



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

PROYECTO DE INVESTIGACIÓN

**DESARROLLO DE UN SISTEMA DE PREDICCIÓN CON REDES
NEURONALES ARTIFICIALES PARA DETERMINAR LA DEMANDA DE
ENERGÍA ELÉCTRICA EN UNA CENTRAL HIDROELÉCTRICA**

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

Autor/es:

Bastidas Cashicana Wilson Roberto

Moya Cabezas Angelo Mauricio

Tutor:

Ing. MSc. Castillo Fiallos Jessica Nataly

LATACUNGA – ECUADOR

Marzo - 2022



DECLARACIÓN DE AUTORÍA

Nosotros, **Bastidas Cashicana Wilson Roberto** con C.I. N°: **180491378-6** y **Moya Cabezas Angelo Mauricio** con C.I. N°: **180487978-9** declaramos ser autores del presente proyecto de investigación: **“DESARROLLO DE UN SISTEMA DE PREDICCIÓN CON REDES NEURONALES ARTIFICIALES PARA DETERMINAR LA DEMANDA DE ENERGÍA ELÉCTRICA EN UNA CENTRAL HIDROELÉCTRICA”**, siendo la **Ing. MSc. Jessica Nataly Castillo Fiallos** tutora del presente trabajo; y eximimos expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

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

.....
Bastidas Cashicana Wilson Roberto

C.C. 1804913786

.....
Moya Cabezas Angelo Mauricio

C.C. 1804879789



Universidad
Técnica de
Cotopaxi



Ingeniería
Eléctrica

AVAL DEL TUTOR DE PROYECTO DE INVESTIGACIÓN

En calidad de Tutor del Trabajo de Investigación sobre el título: **“DESARROLLO DE UN SISTEMA DE PREDICCIÓN CON REDES NEURONALES ARTIFICIALES PARA DETERMINAR LA DEMANDA DE ENERGÍA ELÉCTRICA EN UNA CENTRAL HIDROELÉCTRICA”**, Bastidas Cashicana Wilson Roberto y Moya Cabezas Angelo Mauricio, de la carrera de Ingeniería Eléctrica, considero que dicho Informe Investigativo cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos a la evaluación del Tribunal de Validación de Proyecto que el Honorable Consejo Académico de la **Facultad de Ciencias de la Ingeniería y Aplicadas** de la Universidad Técnica de Cotopaxi designe, para su correspondiente estudio y calificación.

Latacunga, marzo 2022

El tutor

Ing. MSc. Jessica Nataly Castillo Fiallos

C.C. 0604590216



APROBACIÓN DEL TRIBUNAL DE TITULACIÓN

En calidad de Tribunal de Lectores, aprueban el presente Informe de Investigación de acuerdo a las disposiciones reglamentarias emitidas por la Universidad Técnica de Cotopaxi, y por la Facultad de Ciencias de la Ingeniería y Aplicadas; por cuanto, los postulantes: **Bastidas Cashicana Wilson Roberto** y **Moya Cabezas Angelo Mauricio** con el título de Proyecto de titulación: **“DESARROLLO DE UN SISTEMA DE PREDICCIÓN CON REDES NEURONALES ARTIFICIALES PARA DETERMINAR LA DEMANDA DE ENERGÍA ELÉCTRICA EN UNA CENTRAL HIDROELÉCTRICA”**, han considerado las recomendaciones emitidas oportunamente y reúnen los méritos suficientes para ser sometidos al acto de Sustentación de Proyecto.

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

Latacunga, marzo 2022

Para constancia firman:

.....
Lector 1 (Presidente)

Nombre: Franklin Hernán Vásquez Teneda

CC: 1710434497

.....
Lector 2

Nombre: Edgar Roberto Salazar Achig

CC: 0502847619

.....
Lector 3

Nombre: Carlos Francisco Pacheco Mena

CC: 0503072902

AGRADECIMIENTO

Este momento es un acontecimiento importante en la vida de cada estudiante, debido a que se muestra el trabajo arduo en toda la etapa universitaria. En primer lugar, agradezco a Dios por los buenos y malos momentos, por mantenerme con buena salud, por tomar buenas decisiones y guiarme por el buen camino, sé que es un buen amigo y nunca me abandonará.

A mi madre María Cashicana que te encuentras en el cielo, debido a ella, fue una de las personas importantes en mi vida que me forjó como una persona humilde, brindándome sus consejos, su cariño y amor, cosas necesarias para continuar esforzándome cada día.

A mi padre Ramón Bastidas por apoyarme moralmente y económicamente, también por inculcarme con valores para ser una mejor persona. Y un agradecimiento especial a mis hermanos y hermanas por brindarme su apoyo incondicional para seguir adelante.

A mi compañero de tesis, gracias a su ayuda y trabajo, se logró culminar nuestra carrera universitaria.

A mi tutora de Tesis la MSc. Jessica Castillo que fue una de las personas que ayudó en el desarrollo del trabajo de investigación, gracias por sus consejos y el apoyo brindado.

Al Ingeniero Roberto Salazar, gracias por su gran ayuda y por ser la persona que con sus directrices logró explicarlos aquellos detalles necesarios para el desarrollo del trabajo de investigación.

A la Universidad Técnica de Cotopaxí, por abrirme las puertas y desarrollar mis estudios de tercer nivel. También un agradecimiento a todos los docentes que, gracias a su esfuerzo y compromiso, contribuyeron de manera extraordinaria en mi formación profesional.

Wilson Roberto Bastidas Cashicana

AGRADECIMIENTO

Agradezco a Dios todopoderoso, porque ha estado conmigo en el trayecto de mi vida, por darme amor, salud, sabiduría y por su inmensa misericordia.

A mi querida madre Elvia Cabezas, pilar fundamental de mi vida, mi gran inspiración para ser mejor cada día, gracias amada madre por tu amor, por tu entrega, por tu lucha diaria, por acompañarme en mis noches de desvelos, por ser mi apoyo incondicional, es para mí un ejemplo de mujer, madre y amiga.

A Danny, por su apoyo incondicional, porque en mi carrera siempre estuvo ahí a mi lado, impulsándome siempre a seguir adelante y jamás abandonar mis sueños, te agradezco por tanta ayuda y tantos aportes no solo para el desarrollo de mi tesis, sino también para mi vida, eres mi inspiración y mi motivación.

A mi tutora de Tesis la MSc. Jessica Castillo que con sus sabios consejos y experiencia nos ha sabido guiar de la mejor manera, para presentar un trabajo de calidad.

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

Al Ingeniero Roberto Salazar, gracias por su disponibilidad, por su apoyo y por el conocimiento transmitido en el desarrollo de mi formación, no solo como profesional sino como persona.

Angelo Mauricio Moya Cabezas

DEDICATORIA

Dedico este proyecto a Dios, por ser mi guía espiritual en este largo camino, gracias a él supere los momentos difíciles y me levante para culminar con éxito.

También a mi padre por sus valiosos consejos, a mi madre que estará conmigo por siempre, fueron las personas que me mostraron el valor de la perseverancia.

A mis hermanos, Fabian, Nelly, Jose, Edison, Erika y como olvidarme de mis sobrinos por el cariño y apoyo que me brindaron en cada etapa de mi vida.

Wilson Roberto Bastidas Cashicana

DEDICATORIA

Dedico este proyecto principalmente a Dios, por darme fuerzas para continuar en situaciones adversas, por brindarme sabiduría, paciencia y ser mi guía en cada paso que doy.

Con mucho amor le dedico el esfuerzo realizado a mi madre, Elvia Cabezas, por depositar su confianza en cada reto que se me presenta sin dudar en ningún momento de mi capacidad, es mi modelo a seguir y probablemente sin ella no hubiese logrado este sueño.

A mi familia en general, que me brindaron su apoyo en esta etapa de mi vida, y por compartir conmigo buenos y malos momentos.

A mis compañeros, Alex, André, David, Fabian, Jordin, Juan, Kevin, que, gracias a su apoyo y conocimiento, hicieron de mi experiencia en la Universidad una de las más especiales, convirtiéndose en amigos para toda la vida.

Angelo Mauricio Moya Cabezas

INDICE GENERAL

DECLARACIÓN DE AUTORÍA	i
AVAL DEL TUTOR DE PROYECTO DE INVESTIGACIÓN	ii
APROBACIÓN DEL TRIBUNAL DE TITULACIÓN.....	iii
AGRADECIMIENTO	iv
AGRADECIMIENTO	v
DEDICATORIA	vi
DEDICATORIA	vii
INDICE GENERAL	viii
INDICE DE FIGURAS	xv
INDICE DE TABLAS	xxi
RESUMEN	xxiii
ABSTRACT	xxiv
AVAL DE TRADUCCIÓN.....	xxv
1. INFORMACIÓN GENERAL.....	1
2. INTRODUCCIÓN	3
2.1. EL PROBLEMA	5
2.1.1. Situación Problémica	5
2.1.2. Formulación del problema	5
2.2. BENEFICIARIOS	5
2.2.1. Directos	5
2.2.2. Indirectos	6
2.3. JUSTIFICACIÓN.....	6
2.4. HIPOTESIS	7
2.5. OBJETIVOS.....	7

2.5.1. General.....	7
2.5.2. Específicos.....	8
2.6. SISTEMA DE TAREAS	8
3. FUNDAMENTACIÓN TEÓRICA	9
3.1. ANTECEDENTES DE LA INVESTIGACIÓN	9
3.2. MARCO TEÓRICO	11
3.2.1. Central hidroeléctrica Illuchi 2	11
3.2.2. Demanda de electricidad.....	14
3.2.2.1. Concepto de la demanda de energía eléctrica	14
3.2.2.2. Tipos de demanda eléctrica.....	15
3.2.3. Centrales hidroeléctricas.....	15
3.2.3.1. Clasificación de las centrales hidroeléctricas.....	15
3.2.3.2. Aprovechamiento del recurso hidráulico	16
3.2.4. Irregularidades del recurso hidráulico	17
3.2.4.1. Irregularidad diaria.....	17
3.2.4.2. Irregularidad estacional.....	17
3.2.4.3. Irregularidad anual	18
3.2.5. Caudal utilizado para la generación de energía eléctrica.....	18
3.2.6. La potencia hidráulica.....	19
3.2.7. Relación entre caudal y potencia	19
3.2.8. La energía eléctrica producida.....	20
3.2.9. Fotogrametría digital (<i>Structure-from Motion</i>)	21
3.2.10. Predicción de la demanda de energía eléctrica	22
3.2.11. Horizonte temporal en la predicción de la demanda de energía eléctrica	24
3.2.11.1. Corto plazo.....	24

3.2.11.2. Mediano plazo.....	24
3.2.11.3. Largo plazo	24
3.2.12. Clasificación de los métodos del pronóstico de la demanda de energía eléctrica	25
3.2.13. Métodos utilizados en la predicción de la demanda de energía eléctrica	25
3.2.14. Categorización de las variables para la predicción de la demanda de energía eléctrica.....	25
3.2.14.1. Inteligencia Artificial	26
3.2.14.2. Machine Learning	26
3.2.14.3. Deep Learning	26
3.2.14.4. Aprendizaje automático	27
3.2.15. Métodos de inteligencia artificial para la predicción de la demanda de energía eléctrica.....	27
3.2.16. Redes neuronales artificiales	28
3.2.16.1. Funcionamiento de las neuronas	28
3.2.16.2. Características principales de una neurona biológica	28
3.2.16.3. Características principales de una red neuronal artificial	29
3.2.16.4. Modelo matemático de la red neuronal artificial	29
3.2.16.5. Células LSTM.....	32
3.2.17. Arquitectura de redes neuronales.....	34
3.2.17.1. Unidad de proceso.....	34
3.2.17.2. Según la estructura de capas	35
3.2.17.3. Según el tipo de respuesta.....	35
3.2.17.4. Según el flujo de los datos	36
3.2.18. Funciones de activación para la aplicación de redes neuronales artificiales	37
3.2.19. Mecanismo de aprendizaje para el uso de redes neuronales artificiales.....	39
3.2.19.1. Aprendizaje supervisado	39

