, with which the prediction for the first 7 days of January 2023 was generated.

**KEYWORD:** Artificial Neural Networks, Electrical Distribution Network, Electrical Load Profile, Primary Feeder, Prediction

## AVAL DE TRADUCCIÓN

Yo, **Chávez Moreno Matilde Elizabeth** con cédula de identidad número: **1721525424**, magister en pedagogía de los idiomas nacionales y extranjeros mención en enseñanza de inglés, con número de registro de la SENESCYT: 1049-2020-2243225; **CERTIFICO** haber revisado y aprobado la traducción al idioma inglés del resumen del trabajo de investigación con el título: **“REDES NEURONALES ARTIFICIALES, APLICADA AL ESTUDIO DE LA DISTRIBUCIÓN DE PERFILES DE CARGA ELÉCTRICA EN ALIMENTADORES DE UNA ARQUITECTURA DE DISTRIBUCIÓN”** de la Ing. Katherine Andrea Díaz Reyes, aspirante a magister en **ELECTRICIDAD MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA**.

Es todo cuanto puedo certificar en honor a la verdad y autorizo a la peticionaria hacer uso del presente certificado de la manera ética que estimen conveniente.

Latacunga, 29 de marzo del 2023

Atentamente,



.....  
Lic. Chávez Moreno Matilde Elizabeth Mg.  
C.I.: 1721525424

# ÍNDICE DE CONTENIDOS

<b>INTRODUCCIÓN</b> .....	1
Antecedentes .....	1
Planteamiento del problema.....	1
Formulación del problema .....	2
Objetivos .....	3
Objetivo General.....	3
Objetivos Específicos .....	3
Sistemas de tareas en relación a los objetivos específicos.....	4
Justificación: .....	5
Hipótesis.....	6
<b><i>CAPÍTULO I</i></b> .....	7
<b>FUNDAMENTACIÓN TEORICA- METODOLOGICA</b> .....	7
1.1 Antecedentes de la investigación .....	7
1.2 Fundamentación Teórica.....	9
1.2.1 Inteligencia Artificial.....	9
1.2.2 Aprendizaje automático.....	9
1.2.3 Aprendizaje profundo .....	10
1.2.4 Redes neuronales artificiales.....	10
1.2.5 Arquitecturas De Redes Neuronales .....	10
1.2.6 Redes Neuronales Recurrentes.....	11
1.2.7 Redes de memoria de corto plazo .....	12
1.2.8 Series de tiempo .....	12
1.2.9 Perfiles de Carga Eléctrica. ....	13
1.2.10 Alimentador Primario.....	13
1.2.11 Aplicación de Redes Neuronales Artificiales a la Distribución Eléctrica ..	13
1.3 Fundamentación metodológica.....	14
1.4 Conclusiones Capítulo I.....	14
<b><i>CAPÍTULO II</i></b> .....	15
<b>PROPUESTA</b> .....	15
2.1 Título del proyecto. ....	15

2.2	Objetivo del proyecto.....	15
2.3	Descripción de la propuesta.....	15
2.4	Metodología o procedimientos empleados para el cumplimiento de los objetivos planteados.....	16
2.5	Diseño de la propuesta .....	18
2.5.1	Tratamiento de los Datos.....	18
2.5.2	Selección del tipo de Red Neuronal.....	19
2.5.3	Transformación de la base de datos.....	21
2.5.4	Procesamiento de datos .....	22
2.5.5	Diseño de las LSTM .....	24
2.5.6	Entrenamiento de redes neuronales .....	25
2.6	Conclusiones Capítulo II .....	26
	<b><i>CAPITULO III.</i></b> .....	27
	<b><i>APLICACIÓN Y/O VALIDACION DE LA PROPUESTA</i></b> .....	27
3.1	Análisis de los resultados: .....	27
3.2	Validación técnica de los resultados:.....	30
3.3	Evaluación de impactos o resultados .....	32
3.4	Conclusiones del III capitulo .....	33
	<b><i>CONCLUSIONES</i></b> .....	34
	<b><i>RECOMENDACIONES</i></b> .....	36
	<b><i>REFERENCIAS BIBLIOGRÁFICAS</i></b> .....	37
	<b><i>ANEXOS</i></b> .....	41

## ÍNDICE DE FIGURAS

Figura 1.	Estructura de una red Neuronal Monocapa.....	11
Figura 2.	Estructura de una red Neuronal Multicapa. ....	11
Figura 3.	Diagrama de Flujo .....	16
Figura 4.	Base de datos Inicial.....	18
Figura 5.	Base de datos tratada .....	18
Figura 6.	Clasificación de Redes Neuronales Artificiales .....	19
Figura 7.	Base de datos de perfiles de carga.....	21

Figura 8. Conjunto de entrenamiento y prueba.....	22
Figura 9. Muestras observadas.....	23
Figura 10. Tendencia.....	23
Figura 11. Estacionalidad.....	23
Figura 12. Error .....	23
Figura 13. Prueba Dickey-Fuller en la serie de tiempo.....	24
Figura 14. Series de tiempo convertida en ventanas .....	25
Figura 15. Predicción del primer modelo LSTM .....	27
Figura 16. Predicción del segundo modelo LSTM.....	28
Figura 17. Predicción del tercer modelo LSTM .....	28
Figura 18. Predicciones del cuarto modelo LSTM.....	29
Figura 19. Predicciones de modelos LSTM.....	29
Figura 20. Modelos de predicción seleccionados.....	30
Figura 21. Predicción del mes de enero del 2023.....	32

## ÍNDICE DE TABLAS

<b>Tabla 1.</b> Sistemas de tareas en relación con los objetivos específicos:.....	4
<b>Tabla 2.</b> Tabla comparativa de redes neuronales recurrentes .....	20
<b>Tabla 3.</b> Descripción de redes LSTM.....	24
<b>Tabla 4.</b> Análisis de error .....	31
<b>Tabla 5.</b> Análisis de error .....	32

# INTRODUCCIÓN

## **Antecedentes**

El presente trabajo de investigación está enmarcado dentro de la línea específica: Energías alternativas y renovables, eficiencia energética y protección ambiental, con una derivación a la Sub-línea: Explotación y diseño de Sistemas de potencia, correspondiente a los ejes temáticos de Redes de transmisión y distribución, pertinentes al programa de Maestría en Electricidad mención Sistemas Eléctricos de Potencia de la Universidad Técnica de Cotopaxi, en fusión del artículo 21 del Reglamento del Trabajo de Titulación de Posgrados.

En la actualidad eléctrica del Ecuador es necesario realizar avances tecnológicos para lograr la eficiencia energética donde se conoce que el tema de pérdidas en el sistema es bastante preocupante sobre todo en las redes de distribución eléctricas. Por tal razón, se plantea la generación de un estudio mediante redes neuronales artificiales para la predicción de perfiles de carga en alimentadores de una arquitectura de distribución. Esta propuesta se enfoca en brindar un apoyo en la mitigación de pérdidas, mediante un reconocimiento basado en datos históricos almacenados como series de tiempo.

## **Planteamiento del problema**

Los perfiles de carga eléctrica en alimentadores primarios se presentan como curvas en la variación de la carga eléctrica a través del tiempo, estos perfiles dependerán del tipo de cliente y de condiciones ambientales. Los cuales son factores que influyen en las pérdidas dentro de la misma [1].

Por esta razón, es importante estudiar la carga eléctrica, ya que con estos datos se pueden predecir el perfil necesario para alimentar de manera eficiente a una población [2]. Ya que, al no realizar un análisis correcto de la carga necesaria a través del tiempo, da como resultado una cantidad excesiva de potencia suministrada que no puede ser almacenada y, por ende, desperdiciada. Esto se traduce en una pérdida para el sistema y en una falta de eficiencia en los recursos [3].

No obstante, los datos necesarios para el perfil de carga en alimentadores primarios han sido almacenados en una base de datos de series de tiempo que, de momento, no ha sido empleado para ningún propósito. En este sentido, al emplear algoritmos de aprendizaje profundo, como lo son las redes neuronales artificiales (RNA), se puedan extraer patrones de estos perfiles que describan su comportamiento, puedan pronosticar las siguientes muestras para realizar una correcta planificación eléctrica. Sin embargo, a pesar de que estos modelos ofrecen una gran oportunidad al realizar varios cálculos matemáticos que, difícilmente una persona pueda hacerlos al mismo tiempo, requiere de una alta demanda computacional y un conocimiento previo en su manejo y configuración [4]. Además, el conjunto de datos debe ser tratado previamente, ya que su frecuencia de muestreo del sistema eléctrico, los valores numéricos obtenidos y errores en el almacenamiento de los datos puede interferir en la fase de entrenamiento del modelo y puede producir predicciones erróneas.

Por lo tanto, las RNA han sido largamente estudiadas para predecir la demanda de energía donde varios autores han presentado novedosas soluciones. Considerando que la exploración de diferentes modelos de las RNA juega un papel importante para determinar el que se ajusta al respectivo conjunto de datos a analizar [2].