3.2.19.2. Aprendizaje no supervisado	39
3.2.19.3. Aprendizaje por refuerzo	39
3.2.20. Algoritmos de aprendizaje para el uso de redes neuronales artificiales	40
3.2.20.1. Algoritmos de regresión.....	41
3.2.20.2. Algoritmos basados en instancias	41
3.2.20.3. Algoritmos de árbol de decisión.	41
3.2.20.4. Algoritmos bayesianos	41
3.2.20.5. Algoritmos de Clustering (agrupación)	41
3.2.21. Optimizadores de redes neuronales artificiales.	41
3.2.21.1. SGD (Stochastic Gradient Descent).....	42
3.2.21.2. RMSprop (Root Mean Square prop).....	42
3.2.21.3. Adaptive Gradient Algorithm (AdaGrad).....	42
3.2.21.4. Adaptive Adam (Adaptive moment estimation).....	42
3.2.21.5. Adadelta	42
3.2.22. Problemas derivados del entrenamiento en el uso de RNA.....	43
3.2.22.1. Overfitting.....	43
3.2.22.2. Underfitting	43
3.2.22.3. Normal fitting.....	44
3.2.23. Criterios para la validación de los resultados aplicando un método de análisis.....	44
3.2.23.1. Error medio cuadrático (MSE – mean square error).....	44
3.2.23.2. Raíz del Error Medio Cuadrático (Root Mean Squared Error – RMSE).....	44
3.2.23.3. Error Medio Absoluto (Mean Absolute Error MAE)	44
3.2.23.4. Error Medio Absoluto Porcentual (Mean Absolute Percentage Error - MAPE)	45
3.2.23.5. Error residual	45
3.2.23.6. Error estándar múltiple	45
3.2.24. Lenguaje de programación Python versión 3.8.6	45

3.2.24.1. Librería Numpy	46
3.2.24.2. Librería Pandas	46
3.2.24.3. Librería Matplotlib	46
3.2.24.4. Librería Scikit-Learn	46
3.2.24.5. Librería Keras	46
3.2.24.6. Librería Tensorflow	47
4. METODOLOGÍA	48
4.1. TIPO DE INVESTIGACIÓN	48
4.1.1. Investigación descriptiva	48
4.1.2. Investigación diagnóstica	48
4.1.3. Investigación aplicada	49
4.2. MÉTODO DE INVESTIGACIÓN	49
4.2.1. Metodología de la investigación bibliográfica	49
4.2.2. Inductivo – deductivo	49
4.3. TÉCNICAS E INSTRUMENTOS	50
4.3.1. Procedimiento a través de un diagrama de flujo para realizar la predicción de la demanda de energía eléctrica mediante la aplicación de redes neuronales artificiales	50
5. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS	60
5.1. ANÁLISIS DE LA CENTRAL HIDROELÉCTRICA ILLUCHI 2	60
5.2. ANALISIS DE CORRELACIÓN DE LA INFORMACIÓN DE LA CENTRAL HIDROELÉCTRICA ILLUCHI 2	62
5.3. PREPROCESAMIENTO DE LA INFORMACIÓN DE LA CENTRAL HIDROELÉCTRICA ILLUCHI 2	64
5.3.1. Depuración de datos de la central hidroeléctrica Illuchi 2	64
5.3.2. Integración de datos de la CENTRAL HIDROELÉCTRICA ILLUCHI 2	66

5.3.3. Verificación de datos atípicos o nulos de la CENTRAL HIDROELÉCTRICA ILLUCHI 2.....	67
5.4. SELECCIÓN DE LAS VARIABLES DE ENTRADA PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN.....	68
5.5. VALIDACIÓN Y PREPROCESAMIENTO DE DATOS DE ENTRADA PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN.....	68
5.5.1. Desarrollo del algoritmo de predicción en Python	69
5.5.2. Preprocesado de los datos en Python.....	69
5.6. DEFINIR LA ESTRUCTURA DE LA RED NEURONAL ARTIFICIAL PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN.....	71
5.6.1. Estructura de la red neuronal recurrente LSTM	71
5.6.2. Normal fitting	73
5.7. VERIFICACIÓN DE LA RED NEURONAL ARTIFICIAL PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN	74
5.8. ALMACENAMIENTO DE LOS PARAMETROS DE ENTRENAMIENTO DE LA RED NEURONAL RECURRENTE IMPLEMENTADO.....	76
5.9. ANALISIS DE LA VARIACIÓN EN LA ESTRUCTURA DE LA RNA PARA LA PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA	76
5.9.1. Variación del algoritmo de entrenamiento.....	76
5.9.2. Variación del número de neuronas	77
5.9.3. Variación del número de épocas	78
5.10. ANÁLISIS DE RESULTADOS.....	80
5.10.1. Análisis del comportamiento de la demanda de energía eléctrica real de la CENTRAL HIDROELÉCTRICA ILLUCHI 2	80
5.10.2. Análisis del comportamiento de la demanda eléctrica pronosticada.	85
5.10.3. Análisis del comportamiento de la demanda de energía eléctrica pronosticada a los años 2 020 y 2 021.	89

5.11. ANÁLISIS DE LA COMPARACIÓN ENTRE LOS DATOS REALES Y LA DEMANDA PRONOSTICADA	95
5.11.1. Análisis del comportamiento de los errores de la demanda de energía eléctrica pronosticada en el año 2 019 para determinar la confiabilidad y validación del programa realizado en Python.	99
5.11.2. Análisis para la comparación entre la base de datos depurados y los datos pronosticados a los años 2 020 y 2 021	102
5.12. DESARROLLO DE LA INTERFAZ GRÁFICA	105
5.12.1. Módulo de datos históricos	107
5.12.2. Módulo de entrenamiento de la red	109
5.12.3. Módulo de la predicción de la demanda	110
6. IMPACTOS	112
6.1. Impactos técnicos	112
6.2. Impactos sociales.....	112
6.3. Impactos ambientales	112
6.4. Impactos económicos	112
7. CONCLUSIONES Y RECOMENDACIONES	113
7.1. CONCLUSIONES.....	113
7.2. RECOMENDACIONES	115
8. BIBLIOGRAFÍA	116

INDICE DE FIGURAS

Figura 2.1: Uso de Python a nivel mundial aplicado en los últimos cinco años, respecto a otros lenguajes	6
Figura 3.1: Ubicación geográfica de la casa de máquinas perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2	12
Figura 3.2: Ubicación geográfica del tanque de la CENTRAL HIDROELÉCTRICA ILLUCHI 2	12
Figura 3.3: Curva de la demanda de energía eléctrica en el mes de Enero del 2 016	14
Figura 3.4: Tipos de demanda eléctrica	15
Figura 3.5: Partes principales que compone una central hidroeléctrica aprovechando el recurso hidráulico	17
Figura 3.6: Representación gráfica de los comportamientos del estiaje en el transcurso del tiempo	18
Figura 3.7: Tanque de captación perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2	18
Figura 3.8: Relación entre caudal y potencia para verificar el rendimiento del sistema con diferentes caudales.....	20
Figura 3.9: Posiciones de cámara, orientación, longitudes focales y posiciones relativas para la evaluación del área de estudio	21
Figura 3.10: Representación gráfica utilizando la fotogrametría digital.....	22
Figura 3.11: Campos de aplicación que utilizan las técnicas de predicción mediante redes neuronales artificiales	23
Figura 3.12: Parámetros que indican en la predicción de la demanda para emplearlos en el modelo de red neuronal artificial.....	25
Figura 3.13: Categorización de la variable de estudio para la predicción de la demanda de energía eléctrica.....	26
Figura 3.14: Clasificación relacionado a los métodos de inteligencia artificial empleados en la predicción de la demanda de energía eléctrica	27

Figura 3.15: Estructura general de una neurona biológica.....	28
Figura 3.16: Estructura general de una red neuronal artificial	29
Figura 3.17: Esquema de una red neuronal artificial	31
Figura 3.18: Estructura interna de una célula LSTM	32
Figura 3.19: Red multicapa aplicando la propagación hacia adelante	36
Figura 3.20: Red multicapa aplicando la propagación hacia atrás	37
Figura 3.21: Clasificación de algoritmos para el uso de redes neuronales artificiales.....	40
Figura 4.1: Flujograma metodológico empleado para la predicción de la demanda de la energía eléctrica utilizando redes neuronales artificiales	50
Figura 4.2: Tubería de presión perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2	51
Figura 4.3. Tubería de presión perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2 [15]	52
Figura 4.4: Comportamiento de la demanda de energía eléctrica procedente de una base de datos.....	52
Figura 4.5: Validación y preprocesamiento de la información procedente de una base de datos	54
Figura 4.6: Flujograma del algoritmo utilizado para la predicción de la demanda eléctrica ..	55
Figura 4.7: Pseudocódigo elaborado para el desarrollo de un modelo de predicción de la demanda de energía eléctrica.....	56
Figura 4.8: Modelo para el entrenamiento de la red neuronal recurrente implementado	57
Figura 4.9: Partición de los datos en subconjuntos para la predicción de la demanda eléctrica	58
Figura 4.10: Función de pérdida y el error medio absoluto para validar los entrenamientos de la RNA.....	58
Figura 4.11: Propuesta de la interfaz gráfica para la predicción de la demanda de energía eléctrica.....	59

Figura 5.1: Análisis de la demanda de energía eléctrica por un periodo de un año.....	60
Figura 5.2: Análisis de la demanda de energía eléctrica mensual por un periodo de 5 años ..	61
Figura 5.3: Comportamiento de la demanda de energía eléctrica en el generador 1	62
Figura 5.4: Comportamiento de la demanda de energía eléctrica en el generador 2	62
Figura 5.5: Información relevante de las variables para la predicción de la demanda de energía eléctrica.....	63
Figura 5.6: Mapa de calor para verificar la correlación entre las variables de entrada.....	63
Figura 5.7: Secuencia de pasos a seguir para el preprocesamiento de la información procedente de una base de datos	64
Figura 5.8: Muestra de la base de datos del proceso de generación de la CENTRAL HIDROELÉCTRICA ILLUCHI 2 en enero del año 2 016	65
Figura 5.9: Parte de la base de datos después de filtrar los datos que fueron innecesarios	66
Figura 5.10: Integración de la información hacia una nueva base de datos.....	66
Figura 5.11: Base de datos que contienen valores incoherentes con respecto a la demanda de energía eléctrica.....	67
Figura 5.12: Aplicación de las librerías de Python para implementar el algoritmo de predicción	69
Figura 5.13: Estructura del pseudocódigo para el preprocesamiento de datos	70
Figura 5.14: Datos creados por el nuevo Dataframe para la implementación del algoritmo de predicción	70
Figura 5.15: Estructura para el preprocesamiento de los datos finales	71
Figura 5.16: Estructura del pseudocódigo MinMaxScaler para la normalización de los datos e implementar el algoritmo de predicción.....	72
Figura 5.17: Estructura de la red neuronal artificial implementado en el algoritmo de predicción	73
Figura 5.18: Optimizadores utilizados para los entrenamientos de la red neuronal recurrente implementado	74

Figura 5.19: Histograma de error mostrados en los entrenamientos de la red neuronal recurrente implementado	75
Figura 5.20: Estructura de la red neuronal LSTM al aplicar 10 épocas (entrenamientos) con una muestra de datos	75
Figura 5.21: Almacenamiento de entrenamientos en formato jerárquico h5	76
Figura 5.22: Comportamiento de la predicción de la demanda de energía eléctrica aplicando diferentes optimizadores.....	77
Figura 5.23: Comportamiento de la predicción de la demanda de energía eléctrica dependiendo del número de neuronas.....	78
Figura 5.24: Comportamiento de la predicción de la demanda de energía eléctrica aplicando varios epoch (épocas)	79
Figura 5.25: Variación del comportamiento de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana.....	80
Figura 5.26: Desviación estándar aplicando los datos reales de la demanda de energía eléctrica	82
Figura 5.27: Comportamiento de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana	82
Figura 5.28: Visualización de las capacidades del proceso para la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana.....	83
Figura 5.29: Comportamiento de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 día	84
Figura 5.30: Capacidades del proceso para la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 día	85
Figura 5.31: Comportamiento de la demanda de energía eléctrica analizando los datos pronosticados en un intervalo de 1 semana	86
Figura 5.32: Desviación estándar aplicando los datos pronosticados de la demanda de energía eléctrica.....	87

Figura 5.33: Capacidades del proceso para la demanda de energía eléctrica analizando los datos pronosticados en el intervalo de 1 semana	88
Figura 5.34: Comportamiento de la demanda de energía eléctrica analizando los datos pronosticados en un intervalo de 1 día	88
Figura 5.35: Capacidades del proceso para la demanda de energía eléctrica analizando los datos pronosticados en el intervalo de 1 día	89
Figura 5.36: Comportamiento de la curva de la demanda eléctrica pronosticada para el año 2020	90
Figura 5.37: Desviación estándar utilizado en el análisis de la demanda de energía eléctrica pronosticada para el año 2020	91
Figura 5.38: Capacidades del proceso para la demanda de energía eléctrica analizando los datos pronosticados para el año 2020	92
Figura 5.39: Comportamiento de la curva de la demanda eléctrica pronosticada para el año 2021	92
Figura 5.40: Desviación estándar para el análisis de la demanda de energía eléctrica para el año 2021	94
Figura 5.41: Capacidades del proceso para la demanda de energía eléctrica pronosticada para el año 2021	95
Figura 5.42: Comportamiento de la demanda de energía eléctrica real vs pronosticado analizando los datos en un intervalo de 1 semana	96
Figura 5.43: Gráfica de error entre demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 semana	96
Figura 5.44: Intervalos que presenta la demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 semana	97
Figura 5.45: Curva demanda eléctrica real vs pronosticada analizando los datos en el intervalo de 1 día	97
Figura 5.46: Gráfica de error entre demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 día	98