Con lo antes comentado, esta investigación es llevada a cabo para analizar el comportamiento de la carga eléctrica en alimentadores primarios de una arquitectura de distribución en el Ecuador, a fin de encontrar patrones específicos que permitan mejorar la eficiencia del sistema. Si bien hay estudios previos sobre el tema, ésta es una investigación novedosa que encara el problema desde una perspectiva más detallada usando herramientas avanzadas como las redes neuronales artificiales, esto permitirá estimar mejor los patrones de comportamiento de la carga.

### **Formulación del problema**

¿Qué modelo de RNA es el más preciso para predecir los perfiles de carga eléctrica de Ecuador y cuáles son los pasos necesarios para preparar los datos, ajustar los parámetros y entrenar dicho modelo para obtener la mayor exactitud en la predicción?

## **Objetivos**

### **Objetivo General**

Desarrollar un modelo de predicción basado en la implementación de métodos de inteligencia artificial, para mejorar el pronóstico de perfiles de carga eléctrica en redes de distribución de energía eléctrica.

### **Objetivos Específicos**

- Investigar modelos de RNA relacionados a bases de datos de series de tiempo, para realizar predicciones de los perfiles de carga en redes de distribución de energía eléctrica.
- Definir el modelo adecuado que cumpla con los principales aspectos para determinar una correcta asimilación de datos históricos involucrados para este estudio.
- Evaluar la eficacia del modelo desarrollado mediante diferentes tipos de error, para analizar su capacidad de predecir correctamente los patrones de demanda en los perfiles de carga eléctrica.

## Sistemas de tareas en relación a los objetivos específicos

**Tabla 1.** Sistemas de tareas en relación con los objetivos específicos:

OBJETIVOS ESPECÍFICOS	ACTIVIDAD	RESULTADO DE LA ACTIVIDAD	TÉCNICAS E INSTRUMENTOS
<p><b>Objetivo 1.</b> Investigar modelos de RNA relacionados a bases de datos de series de tiempo, para realizar predicciones de los perfiles de carga en redes de distribución de energía eléctrica.</p>	<ul style="list-style-type: none"> <li>* Revisión de modelos de RNA.</li> <li>* Clasificación de su utilidad en función del uso de series de tiempo.</li> </ul>	<ul style="list-style-type: none"> <li>* Se elige el modelo que mejores resultados ha tenido para este tipo de estudios.</li> <li>* Se categoriza los modelos que consideren parámetros iniciales en función del tiempo para facilitar la elección.</li> </ul>	<p>Investigación bibliográfica, como tesis, artículos científicos.</p>
<p><b>Objetivo 2.</b> Definir el modelo adecuado que cumpla con los principales aspectos para determinar una correcta asimilación de datos históricos involucrados para este estudio</p>	<ul style="list-style-type: none"> <li>* Aplicación del modelo elegido para la predicción de los perfiles de carga.</li> <li>* Generación de diferentes tipos de arquitecturas de redes para realizar un estudio de factibilidad del modelo.</li> </ul>	<ul style="list-style-type: none"> <li>* Se describe la base de datos de series de tiempo para ajustarla a las necesidades específicas de los modelos de RNA y poderlos entrenar.</li> <li>* Se obtiene el modelo finalizado que permitirá determinar patrones de perfiles de carga de manera precisa</li> </ul>	<p>Programación en Python. Librerías. Jupyter Lab.</p>
<p><b>Objetivo 3.</b></p>	<ul style="list-style-type: none"> <li>* Valoración de la efectividad del</li> </ul>	<ul style="list-style-type: none"> <li>* Se determina la efectividad del modelo</li> </ul>	<p>Programación en Python.</p>

<p>Evaluar la eficacia del modelo desarrollado mediante diferentes tipos de error, para analizar su capacidad de predecir correctamente los patrones de demanda en los perfiles de carga eléctrica.</p>	<p>modelo de predicción. * Elección del modelo de predicción más certero y darle una aplicación.</p>	<p>en la predicción de patrones de perfiles de carga eléctrica. * Se predicen los primeros días del mes de enero con el modelo seleccionado.</p>	<p>Librerías. Jupyter Lab.</p>
---	--	--	------------------------------------

**Justificación:**

La Inteligencia Artificial es una herramienta cada vez más importante en nuestra realidad, siendo una ayuda para mejorar la eficiencia de diversos sistemas, no siendo los eléctricos una excepción, esta tecnología puede asistir a los operadores de la red a monitorear y optimizar el uso de la energía y reducir el consumo de energía.

El uso de la Inteligencia Artificial en redes eléctricas de distribución en el Ecuador ha sido objeto de estudio en los últimos años, por tal razón, se plantea esta investigación como un punto de partida para un estudio más complejo sobre las pérdidas que sufre la empresa eléctrica dentro del sistema de distribución, una de ellas es el sobre incremento de la oferta, la cual parte del desatino en la predicción energética, ya que anualmente las distribuidoras solicitan el abastecimiento de energía eléctrica en base a una errónea demanda, generada por las pérdidas que existen en la red [5]. Esto podría corregirse con análisis sobre el consumo eléctrico.

Mediante este trabajo se pretende proponer un método de predicción de perfiles de carga de distribución eléctrica en alimentadores de red, permitiendo a los investigadores tener una mejor comprensión de los beneficios y desafíos de la

implementación de la Inteligencia Artificial en redes eléctricas de distribución y así en un futuro poder brindar mayor eficiencia en la planificación anual y mensual de distribución energética, con lo cual se beneficiarían tanto las empresas distribuidoras como los usuarios.

Este trabajo podría ser el primer paso de estudio para resolver en parte la problemática, usando elementos de estudio como datos históricos, a los cuales se les podría agregar fallas eléctricas, provisión errónea para la cantidad de consumo de la red en diferentes épocas del año, clima, estaciones del año, tipos de clientes, entre otros, provenientes de diversos casos pasados que puedan afectar al cambio de flujo de la red, para poder definir y predecir el problema de manera más acercada a la realidad del alimentador, en función del estudio, se procura aminorar costos innecesarios y las pérdidas que puedan ser generadas.

El presente trabajo de titulación propone la aplicación de un modelo de red neuronal artificial, creada en base a los datos del flujo de energía eléctrica que es distribuida en el alimentador de red, para que puedan ser analizados, generando una predicción acertada para la demanda de la red y así poder brindar una opción de análisis que a futuro podría llegar a ser una solución preventiva o predictiva del suceso.

### **Hipótesis**

El análisis del comportamiento de las curvas de perfiles de carga mediante el uso de redes neuronales podría ayudar en la predicción de consumo que permitiría realizar una mejor planificación en la generación y planificación eléctrica.

# **CAPÍTULO I.**

## **FUNDAMENTACIÓN TEORICA- METODOLOGICA**

### **1.1 Antecedentes de la investigación**

Actualmente, las personas se han interesado en anticipar eventos para poder optar por la mejor solución antes del suceso, por lo cual las redes neuronales artificiales llegan a ser una herramienta realmente importante en cualquier campo con predicciones de grandes volúmenes de datos [6].

Las redes neuronales artificiales son mallas interconectadas masivamente, que emulan el funcionamiento de las neuronas cerebrales para tener la capacidad de extraer patrones para luego realizar tareas de clasificación, agrupamiento y predicción [7]. Las Redes Neuronales Artificiales (RNA) replican la estructura de redes neuronales biológicas del cerebro humano para extraer características principales de los datos introducidos, abstraer, generalizar y aprender [8] [9]. En el 2001, la Universidad Tecnológica Nacional de El Rosario estableció una cronología evolutiva para abordar la comprensión y el desarrollo de las redes neuronales artificiales [10], Esta cronología partió con la comprensión del funcionamiento de las neuronas en el cerebro hasta llegar al desarrollo de perceptrones, modelos de redes neuronales. [11]. En general una arquitectura de una Red neuronal artificial está compuesta por conjuntos de neuronas (capas) divididos en tres grupos: Capa de entrada para recibir datos, capas ocultas para realizar el análisis y la capa de salida para emitir la respuesta [12].

Una ventaja muy significativa de las redes neuronales es que es una rama de estudio multidisciplinar, es decir que es aplicable a cualquier área de la ciencia [1], además no se requiere de una programación previa a la aplicación de estas redes ya que son capaces de aprender y generalizar en dependencia de la experiencia [13]. Dentro de los campos interdisciplinarios que maneja la investigación mediante redes neuronales podemos citar las siguientes: área neurocientífica y psicológica que mediante técnicas cuantitativas llegan a un mayor conocimiento en su disciplina.

También existen aplicaciones en el área informática e ingenieril, con ayuda de los RNA pueden construir sistemas que satisfagan las necesidades de su campo y por último el área de la física y las matemáticas en donde se encuentran nuevos dominios que aportan al desarrollo de este campo [14]. Donde los modelos RNA dentro del sector energético [15], han sido empleado como se muestra a continuación:

Las primeras aplicaciones se basaron en análisis energético sobre el producto interno bruto (PIB), donde Bassam et al. [16], realizó una predicción del consumo energético utilizando, usando como datos entrada, el PIB, cantidad poblacional, datos de importación y exportación, utilizando el modelo de perceptrón. Luego, Campoverde et al. [17], exploró como las redes neuronales artificiales y las técnicas de agrupamiento se utilizan para mejorar la reconfiguración de sistemas de distribución, e incluye evaluaciones de los resultados obtenidos y recomendaciones para futuros estudios. Por su parte, Yilmaz et al. [18], propuso una solución para la localización de fallas en sistemas de distribución de energía con generación remota usando redes neuronales artificiales. Se estudian la arquitectura, los métodos de entrenamiento y se evalúan los resultados. Los resultados sugieren que la propuesta es eficaz para el propósito, y se recomiendan cambios para mejorar los resultados. Además, Manitsas et al. [19], exploró el uso de una red neuronal artificial para estimar el estado de un sistema de distribución. Se analizan técnicas existentes y se propone un enfoque basado en redes neuronales para mejorar la precisión del modelado de medición pseudométrica. Los resultados muestran que el enfoque propuesto aumenta significativamente la precisión de la estimación de estado del sistema de distribución. Por otro lado, Al-shaher et al. [20], examina el uso de una red neuronal artificial para localizar fallas en una red de distribución de anillos múltiples. El documento ofrece información sobre la arquitectura de la red, el proceso de entrenamiento y los resultados obtenidos al evaluar el enfoque propuesto, concluyendo que la red neuronal es capaz de proporcionar un rendimiento aceptable para la localización de fallas. Además, el documento ofrece recomendaciones para futuros estudios en esta área [20].

En conclusión, se puede mencionar que las RNA es un adecuado enfoque para la predicción de comportamientos o resultado de estudios en diferentes áreas, incluso llegando a ser aplicada en el área de consumo de energía. Un caso específico en Ecuador existe una investigación sobre el análisis predictivo de consumo residencial en la ciudad de Milagro [21], la misma que ayuda a realizar previamente una planificación energética a medio- largo plazo tomando en consideración dentro del plan las redes de transporte y distribución, ya que una sobreestimación o subestimación causaría costes no necesarios dentro del proyecto [22].

## **1.2 Fundamentación Teórica**

Esta sección presenta los componentes teóricos necesarios para abordar el uso de RNA en bases de datos de series temporales en la planificación eléctrica.

### ***1.2.1 Inteligencia Artificial***

La inteligencia artificial (IA) se enfoca en emular el funcionamiento humano para el descubrimiento de patrones y toma de decisiones [23]. Este proceso es estrechamente ligado con la capacidad computacional que se cuenta y la cantidad de datos que se puede emplear para entrenar modelos. Además, a pesar de este alto requerimiento computacional, su respuesta es largamente menor que si una persona lo hiciera por sí mismo.

### ***1.2.2 Aprendizaje automático***

Este término es parte de la IA, ya que permite a las computadoras adquirir habilidades similares al razonamiento humano mediante algoritmos multipropósito que puede ejecutar varias tareas, es decir, no tiene una funcionalidad específica y puede ser utilizados en varias aplicaciones y tareas [24]. Esta tecnología se basa en el análisis de datos históricos para identificar patrones.

### ***1.2.3 Aprendizaje profundo***

Es otro término que es considerado parte de la IA que se caracteriza por constar de estructuras algorítmicas que posibilitan la creación de modelos con varias capas de procesamiento, un ejemplo de esto son las RNA [25]. Esta definición se enfoca en la capacidad de los algoritmos de aprender de los continuar leyendo datos para encontrar representaciones profundas y significativas.

### ***1.2.4 Redes neuronales artificiales***

Las RNA se basan en el funcionamiento de las redes neuronales biológicas, es decir, es una imitación del sistema nervioso natural, pero con ayuda de la tecnología, pueden procesar datos incompletos y ruidosos, por lo que tienen una mayor capacidad de absorber errores desempeñándose bien rápidamente ante problemas no lineales [26]. Una red neuronal debe configurarse de modo que la entrada de una serie de variables genere el conjunto deseado de resultados. Hay diferentes métodos para establecer la fuerza de las conexiones. Una opción es establecer explícitamente los pesos, usando conocimientos previos. Otra forma es entrenar la red neuronal alimentándola con patrones de aprendizaje, dejando que los pesos cambien conforme a alguna norma de aprendizaje [27].

Los tipos de entrenamiento en redes neuronales se pueden clasificar en tres: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje reforzado. En el aprendizaje supervisado, se proporcionan los datos de entrada a la red junto con un conjunto de salidas deseadas para cada nodo de la capa de salida. Se realiza un paso hacia adelante para calcular la discrepancia entre la salida deseada y la real para cada nodo. Esta diferencia se utiliza para ajustar los pesos de la red de acuerdo con el método de aprendizaje respectivo

### ***1.2.5 Arquitecturas De Redes Neuronales***

Es la configuración o disposición en la que las neuronas se conecta entre sí. La arquitectura básica consta de tres tipos de capas de neuronas: capas de entrada, ocultas

y de salida. Las RNA monocapa o perceptrón son una arquitectura simple que se compone de una capa de entrada y una de salida. En la Fig. 1, se puede observar un ejemplo de ellas.




Figura 1. Estructura de una red Neuronal Monocapa.  
Fuente: Autor

Por otro lado, las RNA multicapas, a diferencia de la red monocapa tiene capas ocultas para identificar patrones exhaustivamente y resolver problemas más complejos. En la Fig. 2, se muestra un ejemplo de ellas.




Figura 2. Estructura de una red Neuronal Multicapa.  
Fuente: Autor

**1.2.6 Redes Neuronales Recurrentes**

Redes neuronales recurrentes (RNN) son una clase de modelo de aprendizaje profundo que se utiliza para procesar datos de tiempo y secuencia, utilizan una estructura de

ramificación para procesar datos en tiempo real, permitiendo que el modelo "recuerde" información del pasado, esto les permite procesar datos secuenciales y entender patrones complejos en los datos [28]. Las redes neuronales son capaces de autorregularse al momento de entrenarse, pueden retener información y determinar su periodo de persistencia, así como decidir si almacenan o eliminan datos, por lo que no requieren una gran cantidad de memoria.

### ***1.2.7 Redes de memoria de corto plazo***

Las redes neuronales de memoria de corto plazo es una arquitectura que forma parte de las RNN que se emplean para la predicción de datos en series de tiempo que sus siglas en inglés es LSTM. Esta específica arquitectura está orientada a descubrir patrones en secuencias, por lo que es necesario que la información tenga una línea de tiempo. Su principal característica es que debido a que cuenta con bucles de aprendizaje, puede recordar estados previos para predecir la secuencia de datos de manera cronológica. Específicamente cuenta con diferentes modelos para la predicción de datos. La primera es considerada como Vanilla LSTM, que es en modelo con una capa de entrada y una de salida para la predicción. La segunda es considerada stacked LSTM, siendo un modelo complejo que se puede emplear varias capas ocultas para mejorar el proceso de extracción de características.

### ***1.2.8 Series de tiempo***

Una serie de tiempo es un conjunto de datos con una o varias variables que dependen del tiempo. Por tal motivo, cada variable depende de las muestras anteriores, es decir, tiene una dependencia de lo sucedido con anterioridad. Su principal característica es la estacionariedad, ya que este término demuestra que los datos son estrechamente relacionados y que ocasionalmente tienen un fenómeno cíclico, estadísticamente nombrado frecuencia.

### ***1.2.9 Perfiles de Carga Eléctrica.***

Los perfiles de carga eléctrica en alimentadores primarios son una representación gráfica de la carga eléctrica en una red de distribución. Estos perfiles se utilizan para entender mejor la distribución de la carga eléctrica a lo largo de la red, así como para identificar cargas críticas y cargas excesivas que pueden afectar la calidad del suministro eléctrico. Los perfiles de carga también se usan para estimar el tamaño de los componentes del sistema, como transformadores y cables, y para determinar si se requiere la adición de nuevas líneas o equipos [29].

### ***1.2.10 Alimentador Primario***

Un alimentador primario es una línea de transmisión de energía eléctrica que conecta una subestación de transmisión con una subestación de distribución. Estas líneas de transmisión suelen tener una capacidad de transmisión de decenas de miles de kilovatios, y se usan para transportar energía eléctrica desde la subestación de transmisión hasta los usuarios finales [30].

### ***1.2.11 Aplicación de Redes Neuronales Artificiales a la Distribución Eléctrica***

Las principales aplicaciones de redes neuronales artificiales a la distribución eléctrica incluyen:

- Predicción de fallas en líneas eléctricas se puede detectar un anómalo comportamiento que puede alertar a los a los operadores de red a tomar medidas de prevención para reducir el riesgo de interrupciones del servicio.
- Análisis de demanda eléctrica para analizar los patrones de demanda eléctrica y determinar la capacidad de los sistemas existentes para satisfacer futuras demandas.
- Predicción de defectos de los equipos eléctricos al predecir con precisión los defectos de los equipos eléctricos. Esto ayuda a los operadores a identificar y reparar los equipos antes de que ocurran fallas.

### **1.3 Fundamentación metodológica**

El enfoque empleado para el desarrollo del presente proyecto ha sido el análisis de datos mixto ya que se han combinado enfoques cualitativos y cuantitativos:

Para el análisis de datos cualitativos podemos considerar el estudio de los tipos de datos históricos que intervendrán en la creación de un modelo de red neuronal artificial para la predicción de cargas en perfiles de distribución, estos datos ingresarán en el software para poder establecer un modelo que tenga gran cantidad de información y pueda discernir la información útil para el estudio. Por otro lado, el análisis cuantitativo se enfoca en la cantidad de incidencias que se pueden considerar de los datos históricos, con los cuales se puede fortalecer el conocimiento de la red neuronal para la predicción en base a toda la información de ingreso que tiene.