Figura 5.47: Intervalos que presenta la demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 día	99
Figura 5.48: Comportamiento de la demanda de energía eléctrica mediante regresión lineal	100
Figura 5.49: Comportamiento de la demanda de energía eléctrica mediante Python	100
Figura 5.50: Comportamiento de la demanda de energía eléctrica mediante Python	101
Figura 5.51: Comportamiento de la demanda de energía eléctrica para su validación.....	102
Figura 5.52: Comportamiento de la demanda de energía eléctrica real desde el año 2 015 hasta el año 2 019	103
Figura 5.53: Comportamiento de la demanda de energía eléctrica pronosticada de los años 2 020 y 2 021	103
Figura 5.54: Intervalos que presenta la demanda de energía eléctrica pronosticada en los años 2 020 y 2 021	104
Figura 5.55: Comportamiento de la demanda de energía eléctrica desde el año 2 015 hasta el año 2 021	104
Figura 5.56: Visualización del menú principal de la interfaz gráfica diseñada	106
Figura 5.57: Visualización de la interfaz completa.....	107
Figura 5.58: Interfaz para el análisis de la predicción de la demanda de energía eléctrica ..	108
Figura 5.59: Módulo de datos históricos representando la curva de la demanda.....	108
Figura 5.60: Interfaz para el entrenamiento de la predicción de la demanda de energía eléctrica	109
Figura 5.61: Interfaz para el entrenamiento de la predicción de la demanda de energía eléctrica	110
Figura 5.62: Módulo para la predicción de la demanda de energía eléctrica.....	111
Figura 5.63: Módulo para la predicción de la demanda de energía eléctrica.....	111

INDICE DE TABLAS

Tabla 2.1: Sistema de tareas en relación a los objetivos planteados	8
Tabla 3.1: Capacidades de las diferentes centrales hidroeléctricas pertenecientes a ELEPCO	11
Tabla 3.2: Coordenadas de la casa de máquinas y del tanque de captación de la CENTRAL HIDROELÉCTRICA ILLUCHI 2	12
Tabla 3.3: Datos de los equipos que conforma la central HIDROELÉCTRICA ILLUCHI 2	13
Tabla 3.4: Funciones de activación para la aplicación de redes neuronales artificiales.....	37
Tabla 4.1: Selección preliminar de las variables para la predicción de la demanda de energía eléctrica.....	53
Tabla 5.1: Selección final de las variables de entrada para la predicción de la demanda de energía eléctrica.....	68
Tabla 5.2: Resultados obtenidos aplicando diferentes tipos de optimizadores para la predicción de la demanda de energía eléctrica	77
Tabla 5.3: Resultados del error MAE con la variación de neuronas para la predicción de la demanda de energía	78
Tabla 5.4: Resultados derivados de la variación del número de épocas para la predicción de la demanda de energía eléctrica.....	79
Tabla 5.5: Análisis descriptivo de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana	81
Tabla 5.6: Análisis descriptivo de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana	86
Tabla 5.7: Análisis descriptivo de la demanda de energía eléctrica pronosticada para el año 2020	90
Tabla 5.8: Análisis descriptivo de la demanda de energía eléctrica pronosticada para el año 2021	93

Tabla 5.9: Valor del error promedio entre la demanda de energía eléctrica real y la pronosticada	96
Tabla 5.10: Valor del error promedio entre la demanda eléctrica real y la pronosticada.....	98
Tabla 5.11: Análisis descriptivo de la demanda de energía eléctrica real y pronosticada desde el año 2 015 hasta el año 2 021.....	105

UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

TITULO: “DESARROLLO DE UN SISTEMA DE PREDICCIÓN CON REDES NEURONALES ARTIFICIALES PARA DETERMINAR LA DEMANDA DE ENERGÍA ELÉCTRICA EN UNA CENTRAL HIDROELÉCTRICA”

Autor/es: Bastidas Cashicana Wilson Roberto
Moya Cabezas Angelo Mauricio

RESUMEN

La predicción de eventos ha sido desde la antigüedad, un fenómeno capaz de generar curiosidad en los seres humanos, sin embargo, para lograr una proyección de un suceso futuro se requiere un detallado análisis de datos para lograr predecir eventos posteriores, con esta idea, el objetivo de la investigación fue desarrollar un sistema de predicción aplicando redes neuronales artificiales para determinar la demanda de energía eléctrica pronosticada en la CENTRAL HIDROELÉCTRICA ILLUCHI 2. Los datos utilizados para este estudio fueron recopilados por los operarios de ELEPCO S.A que están basados entre los años 2 010 hasta el año 2 019. Se plantearon las variables de entradas que fueron fecha y energía consumida para elaborar diferentes casos con diversas condiciones con el propósito de alcanzar un acertado modelo de red neuronal recurrente (Long Short Term Memory) posible. Una vez comprendidas las variables del modelo, los datos se dividieron en dos grupos: entrenamiento 80 % y validación 20 % respectivamente. Para los pertinentes entrenamientos se utilizó el algoritmo de RMSprop y las librerías que ofrece Python 3.8.6. A partir de los datos de la demanda de energía eléctrica del último periodo del mes de enero del año 2 019 a la semana siguiente del mes de febrero del mismo año, que corresponden a 8 días, se puede afirmar que el modelo planteado, presenta el mayor ajuste al comportamiento de la serie de datos con un error medio absoluto (MAE) del 0,0352 y error porcentual absoluto medio (MAPE) es de 3 % de esta forma validando y utilizando los resultados para predecir la demanda de energía eléctrica para el año 2 020 y 2 021. Para futuros estudios se recomienda realizar el mismo estudio aplicando otros programas computacionales utilizados para el análisis de datos.

Palabras clave: *Demanda de energía eléctrica, central hidroeléctrica, redes neuronales artificiales.*

COTOPAXI TECHNICAL UNIVERSITY

ENGINEERING AND APPLIED SCIENCES FACULTY

TOPIC: " A PREDICTION SYSTEM DEVELOPMENT WITH ARTIFICIAL NEURAL NETWORKS TO DETERMINE THE ELECTRICAL ENERGY DEMAND IN EACH HYDROELECTRIC PLANT, LOCATED IN THE LATACUNGA CITY IN THE YEAR 2021".

Author/s: Bastidas Cashicana Wilson Roberto

Moya Cabezas Angelo Mauricio

ABSTRACT

The event prediction has been, since ancient times, a capable phenomenon of generating curiosity into human beings, however, to achieve a future event projection, it is required a data detailed analysis to predict subsequent events, with this idea, the research aim was to develop a prediction system by applying artificial neural networks for determining the electrical energy predicted demand at the ILLUCHI 2 HYDROELECTRIC POWER PLANT. The used data for this study was collected by the ELEPCO SA operators, which are found between the years 2010 and the year 2019. It was proposed input variables, what were consumed date and energy to elaborate different cases with different conditions, with the purpose to achieve a successful recurrent neural network model (Long Short-Term Memory) possible. Once, it understood the model variables, the data were divided into two groups: training 80% and validation 20%, respectively. For the relevant training, it was used the RMSprop algorithm and the libraries offered by Python 3.8.6. Since, the electrical energy demand data from year 2019 January month last period, to the following week of same year February month, what correspond to 8 days, it can be affirmed that the proposed model presents the best fit to the data serie behavior with 0.0352 of mean absolute error (MAE) and mean absolute percentage error (MAPE) is 3%, this way validating and using the results to predict the electrical energy demand for the years 2020 and 2021. For future studies, it is recommended to make same study by applying used other computer programs for data analysis.

Keywords: *Electric power demand, hydroelectric power plant, artificial neural networks.*

AVAL DE TRADUCCIÓN

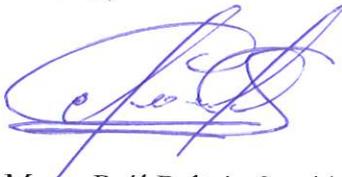
En calidad de Docente del Idioma Inglés del Centro de Idiomas de la Universidad Técnica de Cotopaxi; en forma legal **CERTIFICO** que:

La traducción del resumen al idioma Inglés del trabajo de titulación cuyo título versa: **“DESARROLLO DE UN SISTEMA DE PREDICCIÓN CON REDES NEURONALES ARTIFICIALES PARA DETERMINAR LA DEMANDA DE ENERGÍA ELÉCTRICA EN UNA CENTRAL HIDROELÉCTRICA UBICADA EN LA CIUDAD DE LATACUNGA EN EL AÑO 2021”**, presentado por: **Bastidas Cashicana Wilson Roberto** y **Moya Cabezas Angelo Mauricio**, estudiantes de la Carrera de **Ingeniería Eléctrica** perteneciente a la **Facultad de Ciencias de la Ingeniería y Aplicadas** lo realizaron bajo mi supervisión y cumple con una correcta estructura gramatical del Idioma.

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

Latacunga, 23 marzo del 2022

Atentamente,



Mg. Marco Paúl Beltrán Semblantes

DOCENTE CENTRO DE IDIOMAS-UTC
CI: 0502666514

1. INFORMACIÓN GENERAL

Título: Desarrollo de un sistema de predicción con redes neuronales artificiales para determinar la demanda de energía eléctrica en una central hidroeléctrica

Fecha de inicio: 25 octubre de 2021

Fecha de finalización: 25 febrero de 2022

Lugar de ejecución: Provincia de Cotopaxi, cantón Latacunga

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

Carrera que auspicia: Carrera de Ingeniería en Electricidad.

Proyecto de investigación vinculado: Desarrollo de sistemas para el abastecimiento y uso del servicio de energía eléctrica a nivel local, regional o nacional.

Equipo de Trabajo:

Grupo de Investigación de Sistemas Eléctricos de Potencia

- **Tutor de Titulación:**

Nombre y Apellidos: Ing. MSc. Jessica Nataly Castillo Fiallos

Lugar y fecha de Nacimiento: Riobamba 30 de abril de 1988

Estado civil: Soltera

Cédula de Ciudadanía: 060459021-6

E-mail: jessica.castillo@utc.edu.ec

- **Estudiante/s:**

Estudiante 1

Nombres: Wilson Roberto

Apellidos: Bastidas Cashicana

Cédula de Ciudadanía: 180491378-6

E-mail: wilson.bastidas3786@utc.edu.ec

Estudiante 2

Nombres: Angelo Mauricio

Apellidos: Moya Cabezas

Cédula de Ciudadanía: 180487978-9

E-mail: angelo.moya9789@utc.edu.ec

Área de Conocimiento: 07 Ingeniería, Industria y Construcción / 071 Ingeniería y Profesiones Afines / 0713 Electricidad y Energía.

Línea de investigación: Energías Alternativas y Renovables, Eficiencia Energética y Protección Ambiental.

Sublíneas de investigación de la Carrera: Inteligencia Artificial y Modelación de Sistemas.

2. INTRODUCCIÓN

En el presente documento se desarrollará la predicción de la demanda de energía eléctrica que se produce en la CENTRAL HIDROELÉCTRICA ILLUCHI 2, que pertenece a ELEPCO S.A. (Empresa Eléctrica Provincial de Cotopaxi S.A.), realizando un diagnóstico integral de la central, desde su tanque de reserva en donde interviene el agua, un recurso con amplia disponibilidad tomado desde un afluente que pueda abastecer el caudal mínimo necesario que requiera el sistema, hasta el proceso de generación y consumo.

La predicción de eventos ha sido desde la antigüedad un fenómeno capaz de generar obsesión en los seres humanos, sin embargo, para lograr una proyección de un suceso futuro se requiere de un detallado análisis en base a datos, eventos pasados, e información existente para lograr predecir eventos futuros. Ahora bien, la incertidumbre por conocer la evolución de la demanda de energía eléctrica a corto plazo, es sustancial para la planificación y modificación de la estructura del sistema eléctrico, pero la falta de información en este tipo de investigación, ha surgido la necesidad de buscar nuevos procesos que ayuden a obtener predicciones con niveles de errores mínimos y relacionados a los datos reales [1], [2], [3].

La previsión de la demanda de energía eléctrica es fundamental para contar con una confiable y económica operación del sistema eléctrico, procesos que son realizados por el Centro Nacional de Control de Energía (CENACE). Pero los diversos datos que se pretenden predecir se deben aplicar técnicas de aprendizaje automático, esta técnica ha sido utilizada ampliamente para resolver problemas complicados en diversas disciplinas [4].