Esta investigación pretende ser de tipo exploratorio y experimental por que se pretende definir un modelo de RNA en base a datos fidedignos ya conocidos, con los cuales se espera usar para la predicción de los perfiles de carga en los alimentadores de distribución. La técnica de recolección de datos informativos para realizar el modelo de RNA se realizará mediante mediciones históricas existentes en la base de datos de la empresa distribuidora.

### **1.4 Conclusiones Capítulo I**

- Los RNA son estructuras de elevada capacidad que pueden examinar la evolución de los métodos de conjunto básico empleados para ambos procedimientos propuestos. Los enfoques de conjuntos avanzados son capaces de prever la conducta con el objetivo de usar principalmente aquellos que ofrecen el mayor grado de exactitud.
- Existen diferentes formas de crear una RNA, para lo cual el experimentador deberá tener claro el resultado que pretende conseguir de los datos de entrada.

## **CAPÍTULO II.**

### **PROPUESTA**

#### **2.1 Título del proyecto.**

Redes neuronales artificiales aplicadas al estudio de perfiles de carga eléctrica en alimentadores primarios de una arquitectura de distribución.

#### **2.2 Objetivo del proyecto.**

Desarrollar un modelo de predicción por medio de la implementación de métodos de inteligencia artificial, evitando así el exceso de oferta en redes de energía eléctrica.

#### **2.3 Descripción de la propuesta**

La propuesta de titulación “Redes Neuronales Artificiales Aplicadas al Estudio de Perfiles de Carga Eléctrica en Alimentadores Primarios de una Arquitectura de Distribución” tiene como objetivo investigar el uso de la tecnología de RNA para mejorar la comprensión de la distribución de la carga eléctrica en una red de distribución. Esta investigación se centrará en el uso de la RNA para desarrollar modelos predictivos que permitan predecir con precisión los perfiles de carga eléctrica en alimentadores primarios. Estos modelos permitirán a los ingenieros de la red identificar cargas críticas, detectar anomalías en la carga, optimizar la asignación de la carga mejorando la eficiencia y minimizando los costos de la red. Además, el estudio abordará el uso de la optimización para mejorar los resultados del modelo, así como la implementación práctica de la red neuronal artificial para su aplicación en una arquitectura real de distribución.

Finalmente, la investigación también abordará la evaluación de los resultados obtenidos y la comparación con otros métodos para el estudio de la distribución de la carga eléctrica. Con este trabajo se espera desarrollar una metodología de trabajo que permita la aplicación de la RNA para mejorar la eficiencia y la calidad del suministro eléctrico en una red de distribución.

## 2.4 Metodología o procedimientos empleados para el cumplimiento de los objetivos planteados

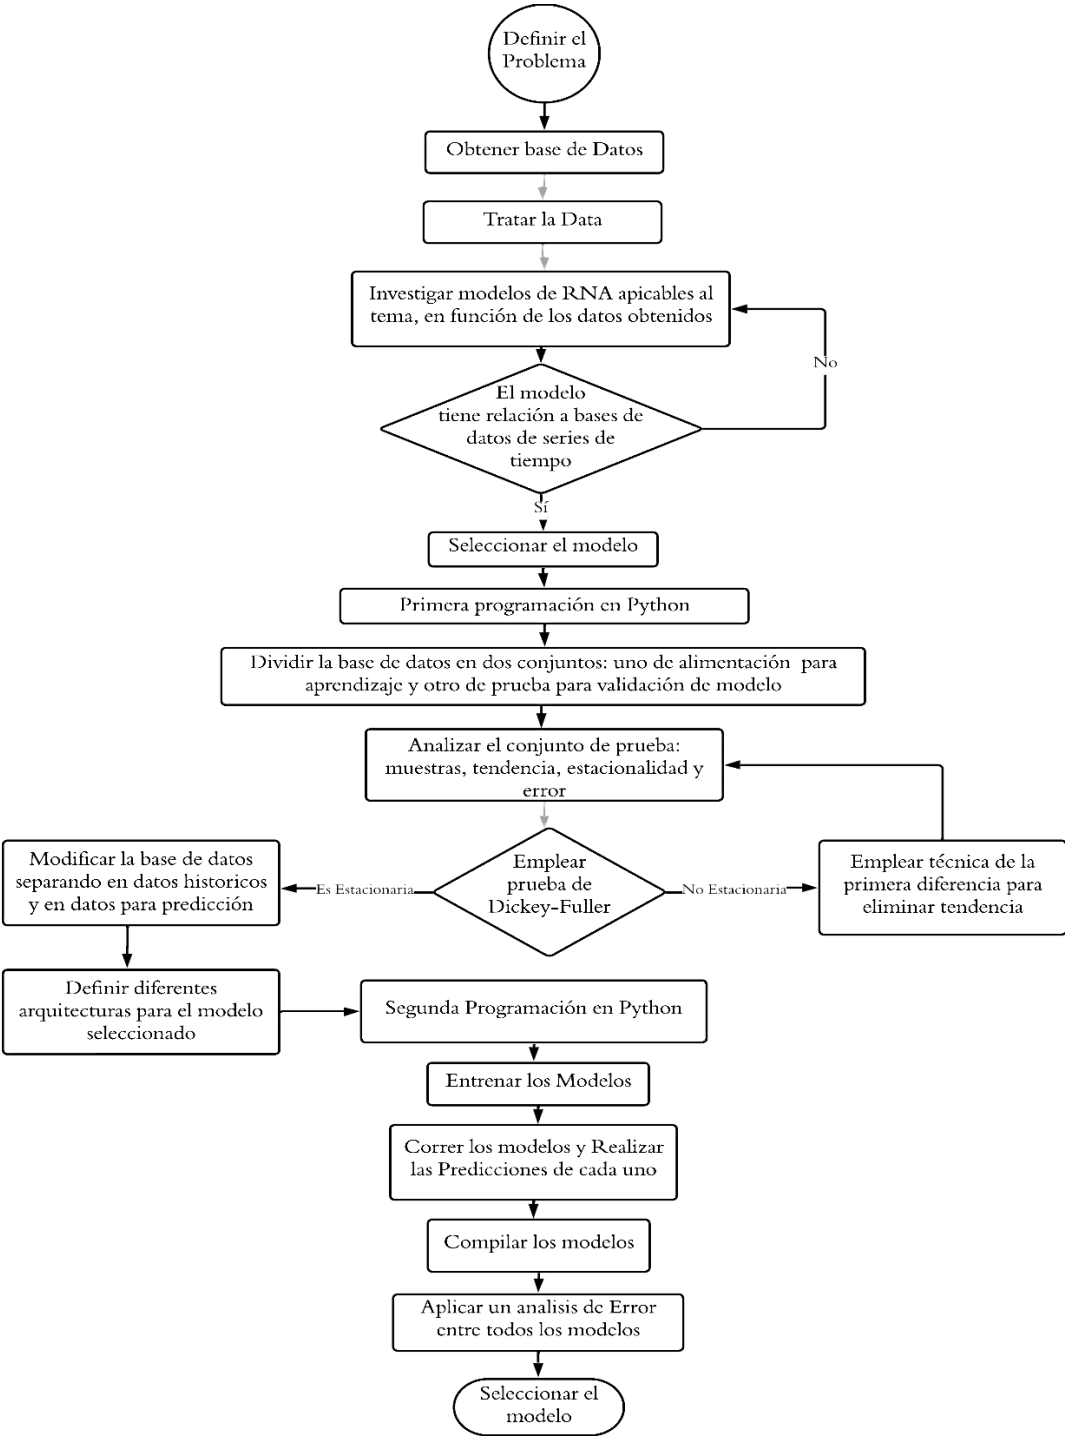


Figura 3. Diagrama de Flujo  
Fuente: Autor

El procedimiento empleado es el siguiente:

- Definir el problema: Con lo mencionado anteriormente, el problema a enfrentar es el inexistente estudio de perfiles de carga eléctrica en alimentadores primarios de una arquitectura de distribución. Teniendo como consideración que se cuenta con datos para aplicar modelos de aprendizaje profundo.
- Transformar la base de datos: Analizar datos para ajustar frecuencia de muestreo adecuada para entrenar modelos de aprendizaje profundo. Escalar los datos entre 0 y 1 de tal forma que puedan ser ingresados a la red neuronal, ya que la actualización de los pesos de las neuronas se encuentra en este rango. Finalmente, Dividir en conjunto de entrenamiento y prueba para validar exactitud del modelo.
- Procesar los datos: Los datos serán convertidos en matrices para generar el modelo de predicción. Es decir que los primeros datos de entrenamiento se convierten en los históricos y el siguiente dato será considerado como predicción. Debido a que la frecuencia mínima que se puede pronosticar series de tiempo de forma eficiente es de forma horaria, las primeras 23 muestras se convierten en históricos y la última hora es considerada el pronóstico. Este proceso es mandatorio para usar LSTM.
- Diseñar la red neuronal: Se emplean los modelos Vanilla y tacked LSTM con diferentes capas y número de neuronas que serán entradas para determinar cuál de los modelos, el número de capas y neuronas es el adecuado. Para estos modelos, se utiliza un esquema de capas interconectadas completamente.
- Entrenar la red neuronal: Con los modelos establecidos con la flexibilidad de usar diferente número de iteraciones para entrenar la red. Este proceso es el cual actualiza los pesos de la red neuronal y que mayor coste computacional conlleva.
- Evaluar la red neuronal: Una vez que los modelos han sido entrenados, cada uno de ellos se evaluarán con métricas de tipos de error para conocer el que mejor pronósticas muestras futuras.

## 2.5 Diseño de la propuesta

La propuesta inicia con la recopilación de datos del perfil de carga de los meses de noviembre y diciembre del 2022.

### 2.5.1 Tratamiento de los Datos

La base de Datos inicial, considera varios parámetros eléctricos del alimentador:




Figura 4. Base de datos Inicial

Fuente: Autor

Los datos serán tratados para hacer uso de los datos específicos y necesarios para la generación de la red neuronal, en este caso los parámetros son Potencias y tiempo, donde el sistema recolecta datos cada 15 minutos, se obtuvo un conjunto de 5856 datos de kilowatts (kW), kilo voltio amperio (kVA) y kilo voltio amperio reactivo (kVAR).

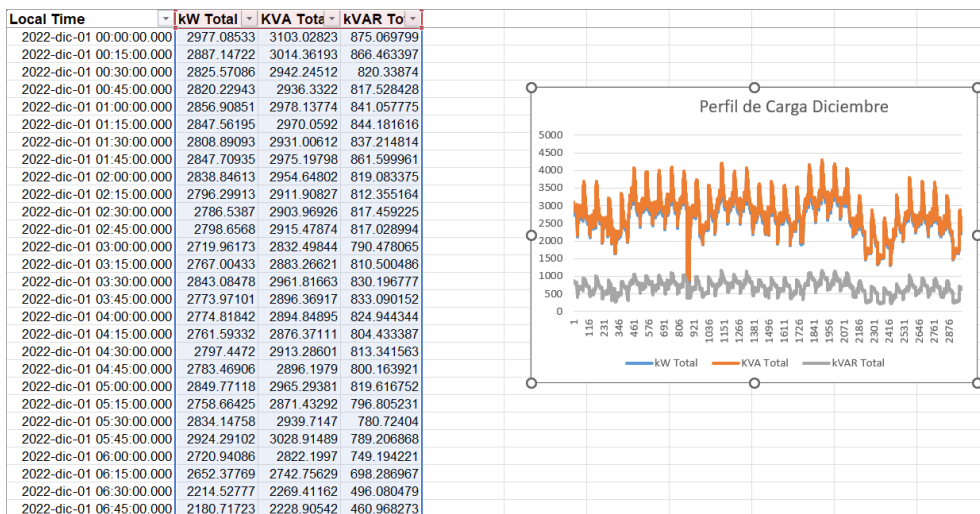


Figura 5. Base de datos tratada

Fuente: Autor

### 2.5.2 Selección del tipo de Red Neuronal

Para poder elegir correctamente debemos entender cuáles son los tipos, características, subtipos y aplicaciones de las redes neuronales artificiales, los cuales se analizan en el siguiente mapa:

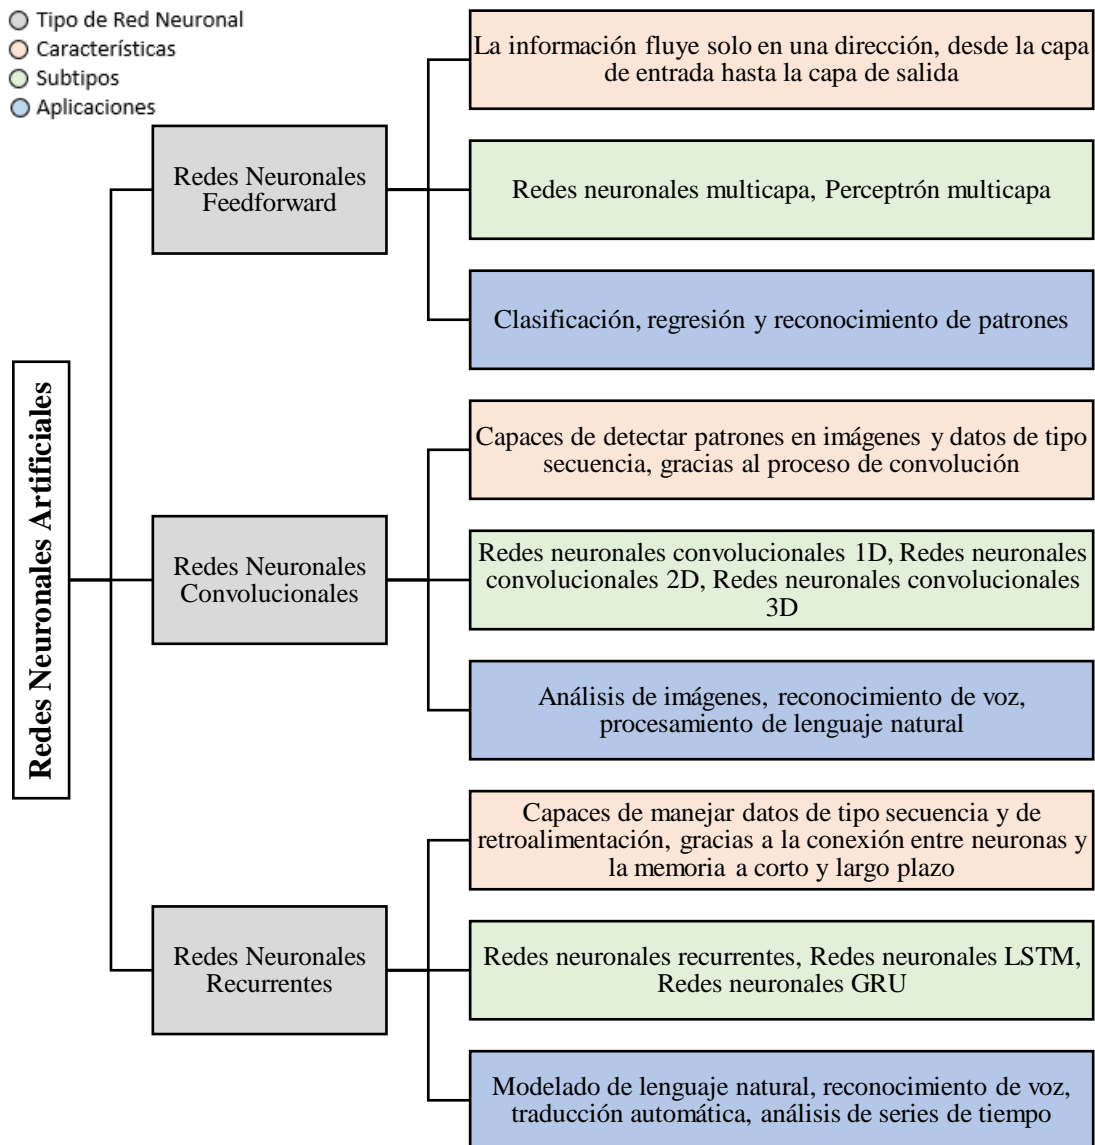


Figura 6. Clasificación de Redes Neuronales Artificiales  
Fuente: Autor

Del mapa se puede observar que el mejor tipo de red neuronal a ser aplicado en función de los tipos de datos obtenidos, es la red neuronal recurrente, por su capacidad de manejar datos de tipo secuencia y de retroalimentación, ahora bien, a partir de esto se

presenta una tabla comparativa entre redes recurrentes para elegir la que más se apegue a los objetivos de este trabajo:

**Tabla 2.** Tabla comparativa de redes neuronales recurrentes

<b>Red Neuronal Recurrente</b>	<b>Características</b>	<b>Ventajas</b>	<b>Desventajas</b>	<b>Aplicaciones</b>
Red neuronal recurrente básica	Capa de retroalimentación que conecta las salidas con las entradas	Simplicidad, fácil implementación	No tiene memoria a largo plazo, no puede capturar patrones de larga duración	Predicción de series de tiempo simples
Red neuronal Jordan	Las salidas de la red se retroalimentan a las entradas retrasadas un paso de tiempo	Captura patrones de corta duración	No tiene memoria a largo plazo, no puede capturar patrones de larga duración	Clasificación de secuencias cortas
Red neuronal Elman	Una capa oculta con una capa de retroalimentación que conecta la salida de la capa oculta con sus entradas	Capacidad para capturar patrones de corta y larga duración	No es muy efectiva en la resolución de problemas complejos	Reconocimiento de voz
Red neuronal de memoria a corto plazo (LSTM)	Contiene compuertas que controlan el flujo de información en la red, lo que permite la memoria a largo plazo	Capacidad para capturar patrones de corta y larga duración, mejor desempeño en la resolución de problemas complejos	Mayor complejidad, requiere mayor tiempo de entrenamiento y ajuste de parámetros	Predicción de series de tiempo complejas, procesamiento de lenguaje natural, reconocimiento de voz

*Elaborado por: Katherine Díaz*

Como se puede analizar en la tabla, las redes neuronales recurrentes LSTM son una buena opción para manejar datos de tipo secuencia y realizar predicciones en base a patrones históricos. En el caso específico de la predicción de series de tiempo, las redes neuronales LSTM son muy efectivas para capturar patrones complejos y tendencias a largo plazo, lo que las hace ideales para este trabajo.