Los modelos basados en el aprendizaje automático logran una alta precisión y eficiencia utilizando el enfoque de las redes neuronales artificiales. Por ello es necesario mencionar algunas investigaciones previas relacionadas al tema [5]:

Los autores proponen el pronóstico de carga a corto plazo usando el método de media móvil integrado autorregresivo (ARIMA) y red neuronal artificial (RNA) basado en carga no lineal. Este método de pronóstico utilizando redes neuronales artificiales, basado en el algoritmo de propagación de retroalimentación. Esta investigación tiene como objetivo desarrollar un pronóstico de carga a medio plazo para el pronóstico de la demanda de consumo de energía anual. Mientras tanto los autores proponen un método de selección de características híbridas basado en aprendizaje automático para obtener las características más relevantes y no redundantes para una adecuada previsión a corto plazo de la demanda de electricidad en

sistemas de energía descentralizados, el objetivo de esta investigación es proponer e implementar un enfoque de selección de características para modelar y pronosticar la demanda de electricidad fluctuante en los sistemas de energía descentralizados en general y los edificios en particular [6], [7].

En la investigación de los autores, el algoritmo de entrenamiento utilizado para la comparación es el modelo de red neuronal *Feedforward Backpropagation*, son *trainlm*, *traingdx* y *trainbfg*. En donde se muestra los entrenamientos con diferentes algoritmos, en este caso se realizó con 3 algoritmos para encontrar la precisión más óptima para luego sea utilizado en la predicción y lograr obtener datos relevantes sobre el consumo de carga mensual [8].

En este subapartado se presenta de manera resumida la estructura y el contenido de cada una de las partes del trabajo de investigación. La estructura está conformada de 6 capítulos, con el fin de guiar al lector a través de los diferentes contenidos:

En el capítulo 1: Se presenta la información detallada del tema propuesto, el lugar de ejecución y los integrantes que conforman el equipo de investigación.

En el capítulo 2: Se aborda la introducción, el problema, beneficiarios, justificación, hipótesis, objetivos y un sistema de tareas.

En el capítulo 3: Se introduce la fundamentación teórica, este es un capítulo necesario para poder comprender todos los conceptos relacionados con la demanda de energía eléctrica y la aplicación de redes neuronales artificiales.

En el capítulo 4: Se describe la metodología utilizada para preparar los datos a ser aplicados en el modelo de predicción propuesto. Se describen las fases de programación, funciones de activación, algoritmos y optimizadores utilizados. Gran parte del desempeño en el trabajo de investigación se encuentra reflejado en este capítulo.

En el capítulo 5: Se presentan los resultados obtenidos durante las diferentes fases de este trabajo y se valora la metodología utilizada, con el propósito de cumplir con los objetivos planteados.

En el capítulo 6: Se finaliza con las respectivas conclusiones y recomendaciones que surgieron durante el desarrollo de nuestra investigación.

2.1. EL PROBLEMA

2.1.1. Situación Problemática

En el sector eléctrico se ha generado una cuestión que ha suscitado mayor interés a lo largo de las últimas décadas, se trata de conocer la demanda de energía eléctrica que se dará en el corto, mediano y largo plazo, creando la necesidad de obtener datos satisfactorios. Estas predicciones asumen importantes resultados económicos y técnicas referentes a la operación del sistema eléctrico nacional.

Al aplicar redes neuronales artificiales como modelos de aproximación de funciones son útiles para varias aplicaciones, pero estos modelos tienen un problema que está relacionado con la precisión de los resultados que se pretenden pronosticarlos y generar excelentes resultados. Para poder lograr que una red neuronal artificial pueda realizar las funciones deseadas debe ser entrenada mediante proceso de pruebas y errores, con el proceso mencionado anteriormente se puede conseguir que la red neuronal logre aprender, alcanzando un modelo capaz de obtener resultados muy acertados incluso con datos diferentes a los que se han utilizado en sus entrenamientos, logrando una red más óptima.

Al momento de no poder predecir la demanda de energía eléctrica de manera correcta se producen pérdidas económicas hacia la empresa distribuidora, debido a que deberá consumir o producir la energía eléctrica de manera abrupta y en consecuencia afecte a los elementos de la subestación más cercana, perdiendo confiabilidad en el sistema eléctrico de distribución.

2.1.2. Formulación del problema

Determinación de los parámetros que inciden en el desarrollo de redes neuronales artificiales para predicción de la demanda en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

2.2. BENEFICIARIOS

2.2.1. Directos

Los beneficiarios directos de la investigación son los estudiantes de la carrera de Ingeniería Eléctrica o carreras afines de la Universidad Técnica de Cotopaxi y la Empresa Eléctrica Provincial de Cotopaxi S.A. (ELEPCO S.A.), debido a que ayudará a tener una acertada comprensión sobre la predicción de la demanda de energía eléctrica mediante la aplicación de redes neuronales artificiales.

2.2.2. Indirectos

Los beneficiarios indirectos son todas las personas que se involucren en el desarrollo de estudios y algoritmos para la predicción relacionado con la demanda de energía eléctrica.

2.3. JUSTIFICACIÓN

La demanda de energía eléctrica es una de las funciones relevantes para responder a una planificación eficiente y coherente, para lograr abastecer las necesidades de la población requeridas en la actual, mediano, corto y a largo plazo, mediante la realización del pronóstico de la demanda eléctrica, de esta forma se permite dimensionar y diseñar políticas, referentes a la generación, transmisión y distribución eléctrica, que tengan la capacidad de cumplir los criterios de seguridad, flexibilidad y confiabilidad en el sector eléctrico [4].

Debido a que existen problemas al momento de realizar la predicción de la demanda de energía eléctrica es necesario ejecutar actividades que ayuden a resolverlos o disminuir los problemas de generación y operación pueden que generan incertidumbre hacia las empresas eléctricas suministradoras.

En relación a la problemática expuesta, se plantea la utilización de técnicas de aprendizaje automático enfocado al desarrollo de estudios en base a Inteligencia Artificial y/o Machine Learning. Se presentan varias alternativas en relación a los lenguajes de programación, cada uno de ellos con diferentes características y algunos que podrían resultar mejores que otros, eso dependerá del tipo de aplicación [9].

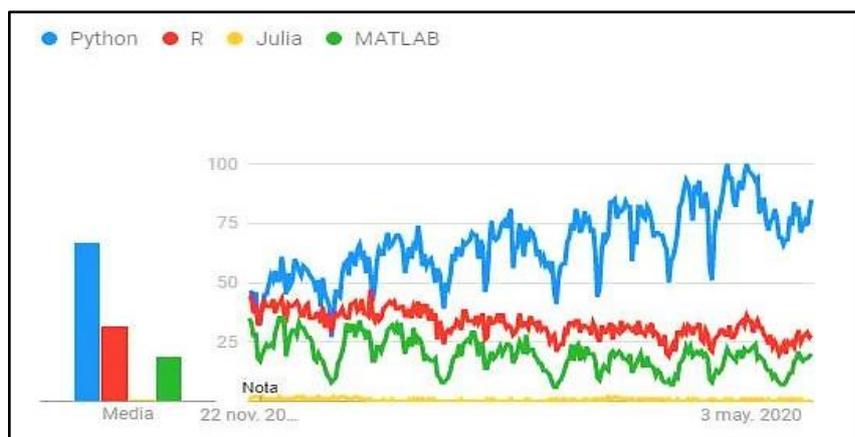


Figura 2.1: Uso de Python a nivel mundial aplicado en los últimos cinco años, respecto a otros lenguajes [9]

Para la implementación del trabajo de investigación se aplicó el uso de Python, la cual es un lenguaje de programación multiplataforma, de propósito general y que se distribuye bajo una licencia libre, además como se puede observar en la figura 2.1, Python ha logrado mantenerse en constante crecimiento en los últimos años, esto debido a su simplicidad, desarrollo de aplicaciones de distinto propósito y la amplia comunidad que aporta continuamente [10].

Como primer criterio de selección y con propósitos de definir una comparación justa y adecuada para cada lenguaje, se basa en la figura 2.1, donde se puede observar la variación por el interés de la variedad de lenguajes de programación a través de los últimos 5 años, en donde, Python se posiciona como el líder en comparación a otros programas computacionales. Además, se debe tomar en consideración que la velocidad y precisión al momento de obtener resultados dependerá de las librerías y optimizadores que se añadan a la red neuronal artificial.

Tomando en cuenta las razones antes mencionadas se sugiere implementar un sistema predictivo aplicando redes neuronales artificiales que ayude a conocer con precisión el consumo de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2, esto es un aporte prometedor debido a que es necesario prever la evolución de la demanda para continuar garantizando la cobertura del servicio hacia los usuarios finales.

Finalmente se puede mencionar que el alcance del presente proyecto de investigación está orientado a desarrollar un modelo predictivo de la demanda de energía eléctrica con el fin de ayudar en la programación de energía a producir y los mantenimientos necesarios para el funcionamiento permanente de la CENTRAL HIDROELÉCTRICA ILLUCHI 2 mediante la aplicación de redes neuronales artificiales.

2.4. HIPOTESIS

¿El desarrollo de una red neuronal en Python, permitirá predecir la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2?

2.5. OBJETIVOS

2.5.1. General

Desarrollar un sistema de predicción con redes neuronales artificiales en Python para determinar la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

2.5.2. Específicos

- Elaborar el estado del arte para el desarrollo de algoritmos utilizados en la predicción de la demanda de energía eléctrica en centrales hidroeléctricas.
- Determinar los parámetros para desarrollar el algoritmo a implementar en la red neuronal artificial.
- Entrenar la red neuronal para determinar la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.
- Validar los datos obtenidos de la red neuronal artificial.

2.6.SISTEMA DE TAREAS

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

Objetivos específicos	Actividad (tareas)	Resultados Esperados	Técnicas, Medios e Instrumentos
Elaborar el estado del arte para el desarrollo de algoritmos utilizados en la predicción de la demanda de energía eléctrica en centrales hidroeléctricas.	<ul style="list-style-type: none"> • Búsqueda de información en obras colectivas y medios digitales referente a la predicción de la demanda de energía eléctrica. • Investigación de los conocimientos básicos de la demanda de energía eléctrica. • Análisis de artículos científicos dedicados al estudio de la predicción de la demanda de energía eléctrica utilizando redes neuronales artificiales. 	<ul style="list-style-type: none"> • Fundamentación teórica y comparación de los distintos métodos de predicción de la demanda de energía eléctrica. • Fundamentación teórica técnica para el desarrollo de la programación en Python. • Metodología para el correcto diseño de la herramienta computacional de predicción de la demanda de energía eléctrica. 	<ul style="list-style-type: none"> • Libros • Tesis • Artículos científicos • Trabajos académicos • Revistas Científicas • Normativas • Informes técnicos

Objetivos específicos	Actividad (tareas)	Resultados Esperados	Técnicas, Medios e Instrumentos
Determinar los parámetros para desarrollar el algoritmo a implementar en la red neuronal artificial.	<ul style="list-style-type: none"> • Estudio de aspectos eficaces del programa computacional Python referentes a redes neuronales artificiales. • Recopilación de datos históricos de la predicción de la demanda de energía eléctrica en una central hidroeléctrica, y obtención de datos de campo. • Análisis y comprensión de la base de datos. • Preprocesamiento de la base de datos. 	<ul style="list-style-type: none"> • Red neuronal para la aplicación específica • Gráficas de datos históricos realizadas en Python. • Gráficas de predicción de la demanda para el periodo especificado realizadas en Python. • Tablas de resultados de las predicciones de la demanda futura en formato Excel. 	<ul style="list-style-type: none"> •Python •Redes Neuronales •Datos Históricos •Fotogrametría
Entrenar la red neuronal para determinar la demanda de energía eléctrica en la central hidroeléctrica Illuchi 2.	<ul style="list-style-type: none"> • Programación de la red neuronal en lenguaje de programación Python. • Programación de una interfaz en el programa de predicción de la demanda de energía eléctrica. • Análisis de los resultados obtenidos en la aplicación. 	<ul style="list-style-type: none"> • Interfaz gráfica amigable de la aplicación. • Predicción de la producción de energía eléctrica. 	<ul style="list-style-type: none"> • Datos históricos y datos nuevos no utilizados en el entrenamiento de la demanda de energía eléctrica en una central hidroeléctrica.
Validar los datos obtenidos de la red neuronal artificial.	<ul style="list-style-type: none"> • Entrenamiento de la red neurona artificial. • Análisis de los resultados obtenidos en la aplicación 	<ul style="list-style-type: none"> • Predicción de la demanda de energía eléctrica. • Verificación de errores. 	<ul style="list-style-type: none"> • Datos históricos • Datos obtenidos en los entrenamientos de la demanda de energía eléctrica en una central hidroeléctrica.