### 2.5.3 Transformación de la base de datos

La base de datos será analizada mediante varios métodos estadísticos para demostrar su estacionalidad (requisito necesario para aplicar redes LSTM). Por tal motivo, la base de datos se modifica su frecuencia de muestreo (15 minutos) a uno horario. Este proceso se realiza sumando las muestras de cada hora que se tiene inicialmente y encontrando su promedio. Como resultado, el conjunto de datos se reduce a 1463 muestras de cada variable. La Fig. 7 muestra en diferentes colores representadas en el tiempo las variables antes mencionadas.




Figura 7. Base de datos de perfiles de carga.  
Fuente: Autor

#### 2.5.4 *Procesamiento de datos*

La base de datos es dividida en dos conjuntos. El primero es el conjunto de entrenamiento que servirá para alimentar a la red neuronal y pueda aprender al detectar sus patrones más relevantes, es decir los primeros 24 días del mes que equivalen al 77.42%. El segundo es el conjunto de pruebas que servirá para validar el modelo generado por la red neuronal. En este caso, se han establecido los últimos 7 días del mes de diciembre al 22.58% restante, que es la parte final del conjunto total, sea considerado como prueba. Como resultado, se podrá predecir los siguientes 7 días en adelante con el modelo seleccionado, es decir, pronosticar los días de enero del 2023. La Fig. 8 muestra por colores como se ha dividido el conjunto de datos.




Figura 8. Conjunto de entrenamiento y prueba  
Fuente: Autor

Con el conjunto de prueba, se analizan los componentes principales de las series de tiempo al descomponerla, los cuales son: (a) Las muestras observadas: Los valores obtenidos de la variable. (b) La tendencia: Define si su comportamiento es ascendente, descendente o estable. (c) Estacionalidad: La frecuencia que la serie de tiempo se repite

y (d) Error: El ruido de la serie de tiempo. Las Fig. 9-10-11-12 muestran estos componentes de forma gráfica

*Descomposición de la serie de tiempo:*




Figura 9. Muestras observadas  
Fuente: Autor




Figura 10. Tendencia  
Fuente: Autor




Figura 11. Estacionalidad  
Fuente: Autor




Figura 12. Error  
Fuente: Autor

Luego, se emplea la prueba de Dickey-Fuller permite conocer la estacionalidad de la serie de tiempo. Como se puede apreciar en la Fig. 13, los datos no relacionan entre sí estrechamente y su p-valor en esta prueba estadística en todas las variables es superior a 0.5. Por lo tanto, inicialmente no puede ser considerada una serie de tiempo

estacionaria que deriva en el uso de modelos más complejos como lo son las redes neuronales. Posteriormente, se emplea la técnica de la primera diferencia para eliminar la tendencia y volver a generar la prueba, donde esta vez la serie de tiempo si se comprueba ser estacionaria. Es decir, que el modelo debe ser complejo ya que la tendencia no es lineal.




Figura 13. Prueba Dickey-Fuller en la serie de tiempo  
Fuente: Autor

**2.5.5 Diseño de las LSTM**

Se han empleado 4 modelos diferentes de redes LSTM, donde de ellas son Vanilla-LSTM y dos tacked-LSTM con 50 iteraciones de entrenamiento (epochs) bajo un estudio de prueba y error en un servidor de altas prestaciones. La descripción de cada una se muestra en la Tabla 3.

**Tabla 3.** Descripción de redes LSTM

Modelo	Descripción
Vanilla-LSTM #1	Modelo secuencial con una capa de entrada LSTM de 100 neuronas y una cada de salida Densa con una neurona. Se emplea el optimizador “Adam” y medida de pérdida “mse”.

Vanilla-LSTM #2	Modelo secuencial con una capa de entrada LSTM de 200 neuronas y una capa de salida Densa con una neurona. Se emplea el optimizador “Adam” y medida de pérdida “mse”.
tacked-LSTM #1	Modelo secuencial con una capa de entrada LSTM de 100 neuronas, una capa oculta LSTM de 50 neuronas y una capa de salida Densa con una neurona. Se emplea el optimizador “Adam” y medida de pérdida “mse”.
tacked-LSTM #2	Modelo secuencial con una capa de entrada LSTM de 200 neuronas, una capa oculta LSTM de 100 neuronas y una capa de salida Densa con una neurona. Se emplea el optimizador “Adam” y medida de pérdida “mse”.

*Elaborado por: Katherine Díaz*

### 2.5.6 Entrenamiento de redes neuronales

La base de datos se modifica para que pueda ajustarse al requerimiento de la red LSTM. Por tal motivo, el conjunto de datos se transforma en ventanas donde las 23 horas del día se convierten en los históricos de la señal y la última hora del día se considera la predicción del conjunto. La Fig. 14 muestra la forma que los datos fueron convertidos en ventanas.




Figura 14. Series de tiempo convertida en ventanas  
Fuente: Autor

## 2.6 Conclusiones Capítulo II

- las redes neuronales recurrentes son útiles para la predicción de perfiles de carga eléctrica con bases de datos en series de tiempo, pero las redes LSTM pueden ser particularmente efectivas debido a su capacidad para capturar patrones de corta y larga duración y su mejor desempeño en la resolución de problemas complejos. Sin embargo, se debe tener en cuenta que las redes LSTM son más complejas y pueden requerir más tiempo de entrenamiento y ajuste de parámetros.
- Las series de tiempo antes de ser analizadas se deben asegurar que su frecuencia sea permitida para entrenar modelos. Además, comprobar la estacionalidad es muy importante para establecer los diferentes modelos a usar.
- Las series de tiempo deben ser modificadas para que puedan ser parte del entrenamiento de las redes neuronales. Por lo tanto, el siguiente paso es definir los diferentes modelos.

## CAPITULO III.

### APLICACIÓN Y/O VALIDACION DE LA PROPUESTA

#### 3.1 Análisis de los resultados:

Una vez entrenados los modelos LSTM se realizan las predicciones de 7 días y verificar su semejanza con el conjunto de prueba. La Fig. 15 muestra el ejemplo de la variable de kilo watts del primero LSTM. A pesar que su rendimiento es adecuado, se puede notar que la tendencia es descendente y que no replicar el conjunto de prueba.




Figura 15. Predicción del primer modelo LSTM

Fuente: Autor

Luego, el segundo modelo se muestra en la Fig. 16, donde se puede evidenciar que se ajusta de mejor forma al conjunto de prueba y su tendencia es muy similar.




Figura 16. Predicción del segundo modelo LSTM  
Fuente: Autor

El tercer modelo donde se emplea una capa oculta donde se puede observar en la Fig. 17, tiene un similar resultado al segundo modelo LSTM.




Figura 17. Predicción del tercer modelo LSTM  
Fuente: Autor

Como se puede apreciar en la Fig. 18, en el cuarto modelo se puede evidenciar que se sobreentrena la red y su predicción sufre varios errores. Por tal motivo este modelo es descartado del análisis.




Figura 18. Predicciones del cuarto modelo LSTM  
Fuente: Autor

Finalmente, se pueden evidenciar todos los modelos comparados solo con los datos de entrenamiento. Esto se puede evidenciar en la Fig. 19.




Figura 19. Predicciones de modelos LSTM  
Fuente: Autor

### 3.2 Validación técnica de los resultados:

Una vez compilados todos los modelos, en la sección anterior se pudo observar que el segundo modelo y el tercero demostraron ser los que más se ajustan a la serie de tiempo de perfiles de carga. Por tal motivo, ambos modelos son reflejados directamente con el conjunto de prueba para observar sus similitudes. Las Fig. 20 representa este proceso.




Figura 20. Modelos de predicción seleccionados  
Fuente: Autor

Para la correcta selección del modelo de predicción, se evalúan con diferentes tipos de error. El error absoluto medio (EAM) puede pedir la precisión del modelo, sin observar la dirección del error. Por lo tanto, el error cuadrático medio (ECM) ajusta este es problema al elevar el error al cuadrado y evitar sesgos en la decisión. Finalmente, el coeficiente de determinación (R2) muestra la variabilidad del modelo y el ajuste que tiene la predicción. En la tabla 4 se puede apreciar que a pesar de que el modelo #2 tiene un menor EAM en relación con el modelo #3. No obstante eso puede mencionar que los errores negativos y positivos pueden sesgar la selección. Por tal motivo, el ECM muestra que el modelo #3 tiene un menor valor lo que significa que es un modelo que se ajusta de mejor forma. Además, con la métrica R2, se puede evidenciar que el pronóstico es muy cercano a cero y ambos modelos parecen ser tener un comportamiento muy similar. Finalmente, cuando se observan los errores máximos de cada modelo, la predicción del modelo #3 es mucho mayor y que por ende se elige al segundo modelo con una sola capa de entrada y una capa de salida.