3. FUNDAMENTACIÓN TEÓRICA

3.1. ANTECEDENTES DE LA INVESTIGACIÓN

Los estudios relacionados con la demanda de energía eléctrica son de gran importancia y eso se refleja en la variedad de estudios relacionados al trabajo de investigación, si bien es conocido que la demanda tiene una característica no lineal, debido a su comportamiento variado, esto incita a más investigadores a cambiar su metodología y de esta forma conseguir mejores resultados, tal como se muestra en la investigación titulado “Modelo de predicción de la

producción de energía eléctrica en la central hidroeléctrica Coca Codo Sinclair mediante la aplicación de técnicas de aprendizaje computacional” donde se implementa un modelo de predicción relacionado con la producción de energía eléctrica mediante la aplicación de técnicas de aprendizaje computacional, mejorando el aprovechamiento del recurso hídrico proveniente del río Coca. Se identifica el uso de técnicas y modelos basados en Machine Learning, concretamente se utiliza modelos de redes neuronales artificiales, para obtener mejores resultados en comparación a diferentes técnicas tradicionales como: Regresión Lineal, ARIMA, etc., utilizados en la predicción de caudal y otros fenómenos estocásticos. De esta forma se plantea diseñar un modelo para definir la cantidad de energía eléctrica a producirse con base a los caudales pronosticados [11].

Sin embargo, en su investigación titulada “A multi-time-scale power prediction modelo of hydropower station considering multiple uncertainties” proponen un modelo de predicción de energía a múltiples escalas de tiempo de una central hidroeléctrica. El modelo va a realizar predicciones de energía basada en la probabilidad de una central hidroeléctrica considerando varias incertidumbres con la aplicación de redes bayesianas dinámicas. Lo interesante de aplicar redes bayesianas dinámicas (DBN) radica en las siguientes ventajas [12]:

- Utiliza un gráfico dirigido para describir las relaciones complejas entre las variables estocásticas, que es fácil de entender para poder tomar decisiones.
- Tiene una capacidad de inferencias bidireccionales, que no está disponible en la mayoría de los modelos tradicionales de inferencia basados en probabilidades.

También existen otros métodos, en su investigación “Forecasting the evolution of hydropower generation” presentan un nuevo modelo de redes neuronales recurrentes latentes condicionados denominado DeepHydro, para predecir la generación de energía de centrales hidroeléctricas a gran escala. Para permitir el modelado y el pronóstico DeepHydro maneja explícitamente la dependencia temporal entre variables estocásticas, de esta manera obtener representaciones precisas y robustas de series de tiempo multivariadas correspondientes a datos de generación de energía [13].

Todos estos estudios mencionados anteriormente son algunos ejemplos de estudios realizados aplicando diferentes tipos de redes neuronales artificiales, reconociendo la variedad de investigaciones que se pueden desarrollarse.

3.2. MARCO TEÓRICO

Para desarrollar el presente trabajo de investigación y brindar una solución al problema del pronóstico de la demanda de la energía eléctrica, es necesario recopilar la información necesaria para conocer diferentes conceptos de la demanda de la energía eléctrica y redes neuronales artificiales.

3.2.1. Central hidroeléctrica Illuchi 2

La Empresa Eléctrica Provincial de Cotopaxi S.A (ELEPCO S.A) es la institución que está encargada de generar y distribuir la energía eléctrica hacia las zonas rurales y urbanas de los cantones: Pangua, La Maná, Pujilí, Sigchos, Latacunga, Saquisilí y Salcedo ubicados en la Provincia de Cotopaxi. En la tabla 3.1, se presenta las capacidades de generación eléctrica de las diferentes centrales hidroeléctricas que continúan en operación [14].

Tabla 3.1: Capacidades de las diferentes centrales hidroeléctricas pertenecientes a ELEPCO [14]

Central hidroeléctrica	Capacidad (MVA)
Illuchi N.º 1	5,24
Illuchi N.º 2	6,50
El estado	2,12
Catazación	1,00
Angamarca	0,38

La CENTRAL HIDROELÉCTRICA ILLUCHI 2 se encuentra ubicada en la provincia de Cotopaxi. El agua que se utiliza para la generación de energía eléctrica es proveniente del Río Illuchi. El área del proyecto tiene una zona perfectamente definida desde el punto de vista hidroenergético, además coincide con las condiciones fisiográficas, climatológicas e hidrológicas; situada al este de la ciudad de Latacunga, concretamente al oriente de la Cordillera de los Andes, que a su vez es conocido como el Callejón Interandino [15]. En la tabla 3.2, se presenta las coordenadas de la ubicación exacta de la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

En las figuras 3.1 y 3.2, se presenta la ubicación geográfica tanto de la casa de máquinas como del tanque de captación pertenecientes a la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

Tabla 3.2: Coordenadas de la casa de máquinas y del tanque de captación de la CENTRAL HIDROELÉCTRICA ILLUCHI 2 [15]

	Sur	Oeste
Tanque de captación	0°55'51,02"S	78°31'57,36"W
Casa de máquinas central Illuchi 2	0°56'06"S	78°32'49"W

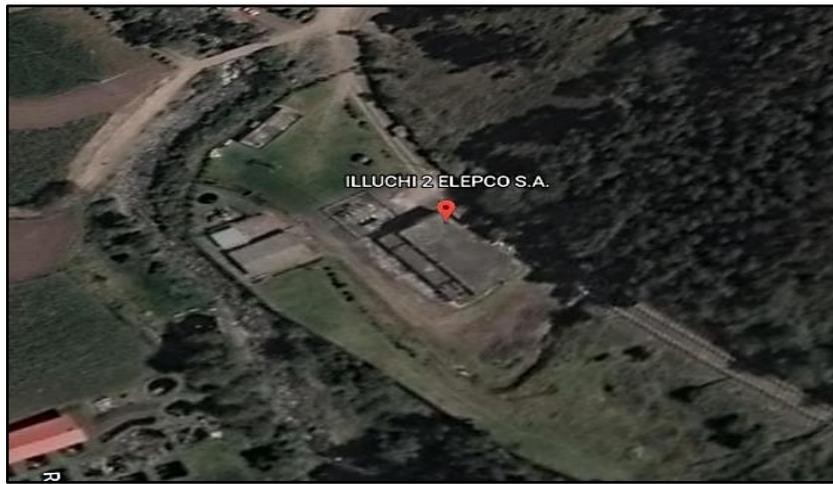


Figura 3.1: Ubicación geográfica de la casa de máquinas perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2

Fuente: Los autores



Figura 3.2: Ubicación geográfica del tanque de la CENTRAL HIDROELÉCTRICA ILLUCHI 2

Fuente: Los autores

La CENTRAL HIDROELÉCTRICA ILLUCHI 2 abastece la demanda eléctrica a la Subestación El Calvario, la cual alimenta a los siguientes sectores:

- Latacunga Sur.
- Latacunga Centro Sur.
- Industrial Sur.
- Oriental.

La CENTRAL HIDROELÉCTRICA ILLUCHI 2 dispone de varios equipos necesarios para el funcionamiento de la central tal como se mencionan en la tabla 3.3.

Tabla 3.3: Datos de los equipos que conforma la central HIDROELÉCTRICA ILLUCHI 2 [16]

Equipo	Magnitud	Unidad	Parámetro
Generadores 1 y 2	3250	kVA	Potencia aparente
	0,8	-	Factor de potencia
	60	Hz	Frecuencia
	720	Rpm	Velocidad
	10	-	Polos
	2400±5%	V	Voltaje
	781,8	A	Corriente
Generador 1	1,51*	p.u.	Impedancia (X_d)
	1,057*	p.u.	Impedancia (X_d)
Generador 2	1,69*	p.u.	Impedancia (X_d)
	1,183*	p.u.	Impedancia (X_d)
Turbina 1 y 2	2675	kW	Potencia activa
	950	l/s	Caudal
	720/1320	Rpm	Velocidad
Transformador principal	6500	kVA	Potencia aparente
	2400/13800	V	Voltaje
	8,43	%	Impedancia
	±2 de 2,5%	%	Taps en Alto Voltaje

* Los datos en p.u. de las impedancias están dados sobre una $Z_{base} = 1,772 \Omega$

Los generadores y turbinas que se encuentran en funcionamiento son antiguos, pero más actuales en comparación con la central hidroeléctrica Illuchi 1. Cabe recalcar que no se requiere cambiar el generador, pero la turbina si los requiere. Los cada uno de los grupos generadores generan alrededor de 2 675 kW, logrando una capacidad total de 5 350 kW. La central genera un voltaje de 2 400 V que a su vez alimenta hacia un transformador de elevación de 2 400/13 800 V con una potencia aparente de 6 500 kVA [14].

3.2.2. Demanda de electricidad

3.2.2.1. Concepto de la demanda de energía eléctrica

La demanda de energía eléctrica es la cantidad de energía que un consumidor o usuario final utiliza en cualquier momento (variable en el tiempo) para satisfacer sus necesidades. Dicho de otro modo, la demanda es el consumo dentro de una instalación eléctrica realizada por los terminales receptores (carga) que desarrollan un trabajo. En este caso, la carga puede indicarse en kilovatios, kilovares, kilovoltamperios, kiloamperios o amperios [17].

En la figura 3.3, se puede observar la curva de demanda de energía eléctrica con un intervalo de estudio realizado en el mes de Enero del 2 016 observando la variación de los 31 días que se compone la fecha antes mencionada correspondiente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2. Este comportamiento dependerá de las variables que afectan a la demanda a corto, mediano y largo plazo. También se puede mencionar que el comportamiento de la demanda eléctrica tiende a crecer mientras transcurren los primeros días de la semana.

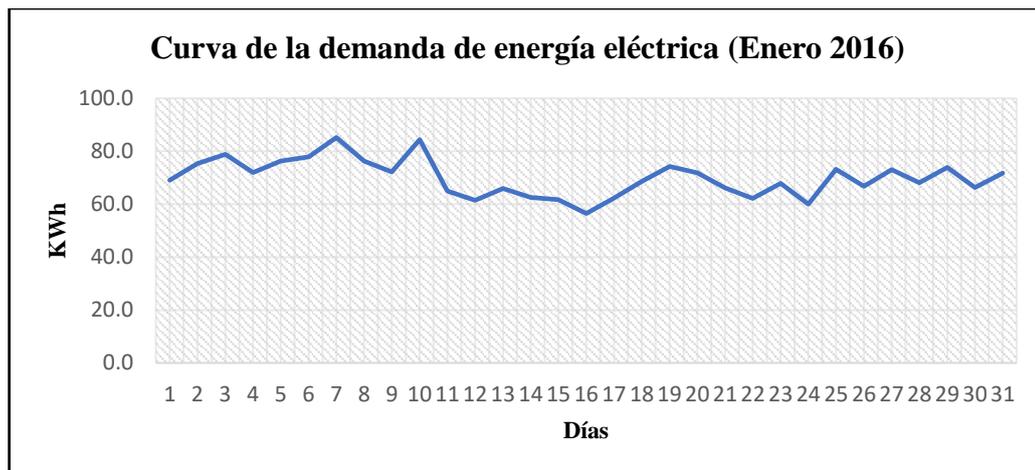


Figura 3.3: Curva de la demanda de energía eléctrica en el mes de Enero del 2 016

Fuente: Los autores

3.2.2.2. Tipos de demanda eléctrica

Al hablar de demanda eléctrica, resulta útil aclarar que se refiere a las cargas que asume todo equipo o elemento eléctrico que requiera de energía del sistema de distribución eléctrica, tales como: lámparas, electrodomésticos, calefacción, motores eléctricos, hornos eléctricos, etc. Estas cargas presentan características diferentes con relación al tamaño, constancia de la carga y el período de funcionamiento. Desde el punto de vista del sistema de energía eléctrica, las cargas pueden ser separadas en tres grupos funcionales que se presentan en la figura 3.4 [3].

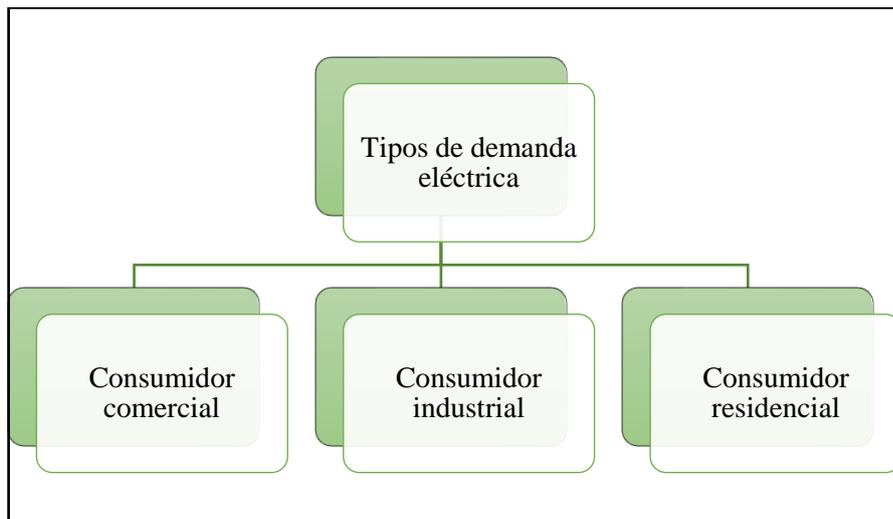


Figura 3.4: Tipos de demanda eléctrica [3]

3.2.3. Centrales hidroeléctricas

Una de las características principales de las centrales hidroeléctricas es aprovechar la energía potencial que posee la masa del agua de un cauce natural en virtud de un desnivel, también conocido como un salto geodésico. El cauce de un río es fundamental, debido que el fluido pasa por una turbina hidráulica, que a su vez se encarga de transmitir la energía hacia un generador, donde se transforma en energía eléctrica. En otras palabras, se trata de una instalación con un diseño que utiliza la energía del movimiento del agua para lograr transformarla en energía eléctrica [18], [19].

3.2.3.1. Clasificación de las centrales hidroeléctricas

Según [20] afirma que la clasificación de las centrales hidroeléctricas es de la siguiente manera:

Por el fin

- Centrales que suministran directamente trabajo mecánico.

- Centrales que suministran solamente energía eléctrica.
- Centrales que suministran energía eléctrica y cuyo embalse sirve para:
 - El regadío
 - La navegación
 - El suministro de agua a las ciudades.
 - La protección contra inundaciones.

Por el tipo de embalse

- Centrales de agua fluyente o centrales sin embalse:
 - Con reserva diaria.
 - Sin reserva diaria
- Centrales con embalse, alimentadas por cursos naturales.
- Centrales de acumulación por bombeo.
- Centrales mareomotrices.

Por la potencia instalada:

- Microcentrales: $P < 100 \text{ kW}$
- Centrales de pequeña potencia (Minicentrales): $100 \leq P \leq 500 \text{ kW}$
- Centrales de media potencia: $1 \leq P \leq 10 \text{ MW}$
- Centrales de gran potencia: $P \geq 10 \text{ MW}$

Por la altura del salto:

- Pequeña altura: $H < 15 \text{ m}$
- Mediana altura: $15 \leq H < 50 \text{ m}$
- Gran altura: $H \geq 50 \text{ m}$

3.2.3.2. Aprovechamiento del recurso hidráulico

Gran parte de la energía del agua que evoluciona siguiendo el ciclo hidrológico de la naturaleza se puede aprovechar para obtener trabajo útil. Sin embargo, el ciclo hidrológico puede sufrir una variación estacional de la producción, proporcional a la variación del caudal de agua. Para satisfacer la demanda de una carga variable, se necesita una gran cantidad de agua. La variación del caudal en un lugar determinado dependerá de las características geográficas, geológicas y topográficas, así como de la magnitud de las precipitaciones de la zona [20], [21]. En la figura

3.5 se muestra un ejemplo del aprovechamiento del recurso hidráulico para la generación eléctrica.

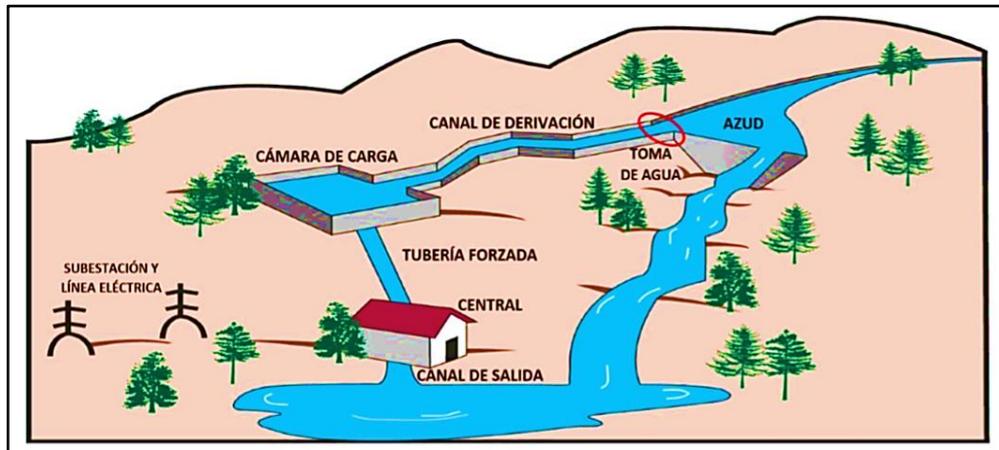


Figura 3.5: Partes principales que compone una central hidroeléctrica aprovechando el recurso hidráulico [22]

3.2.4. Irregularidades del recurso hidráulico

Las características de un río no se conocen suficientemente hasta que no se disponga de un estudio, dicho estudio debe contener un gran número de datos a lo largo de varios años (en el orden de los 20 años o superior) de esta forma se logra obtener correlaciones entre los caudales y las precipitaciones, datos que son normalmente conocidos. A partir de todos ellos es posible determinar el régimen hidráulico del río y la influencia de los principales factores que lo afectan, y que determinan su irregularidad. Se pueden distinguir por algunos tipos de irregularidades entre ellas: diaria, estacional y anual.

3.2.4.1. Irregularidad diaria

Es máxima en los cursos de agua que son alimentados principalmente por los glaciares, debido a que la fusión de la nieve es mucho más acentuada por el día, que por la noche. El retardo asociado a este proceso hace que el caudal máximo diario se presente en las últimas horas de la tarde y el mínimo en el mediodía.

3.2.4.2. Irregularidad estacional

Es máxima en los torrentes de montaña, en los cuales el estiaje ocurre en invierno (régimen glaciar) o en las regiones áridas o semidesérticas, presentando, en este caso el estiaje durante los meses de verano (régimen pluvial). También cuando el río está alimentado por las nieves de

las grandes alturas y por las lluvias de las alturas medias se habla de (régimen mixto) formándose estiajes en invierno y verano. Cada uno de los comportamientos de cada uno de los regímenes mencionados se muestran en la figura 3.6.

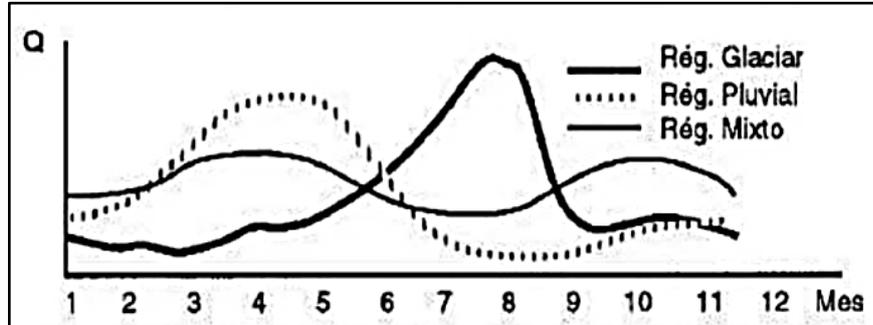


Figura 3.6: Representación gráfica de los comportamientos del estiaje en el transcurso del tiempo [20]

3.2.4.3. Irregularidad anual

Es menos pronunciada, debido a que el ciclo se repite de una manera más o menos constante en todos los años [20].

3.2.5. Caudal utilizado para la generación de energía eléctrica.

Al analizar la potencia producida por una central hidráulica no solo basta con tener en cuenta la altura del salto, sino el caudal que se va a poder turbinar. Esto dependerá en cada momento de las condiciones particulares que presente la cuenca hidráulica.



Figura 3.7: Tanque de captación perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2

Fuente: Los autores

En la figura 3.7, se muestra el tanque de captación perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2, el agua que se almacena es utilizado para la generación eléctrica pero la cantidad de agua en el tanque varía de año a año y se distribuyen desigualmente a través de los meses. Pero no toda el agua almacenada se puede utilizarse, dado que una parte de ella brinda el recurso hídrico para la agricultura, otra parte se infiltra en el subsuelo, pudiendo incluso aflorar posteriormente en una cuenca distinta. Sin embargo, este último efecto, al contrario que la evaporación, no afecta a la cantidad total de agua que se aprovecha [20].

3.2.6. La potencia hidráulica

En las centrales hidroeléctricas, la energía se obtiene aprovechando la energía cinética que adquiere el caudal para lograr impulsar la turbina que, a su vez, hace funcionar el generador para producir electricidad. La potencia hidráulica es, por tanto, una fuente de energía renovable naturalmente disponible, para conocer el valor de la potencia hidráulica se utiliza la ecuación 3.1 [21].

$$P = g\rho QH \quad (3.1)$$

Donde:

P = Es la potencia hidráulica en Watts.

g = Es 9.81 m/s² se cómo la aceleración debida a la gravedad.

ρ = Es la densidad del agua alrededor de 1 000 kg / m³.

Q = Es el caudal o descarga en m³/s.

H = Es la altura de caída del agua o altura en m.

3.2.7. Relación entre caudal y potencia

Es habitual plantear la cantidad de agua que se puede aprovechar, o más bien, la potencia que se estima aprovechar mediante algún tipo de instalación. Por esa razón las centrales hidroeléctricas juegan un papel importante debido a su flexibilidad en sus operaciones, logrando adaptarse a los cambios en la demanda [23]. El agua necesaria para este proceso no debe tener tratamientos específicos para poder usarla, debido a esto se convierte en un recurso con amplia disponibilidad y se puede tomar de cualquier afluente que pueda suplir la demanda de agua que requiera el sistema diseñado.

En la figura 3.8, se muestra un ejemplo del rendimiento de un sistema para diferentes caudales con respecto a la potencia producida y la eficiencia que alcanza el sistema, para un caudal de diseño (243 L/s), se comprueba que la potencia producida es de 7,5 kW y la eficiencia del sistema es del 64 %, es posible que en ciertas épocas el sistema trabaje con caudales menores o mayores al establecido en la fase de diseño, por lo tanto, se estima que el rendimiento del sistema con diferentes caudales, se puede apreciar que a medida que aumenta el caudal, la eficiencia también aumenta, hasta caudales de 200 L/s, el sistema puede producir potencias mayores a 4 kW, lo cual es un valor aceptable para la potencia esperada en la fase de diseño que es de 5 kW [24].

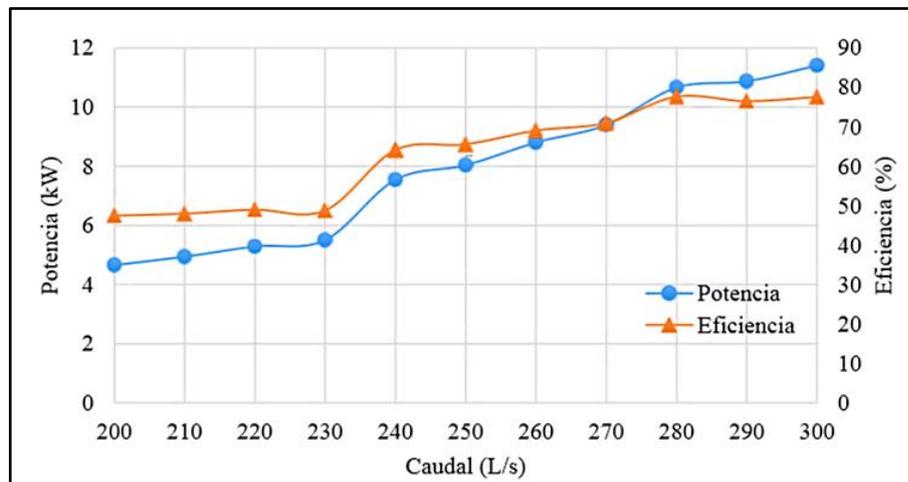


Figura 3.8: Relación entre caudal y potencia para verificar el rendimiento del sistema con diferentes caudales [24]

3.2.8. La energía eléctrica producida

De acuerdo con [21] la energía eléctrica producida en Wh se puede aplicar la ecuación (3.2) o también se puede aplicar la ecuación (3.3) obteniendo el valor de la energía eléctrica producida en kWh .

$$W = 9.81 \cdot 1000QH\eta t \quad (3.2)$$

$$W = 9.81QH\eta t \quad (3.3)$$

Donde:

W = Es la energía producida

t = Es el tiempo de funcionamiento en horas (8 760 h / año)

η = Es la eficiencia del conjunto turbina-generador, que varía entre 0,5 y 0,9.

La potencia desarrollada dependerá de la cantidad Q y de la altura H del agua.

La energía hidráulica es importante solo junto a la energía térmica. Casi el 20 % de la energía total del mundo se obtiene mediante centrales hidroeléctricas.