**Tabla 4.** Análisis de error

MODELO	TIPOS DE ERROR		
	EAM	ECM	R2
Modelo #2	318.45 Kw	347.09 Kw	0.31
Modelo #3	343.78 Kw	437.75 Kw	-0.09

*Elaborado por: Katherine Díaz*

Finalmente, para validar la probabilidad de acierto en los dos modelos estudiados, se estudian las primeras 10 muestras del conjunto de prueba y se analiza la variabilidad del pronóstico. Es decir, el porcentaje de acierto que tiene cada uno de los modelos. La tabla 5, muestra que el modelo #2 tiene un error de pronóstico de  $\pm 3.57\%$  y el modelo #3 tiene un error de  $\pm 4.38\%$ .

**Tabla 5.** Análisis de error

<b>MODELO</b>	<b>Probabilidad de acierto</b>
Modelo #2	$\pm 3.57 \%$
Modelo #3	$\pm 4.38 \%$

*Elaborado por: Katherine Díaz*

### 3.3 Evaluación de impactos o resultados

Una vez seleccionado el modelo, se lo vuelve a entrenar con todo el conjunto de datos para realizar la predicción de futuras muestras. Manteniendo los mismos criterios establecidos en el desarrollo de este proyecto, se predicen los próximos 7 días de enero del 2023. En la Fig. 21 se puede observar que la predicción mantiene la misma periodicidad con picos similares de kilo watts, aunque con una tendencia más lineal. Esto se debe a que el conjunto de datos es reducido y no le permite conocer de mejor forma la periodicidad de este.




Figura 21. Predicción del mes de enero del 2023

Fuente: Autor

### **3.4 Conclusiones del III capítulo**

- Las redes LSTM permiten generar modelos de predicción muy cercanos a los valores de prueba que aseguran pronosticar muestras futuras para una planificación eléctrica.
- Al realizar este estudio de predicción de perfiles de carga, se demostró la utilidad de las redes LSTM, pero se debe tener una consideración de un preprocesamiento de datos que los ajuste a las necesidades del modelo.
- A pesar de que no se ha considerado en este proyecto el coste computacional que conlleva el entrenar redes LSTM y su búsqueda en la selección de capas y neuronas. Es necesario mencionar que se debe contar con servidores de altas prestaciones para compilarlos.

## CONCLUSIONES

- A través de la transformación y procesamiento de la base de datos de series de tiempo se obtuvieron los datos necesarios para entrenar modelos de aprendizaje profundo como las redes neuronales, permitiendo ajustarlos a una frecuencia de muestreo adecuada y escalarlos entre 0 y 1, además de dividirlos en un conjunto de entrenamiento y de prueba. Además, se aplicaron diferentes métodos estadísticos para demostrar la estacionalidad de la serie de tiempo con el uso de la prueba de Dickey-Fuller y la técnica de la primera diferencia, lo cual confirma que el modelo debe ser complejo para pronosticar los datos de forma precisa.
- El uso de redes neuronales recurrentes en el estudio de perfiles de carga eléctrica en alimentadores primarios de una arquitectura de distribución de energía eléctrica, parece ser la mejor opción para lograr un acercamiento predictivo, debido a su capacidad para procesar datos secuenciales y entender patrones complejos en los datos, así como su capacidad de autorregularse y adaptarse a los cambios en el entorno.
- El modelo desarrollado mediante la implementación de técnicas de inteligencia artificial como los modelos de regresión lineal, árboles de decisión y redes neuronales artificiales, fue capaz de predecir de manera aproximada el comportamiento de los perfiles de carga eléctrica en alimentadores primarios de una arquitectura de distribución. Esto fue verificado mediante la evaluación de diferentes tipos de error y del coeficiente de determinación, siendo el segundo modelo (Modelo secuencial con una capa de entrada LSTM de 200 neuronas y una capa de salida Densa con una neurona. Se emplea el optimizador “Adam” y medida de pérdida “mse”) es el que mejor se ajustó para la predicción. Adicionalmente, se pudo corroborar que el modelo seleccionado fue capaz de predecir correctamente la carga durante los próximos días.
- Se concluye que el desarrollo de un modelo de predicción basado en la implementación de métodos de inteligencia artificial, cumplió con los Objetivos

Específicos establecidos. Se encontró que el modelo desarrollado presentó un desempeño satisfactorio al evaluar su eficacia con diferentes tipos de error, lo que demuestra su capacidad para predecir correctamente los patrones de demanda en los perfiles de carga eléctrica, los resultados obtenidos evidencian que la implementación de Redes Neuronales Artificiales es una metodología eficaz y viable para el estudio de perfiles de carga eléctrica en alimentadores primarios de una arquitectura de distribución.

## RECOMENDACIONES

- En cuanto a la limitación del recurso computacional, se sugiere la utilización de aceleradores gráficos (GPU) para el proceso de entrenamiento de la red neuronal, ya que pueden reducir significativamente el tiempo necesario para entrenar el modelo. Además, se podría investigar la posibilidad de utilizar técnicas de paralelización para disminuir el tiempo de procesamiento.
- En el futuro, se podría considerar la utilización de diferentes arquitecturas de redes neuronales, como redes neuronales convolucionales (CNNs) o redes neuronales de atención (ANNS), para comparar su desempeño en la predicción de perfiles de carga eléctrica.
- Se sugiere investigar el efecto de diferentes parámetros de entrenamiento, tales como tamaños de lote (batch size), tasa de aprendizaje (learning rate) y número de épocas (number of epochs), en el desempeño de la red neuronal.
- Dado que el problema de predicción de perfiles de carga eléctrica es una tarea crítica en la industria eléctrica, se recomienda que se realice una validación rigurosa del modelo antes de su implementación en una escala mayor, esto incluiría validaciones cruzadas, conjuntos de prueba externos y análisis de errores.
- Por último, es recomendable que se realice una comparación del desempeño de la red neuronal con otros modelos de predicción tradicionales

## REFERENCIAS BIBLIOGRÁFICAS

- [1] E. Acevedo, A. Serna y E. Serna, «Desarrollo e Innovación en Ingeniería,» *Instituto Antioqueño de la Investigación*, p. 174, 2017.
- [2] J. Mendoza, «PRONÓSTICO DE CARGA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES,» *Scientia Et Technica*, vol. XII, n° 32, pp. 175-180, 2006.
- [3] C. Mallo, «Predicción de la demanda eléctrica horaria mediante redes neuronales artificiales,» *Revista Electrónica de Comunicaciones y Trabajos de ASEPUMA*, vol. 5, n° 1, pp. 5-28, 2004.
- [4] X. Gozález, A. Perea, G. Caicedo y F. Castro, «Estimación de curvas de carga en transformadores eléctricos mediante redes neuronales,» *Ingeniería y Competitividad*, vol. 10, n° 2, pp. 75-86, 2008.
- [5] J. Juárez, *Sistemas de distribución de energía eléctrica*, Mexico: Limusa, 2000.
- [6] V. Yepes, «¿Qué es y para qué sirve una red neuronal artificial?,» *Universitat Politècnica de Valencia*, 7 Enero 2017. [En línea]. Available: <https://victoryepes.blogs.upv.es/2017/01/07/que-es-y-para-que-sirve-una-red-neuronal-artificial/>. [Último acceso: 2020].
- [7] T. Kohonen, «An introduction to neural computing,» *Neural Networks*, vol. 1, n° 1, pp. 3-16, 1988.
- [8] M. Gestal, «Introducción a las Redes de Neuronas Artificiales,» *Universidad da Coruña*, 4 Diciembre 2009. [En línea]. Available: <http://sabia.tic.udc.es/mgestal/cv/RNAtutorial/rna.html>. [Último acceso: 2020].

- [9] X. Basogain, *Redes Neuronales Artificiales y sus Aplicaciones*, Bilbao: Escuela Superior de Ingeniería de Bilbao, 1998.
- [10] D. Matich, *Redes Neuronales: Conceptos Básicos y Aplicaciones*, Rosario: Documento de trabajo. Universidad Tecnológica Nacional, 2001.
- [11] L. Henández y A. Hernández, «Materiales Didácticos de la Universidad Autónoma del Estado de Hidalgo,» Universidad Autónoma del Estado de Hidalgo, Diciembre 2011. [En línea]. Available: [https://www.uaeh.edu.mx/docencia/P\\_Presentaciones/huejutla/sistemas/redes\\_neuronales/perceptron.pdf](https://www.uaeh.edu.mx/docencia/P_Presentaciones/huejutla/sistemas/redes_neuronales/perceptron.pdf). [Último acceso: 2020].
- [12] F. Palacios, «Herramientas en GNU/Linux para estudiantes universitarios,» 2003. [En línea]. Available: [https://www.ibiblio.org/pub/linux/docs/LuCaS/Presentaciones/200304curso-glisa/redes\\_neuronales/curso-glisa-redes\\_neuronales-html/index.html](https://www.ibiblio.org/pub/linux/docs/LuCaS/Presentaciones/200304curso-glisa/redes_neuronales/curso-glisa-redes_neuronales-html/index.html).
- [13] J. Hilera y J. Martínez, *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*, Alfaomega, 1995.
- [14] A. Prieto, «Redes neuronales: modelos y aplicaciones,» 17 Mayo 2018. [En línea]. Available: <https://digibug.ugr.es/handle/10481/55772>.
- [15] R. Piloto y R. Rodriguez, «Redes Neuronales Artificiales. Conceptos básicos y algunas aplicaciones en Energía.,» Universidad Tecnológica de la Habana "José Antonio Echeverría", 2017.
- [16] M. Bassam, «Forecasting Energy Demand in Jordan Using Artificial Neural,» *Topics in Middle Eastern and African Economies*, vol. 14, pp. 473-478, 2012.