3.2.9. Fotogrametría digital (*Structure-from Motion*)

Los métodos basados en la teledetección han desempeñado durante mucho tiempo un papel en el estudio y el seguimiento del hábitat físico de los ríos y la hidromorfología. Cada vez son más las publicaciones que demuestran el uso de la fotogrametría digital y las correlaciones de profundidad espectral para cuantificar la topografía fluvial y la profundidad de los cauces, el cálculo de las variables de textura de las imágenes y la rugosidad de las nubes de puntos de escáner láser terrestre para cuantificar el tamaño del sustrato fluvial y el uso de imágenes multispectrales para cartografiar las unidades hidrogeomórficas. Sin embargo, pocos de estos enfoques son capaces de cuantificar simultáneamente varios parámetros del hábitat físico (por ejemplo, la topografía, la profundidad del agua, el tamaño del sustrato y las variables hidráulicas) utilizando un único conjunto de datos con las resoluciones espaciales más adecuadas para la evaluación del hábitat.

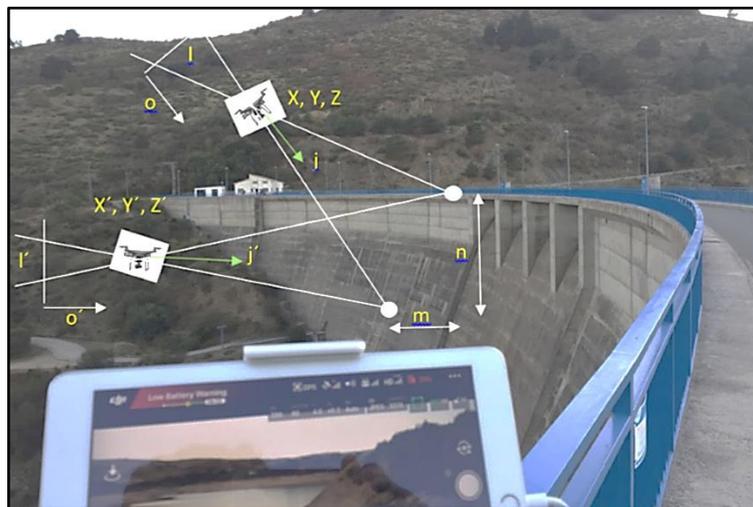


Figura 3.9: Posiciones de cámara, orientación, longitudes focales y posiciones relativas para la evaluación del área de estudio [25]

Paralelamente al rápido desarrollo de los drones para la investigación civil, los avances en la visión por ordenador y el análisis de imágenes han llevado a una mayor disponibilidad de paquetes de software que ofrecen cadenas de procesamiento de imágenes capaces de producir

tanto ortofotos como modelos digitales de elevación (MDE) a partir de imágenes de drones. El SFM proporciona un método automatizado para modelar la geometría relativa en 3D de una escena mediante el cotejo de una serie de imágenes 2D superpuestas, que luego pueden ser georreferenciadas a coordenadas cartográficas (es decir, que muestran el mismo sujeto desde distintos ángulos), tal como se muestra en la figura 3.9. En la figura 3.10, se presenta el resultado final de la visualización de una región analizada por los autores aplicando el método de la fotogrametría digital [26].

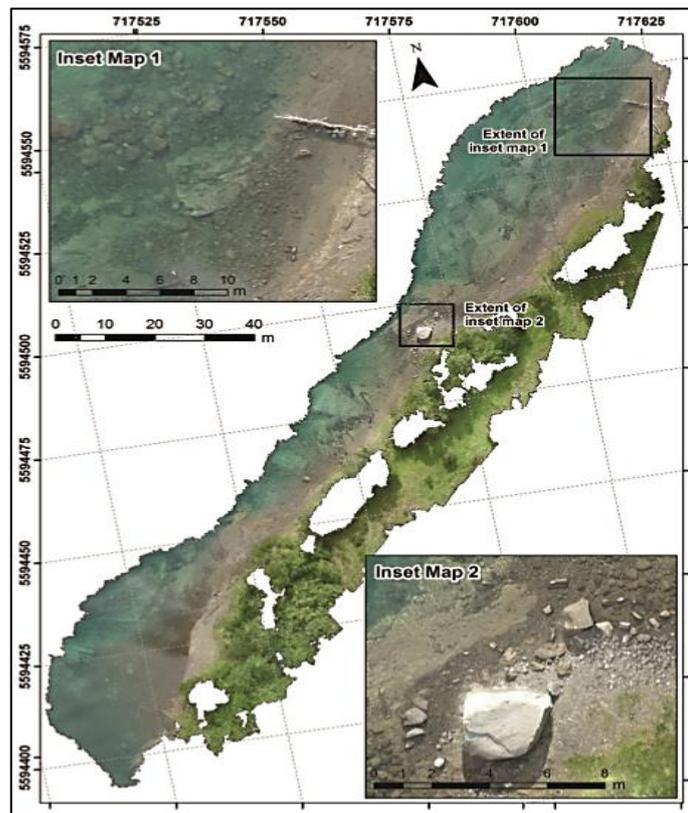


Figura 3.10: Representación gráfica utilizando la fotogrametría digital [26]

3.2.10. Predicción de la demanda de energía eléctrica

Es necesario mencionar que las técnicas de predicción ayudan a obtener estimaciones o pronósticos de valores futuros de una serie temporal a partir de una información histórica, contenida en una la serie observaciones hasta el momento, en otras palabras, se trata de la predicción de posibles valores futuros de las variables en base a los valores previos de esas variables. Existen muchos tipos de técnicas de predicción, así como una gran cantidad de aplicaciones útiles en la vida para el ser humano, desde las más simples como lo pueden ser el

azar, hasta en los negocios de una empresa. Algunos de los campos de aplicación que se utilizan técnicas de predicción se presenta en la figura 3.11.

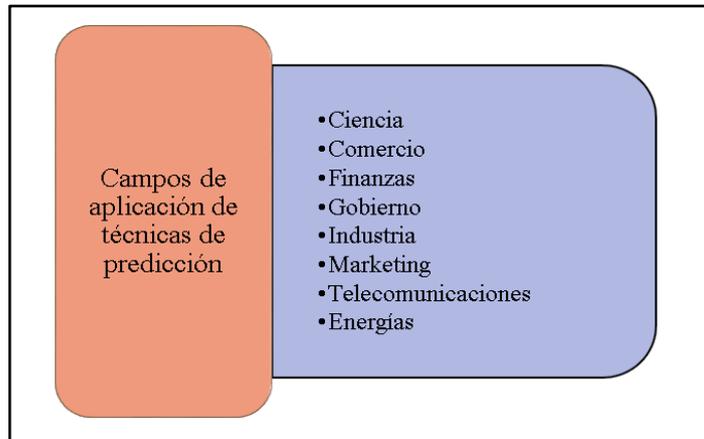


Figura 3.11: Campos de aplicación que utilizan las técnicas de predicción mediante redes neuronales artificiales [27]

Es precisamente en este último campo, el de energías en donde se desarrolla esta investigación, concretamente en la demanda de energía eléctrica que utiliza una empresa distribuidora para distribuir hacia los usuarios y abastecer sus procesos. Utilizando datos históricos recolectados de los generadores y a la selección de las técnicas de predicción para estimar los valores futuros del generador. Las variables de entrada deben ser correctamente seleccionadas para una escala de tiempo de interés para realizar un análisis, las escalas de tiempo se dividen en tres:

- **Horaria:** pueden estar relacionadas con el análisis de datos meteorológicos como: humedad, radiación solar, temperatura, velocidad del viento, etc., también se aplican en el análisis de eventos especiales como: festivos, eventos deportivos, etc.
- **Semanal:** pueden estar relacionadas con el análisis de datos meteorológicos como: la variación de grados día de calefacción, grados día de refrigeración, actividades económicas.
- **Anual:** pueden estar relacionadas con el análisis de insumos económicos como: el producto interno bruto (PIB), los salarios básicos, el índice de precios al consumidor, etc., también se analiza variables demográficas como: el crecimiento poblacional, ingresos familiares, estatus socioeconómicos, inmigración, enfermedades, etc. [27].

No existe una sola forma de caracterizar la demanda eléctrica, es por ello que una primera clasificación en las predicciones de demanda eléctrica está dada por el tipo de caracterización,

normalmente puede estar dado en energía (kWh) o en potencia (kW), comúnmente la predicción suele realizarse caracterizando la demanda eléctrica como energía, sin embargo, no se debe olvidar que la potencia tiene relación directa con la energía mediante un periodo de tiempo especificado para dicha energía, así que no representaría ningún problema si se caracteriza a la demanda como energía o potencia [28].

La predicción en el consumo de energía eléctrica refleja las necesidades futuras de una población; esta predicción debe ser lo más ajustada a la realidad, debido a que pueden existir valores inferiores o superiores a los reales que causarían deficiencias en la prestación del servicio en el futuro [3].

3.2.11. Horizonte temporal en la predicción de la demanda de energía eléctrica

Al construir un modelo que ayude a predecir la demanda de energía se debe realizarse algunos cuestionamientos, bajo este contexto, el horizonte temporal de la predicción, está relacionado con los problemas a los que se enfrenta una empresa que presta el servicio de la energía eléctrica. En el análisis de la predicción se ha identificado tres horizontes de tiempo denominados: corto, mediano y largo plazo, cada uno de ellos se describen a continuación:

3.2.11.1. Corto plazo

Este período que a veces se suele subdividir en muy corto plazo y en corto plazo, normalmente se suele considerar que el primero de un grupo de períodos abarcará los próximos 30 minutos en tiempo real a partir del momento en que se efectúa la predicción de la demanda. Realmente se trata de realizar el seguimiento de la carga y de la predicción inmediata de esta basándose en los datos de la demanda durante pasadas las 24 horas.

3.2.11.2. Mediano plazo

Se suele entender que el período de predicción que se extiende en el futuro, desde un mes hasta un año a partir del momento en que se efectúa el pronóstico. Esta predicción es necesaria, generalmente, para establecer el calendario para el mantenimiento de las plantas generadoras y en los sistemas de transmisión.

3.2.11.3. Largo plazo

Se suele denominar a largo plazo al período de predicción que abarca desde uno a diez años en el futuro. Puesto que es el tiempo necesario que ayuda a planificar, construir, probar y poner en funcionamiento una nueva capacidad generadora [3].

3.2.12. Clasificación de los métodos del pronóstico de la demanda de energía eléctrica

En la figura 3.12, se muestra los parámetros que inciden en la predicción de la demanda de energía eléctrica. Cada uno de los criterios son importantes para lograr plantear un método de predicción.

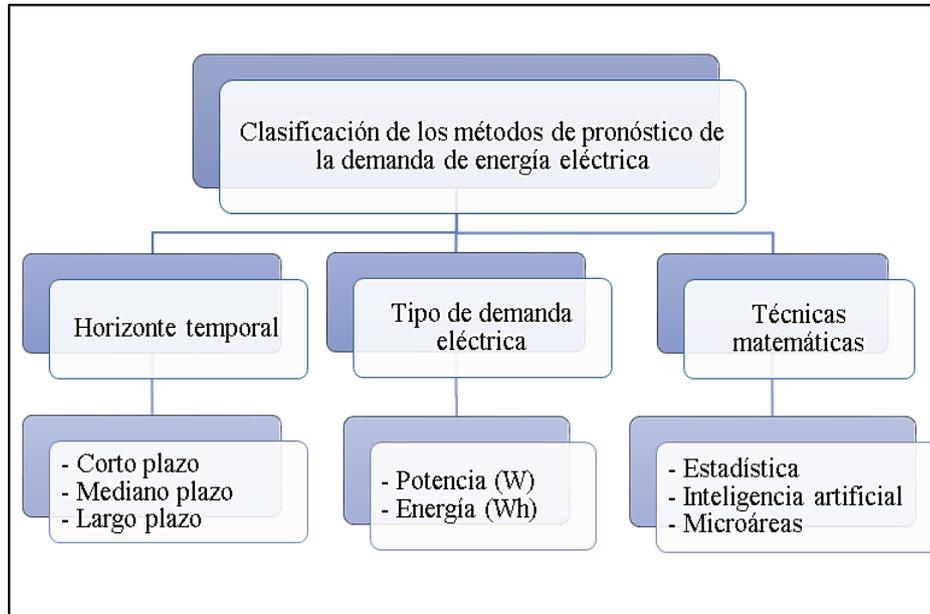


Figura 3.12: Parámetros que indican en la predicción de la demanda para emplearlos en el modelo de red neuronal artificial [29]

3.2.13. Métodos utilizados en la predicción de la demanda de energía eléctrica

Los métodos utilizados en la predicción de la demanda de energía eléctrica se clasifican mediante una variedad de criterios, uno de ellos están relacionados con los métodos cualitativos, donde el pronóstico se obtiene en base a una o varias opiniones de los expertos que posean la experiencia y los conocimientos necesarios sobre la variable que se pretenda predecirlos, otro de los criterios se relacionan con los métodos cuantitativos, la cual consiste en extraer toda la información necesaria en base a los datos históricos agrupados. Cabe mencionar que los métodos cuantitativos se dividen en dos subgrupos denominados métodos estadísticos e inteligencia artificial [3], [28].