- [17] H. Salazar, R. Gallego y R. Romero, «Artificial Neural Networks and Clustering Techniques Applied in the Reconfiguration of Distribution Systems,» *IEEE Transactions on Power Delivery*, vol. 21, n° 3, pp. 1735-1742, 2006.
- [18] Y. Aslan, «An Alternative Approach to Fault Location on Power Distribution Feeders with Embedded Remote-End Power Generation using Artificial Neural Networks,» *IEEE Transactions on Power Delivery*, vol. 32, n° 4, pp. 2468-2478, 2017.
- [19] E. Manitsas, R. Singh, B. Pal y G. Strbac, «Distribution System State Estimation Using an Artificial Neural Network Approach for Pseudo Measurement Modeling,» *IEEE Transactions on Power Systems*, vol. 35, n° 5, pp. 4491-4501, 2020.
- [20] M. Al-shaher, M. Sabry y A. Saleha, «Fault Location in Multi-Ring Distribution Network Using Artificial Neural Network,» *IEEE Transactions on Power Systems*, vol. 34, n° 2, pp. 851-862, 2019.
- [21] B. Campoverde y X. Onofre, «Análisis predictivo de datos para el consumo de energía CNEL-EP Milagro, mediante redes neuronales artificiales utilizando el software matlab,» Universidad Estatal de Mlagro, 2018.
- [22] J. Salas, «Desarrollo con matlab de una red neuronal para estimar la demanda de energia eléctrica,» Universidad de Valladolid, 2016.
- [23] S. J. Russell y P. Norving, *Inteligencia Artificial: Una Introducción Moderna*, San Francisco: Prentice Hall, 2009.
- [24] B. Lantz, *Machine Learning: A Practical Guide*, Berkeley: O'Reilly Media, 2017.

- [25] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning: A Practical Introduction*, Montreal: MIT Press, 2020.
- [26] M. Ilunga y D. Stephenson, « Infilling stream flow data using feed-forward back-propagation (BP) artificial neural networks: Application of standard BP and pseudo Mac Laurin power series BP techniques,» *Water SA*, vol. 31, n° 2, pp. 171-176, 2005.
- [27] M. Fernandez , «Aplicación de lenguas electrónicas en la monitorización de procesos de biosorción de metales,» 2011.
- [28] D. Becker, *Recurrent Neural Networks for Beginners: Principles, Architectures and Applications*, New York: Apress, 2020.
- [29] K. Bollen, H. Naber y W. van den Bos, «Load Profiling for Real-Time Systems,» *IEEE Power Engineering Review*, vol. 16, n° 1, pp. 27-31, 1996.
- [30] A. Pereira, «An Overview of Power System Line Design,» *IEEE Power Engineering Review*, vol. 16, n° 5, pp. 32-35, 1996.

## ANEXO 1: CÓDIGO

26/3/23, 22:51

SERIES\_DE\_TIEMPO

```
In [ ]: tf.random.set_seed(100)
# define model
model_4 = Sequential()
model_4.add(LSTM(100, activation='relu', return_sequences=True, input_shape=(n_input, n_features)))
model_4.add(LSTM(50, activation='relu'))
model_4.add(Dense(1))
model_4.compile(optimizer='adam', loss='mse')
# fit model
history_1=model_4.fit(generator,steps_per_epoch=240, epochs=50)#steps_per_epoch=10


test_predictions = []
first_eval_batch = scaled_train[-n_input:]
current_batch = first_eval_batch.reshape((1, n_input, n_features))
for i in range(len(test_data)):
    # get prediction 1 time stamp ahead ([0] is for grabbing just the number instead of the array)
    current_pred = model_4.predict(current_batch)[0]
    # store prediction
    test_predictions.append(current_pred)
    # update batch to now include prediction and drop first value
    current_batch = np.append(current_batch[:,1:,:], [[current_pred]],axis=1)
```

```
In [ ]: pred_4_nuevo=scaler.inverse_transform(test_predictions)
```

Predicen los dias establecidos

Observa el modelo

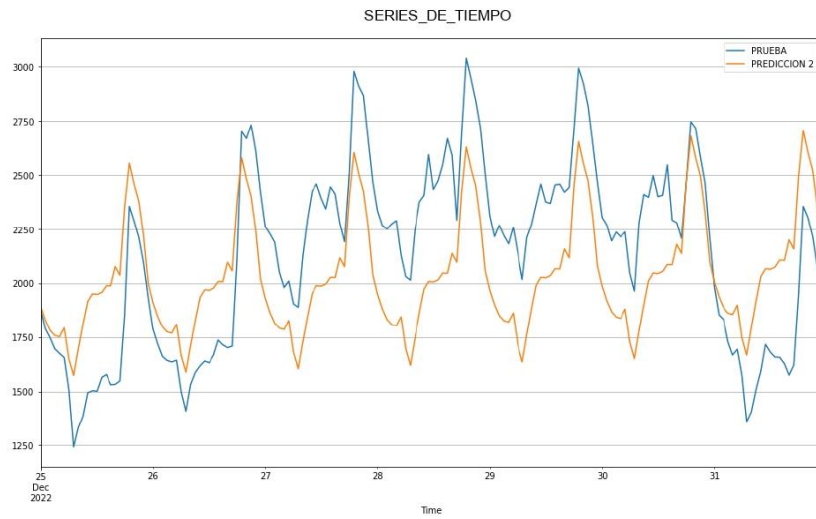
```
In [ ]: train_data_kw['kw'].iloc[:].plot(legend=True,label='ENTRAMAMIENTO')
test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
pred_2_nuevo.plot(legend=True,label='PREDICCION 2')
plt.grid()
```




```
In [ ]: test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
pred_2_nuevo.plot(legend=True,label='PREDICCION 2')
plt.grid()
```

localhost:8890/lab/tree/Documents/TESIS

10/15




```
In [ ]: train_data_kw['kw'].iloc[:].plot(legend=True,label='ENTRAMAMIENTO')
test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
pred_1_nuevo.plot(legend=True,label='PREDICION 1')
plt.grid()
```




```
In [ ]: test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
pred_1_nuevo.plot(legend=True,label='PREDICION 1')
plt.grid()
```

26/3/23, 22:51

SERIES\_DE\_TIEMPO

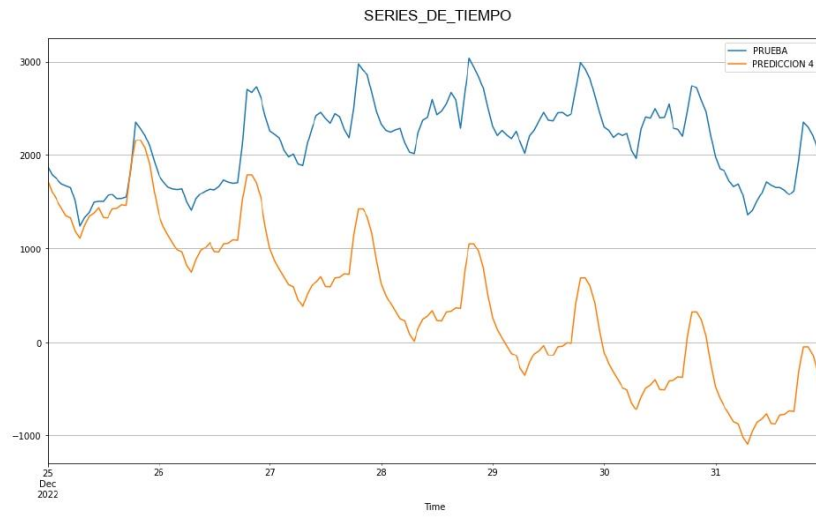


```
In [ ]: train_data_kw['kw'].iloc[:].plot(legend=True,label='ENTRAMAMIENTO')
test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
pred_4_nuevo.plot(legend=True,label='PREDICCION 4')
plt.grid()
```




```
In [ ]: test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
days_pred_4.plot(legend=True,label='PREDICCION 4')
plt.grid()
```

26/3/23, 22:51




```
In [ ]: pred_3_nuevo.plot(legend=True,label='PREDICCION 3')
test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
plt.grid()
```



```
In [ ]: train_data_kw['kw'].iloc[:].plot(legend=True,label='ENTRAMAMIENTO')
test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
pred_3_nuevo.plot(legend=True,label='PREDICCION ')
plt.grid()
```

26/3/23, 22:51

SERIES\_DE\_TIEMPO



```
In [ ]: test_data_kw['kw'].plot(legend=True,label='PRUEBA',figsize=(16,9))
pred_3_nuevo.plot(legend=True,label='PREDICCION 3')
pred_1_nuevo.plot(legend=True,label='PREDICCION 1')
pred_2_nuevo.plot(legend=True,label='PREDICCION 2')
pred_4_nuevo.plot(legend=True,label='PREDICCION 4')

plt.grid()
```