3.2.14. Categorización de las variables para la predicción de la demanda de energía eléctrica

En primer lugar, para lograr definir las variables que intervienen directamente en la predicción se debe establecer una jerarquía de estudio. Al plantear correctamente esta jerarquía,

procedemos a desarrollar la categorización de las variables tal como se muestra en la figura 3.13.

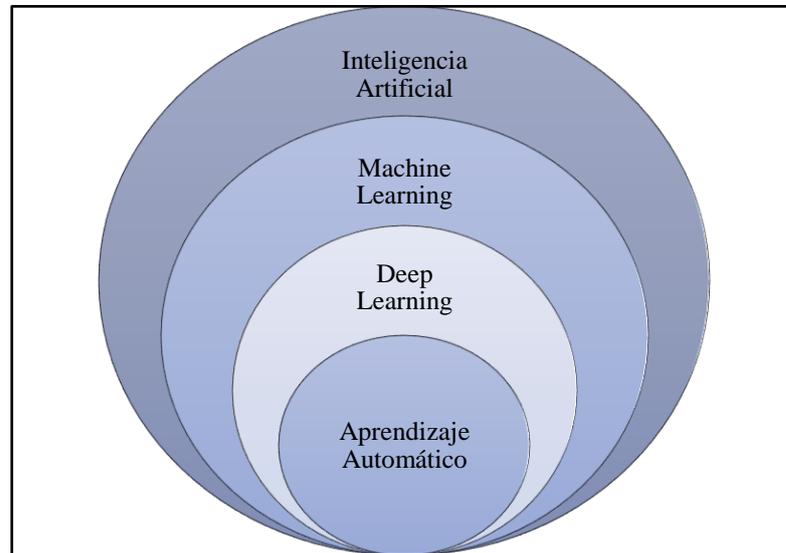


Figura 3.13: Categorización de la variable de estudio para la predicción de la demanda de energía eléctrica [11]

3.2.14.1. Inteligencia Artificial

El concepto inteligencia artificial (IA) no es nuevo debido a que antes ya se consideraba como una rama de la informática. Sus progresos están enfocados en desarrollar sistemas que posean la habilidad comportarse de tal manera, que éste mismo logre imitar lo mismo que realiza un ser humano para resolver problemas.

3.2.14.2. Machine Learning

Es un subconjunto de la Inteligencia Artificial que permite mejorar las tareas de las máquinas incluido el Deep Learning (DL). Una de las funciones básicas del Machine Learning consiste en el uso de una variedad de algoritmos que permitan procesar datos externos, de esta forma logre extraer patrones por medio de algoritmos para ser capaces de entregar pronósticos o indicaciones sobre los datos analizados.

3.2.14.3. Deep Learning

Es un subconjunto de Machine Learning basado en redes neuronales que permiten que una máquina se entrene a sí misma para realizar una tarea. Los modelos desarrollados deben ser

capaces de evaluar diferentes patrones o instrucciones para lograr modificarse a sí mismo y encontrar errores en sus resultados [11].

3.2.14.4. Aprendizaje automático

El aprendizaje automático se centra en crear sistemas autónomos que puedan continuar el proceso de toma de decisiones, con poca o ninguna intervención humana. Para lograr enseñar a la máquina, se necesita datos extraídos del mundo real, para luego pasarlos por modelos denominados algoritmos que utilizarán la probabilidad y estadística para desenterrar patrones y estructuras de los datos. Si esto se hace correctamente, el algoritmo por sí mismo será capaz de analizar los datos y clasificarlos adecuadamente [30].

3.2.15. Métodos de inteligencia artificial para la predicción de la demanda de energía eléctrica

La inteligencia artificial se define como el arte que ayuda a desarrollar máquinas con la capacidad necesaria para realizar tareas. Con este concepto, se puede definir que los métodos de inteligencia artificiales empleados en las predicciones, son algoritmos que se apoyan en las matemáticas avanzadas para ayudar a modelar la variación de las variables dependientes en función de variables independientes, cabe recalcar que las variables involucradas deben estar correlacionadas, de esta forma permite trabajar con sistemas complejos, los mismos que presentan comportamientos no lineales [28]. En la figura 3.14, se muestra la clasificación relacionada con la inteligencia artificial.

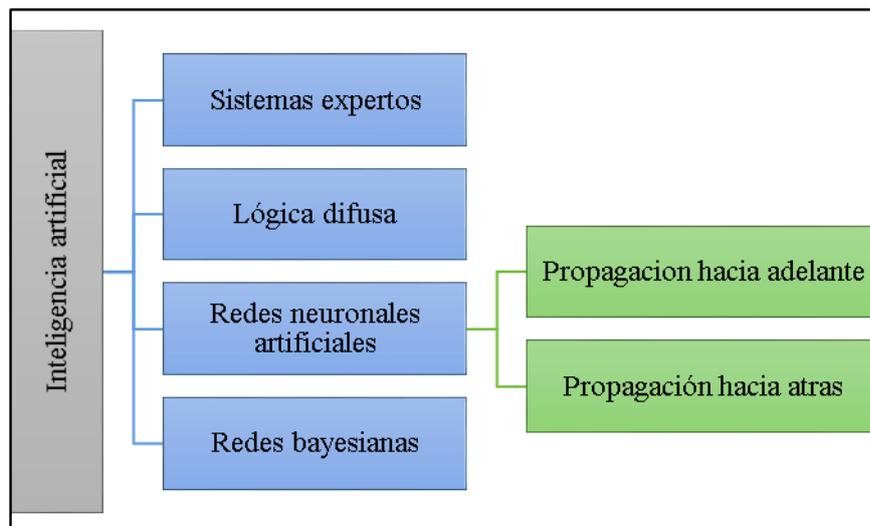


Figura 3.14: Clasificación relacionado a los métodos de inteligencia artificial empleados en la predicción de la demanda de energía eléctrica [29]

3.2.16. Redes neuronales artificiales

3.2.16.1. Funcionamiento de las neuronas

Las redes neuronales artificiales son un sistema computacional cuya arquitectura y operaciones están inspiradas en el funcionamiento de las neuronas biológicas del cerebro de los seres humanos [8]. De manera general las neuronas están formadas por una variedad de nodos, las cuales se conectan una hacia la otra para lograr transmitir cualquier información proveniente del exterior; por ello es necesario tener un punto de entrada para luego procesarlo hasta generar un resultado del procesamiento a través de una salida. Las interconexiones entre cada una de las neuronas están formadas a través de enlaces en donde se entregan toda la información que fueron recibidas desde una neurona predecesora hacia otra neurona sucesora, que a su vez se encuentra multiplicado por un peso. Adicionalmente la información que entrega una neurona hacia cada uno de los enlaces pueden ser modificados mediante la aplicación de funciones de activación, estas funciones de activación tiene como objetivo delimitar los rango que pueda tomar los valores entregados por la neurona de salida [11].

3.2.16.2. Características principales de una neurona biológica

El aparato de comunicación neuronal de los animales y los seres humanos está formado por un sistema nervioso y hormonal, en conexión con los órganos de los sentidos y órganos efectores (músculos y glándulas), estas tienen la misión de recoger información, transmitir las y elaborarlas, en parte también almacenadas y enviarlas de nuevo de forma elaborada.

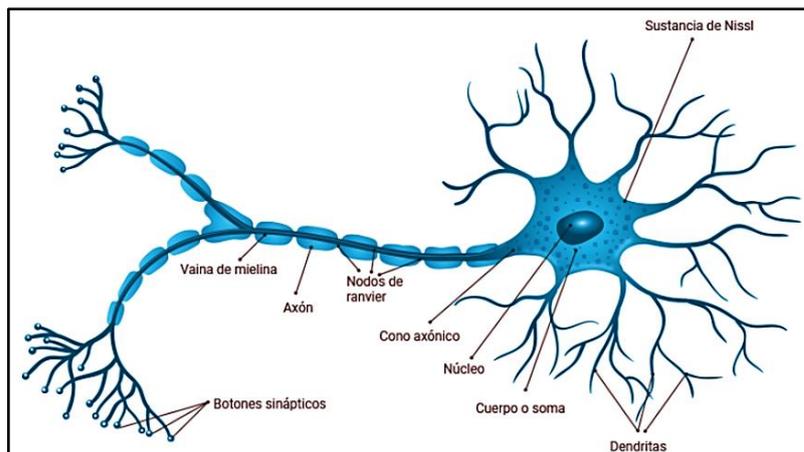


Figura 3.15: Estructura general de una neurona biológica [31]

En la figura 3.15, se aprecia que la neurona consta de un cuerpo celular y un núcleo, seguidamente del axón que es una ramificación de la salida de la neurona, además la neurona

cuenta con un gran número de ramificaciones de entrada conocidas como dendritas que propagan la señal al interior de la neurona [32].

3.2.16.3. Características principales de una red neuronal artificial

Las redes neuronales artificiales (RNAs) son sistemas de cómputo inspirados en las neuronas biológicas que tienen la capacidad de aprender a partir de la experiencia. Su unidad o elemento de procesamiento básico es la neurona, la cual combina los valores de sus señales de entrada y modifica este resultado mediante una función no lineal. Las conexiones entre neuronas tienen pesos asociados que regulan la acción que ciertas unidades tienen sobre el resultado final [33].

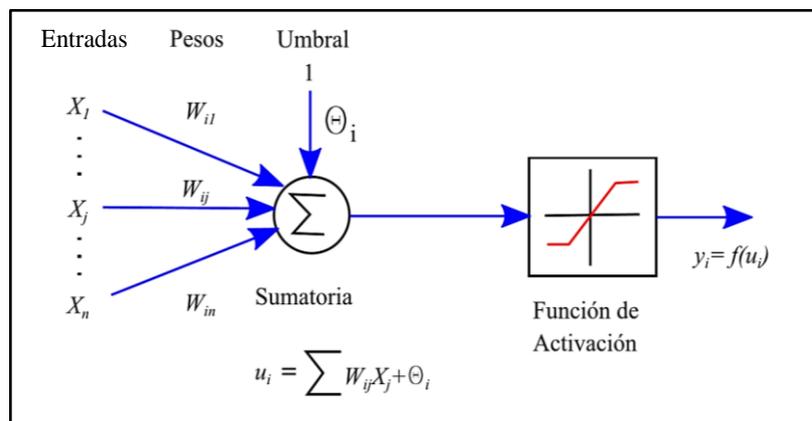


Figura 3.16: Estructura general de una red neuronal artificial [34]

3.2.16.4. Modelo matemático de la red neuronal artificial

Para el planteamiento de los primeros modelos de red neuronal artificial se basaron en el modelo de tipo McCulloch-Pitts, propuesto por Warren McCulloch y Walter Pitts en 1943. Donde se basaron en el funcionamiento de las neuronas biológicas el modelo es considerado como un procesador elemental que está compuesta por X_n entradas y una única salida y_i . El ingreso total hacia la neurona es calculado como la suma ponderada de todas las entradas ponderadas compuesto por ciertos valores. Para lograr obtener la ecuación matemática de la neurona presentada en la figura 3.16, presenta un grupo de entradas $x_1 \dots \dots \dots x_n$, comúnmente se conoce como las sinapsis de una neurona biológica cada una de ellas se encuentran multiplicadas por un peso al que está asociado $w_1 \dots \dots \dots w_n$.

En la figura 3.16, se puede apreciar el símbolo matemático (Σ) este es el resultado de la sumatoria ponderada de todas las entradas y como resultado se obtiene una salida como se muestra en la ecuación 3.4 [35].

$$\sum_{i=1}^n = w_1x_1 + w_2x_2 + \dots + w_n \quad (3.4)$$

Donde:

$x_1 \dots \dots \dots x_n$ = son las entradas.

$w_1 \dots \dots \dots w_n$ = son los pesos simpáticos.

Todas las señales que ingresan a la neurona pueden ser vistas como una única entrada si se describe utilizando la ecuación 3.5.

$$u = \sum_{i=1}^n w_{ij}x_i + \theta_j \quad (3.5)$$

Donde:

u = única entrada

θ_j = umbral o sesgo.

$\sum_{i=1}^n w_{ij}x_i + \theta_j$ = sumatoria de todas las entradas

Dependiendo del signo del peso se habla de una excitación para el caso positivo y de una inhibición para el caso negativo. Si se añade la variable tiempo a la ecuación 3.5 esta se reescribe como lo muestra la ecuación 3.6.

$$u(t) = \sum_{i=1}^n w_{ij}x_i(t) + \theta_j \quad (3.6)$$

Donde:

u = única entrada

θ_j = umbral o sesgo.

$\sum_{i=1}^n w_{ij}x_i + \theta_j$ = sumatoria de todas las entradas

t = tiempo

Los pesos son los encargados de guardar el conocimiento de la red neuronal sobre cierta tarea en cuestión y al proceso mediante el cual se ajustan estos pesos se denomina aprendizaje o entrenamiento. Por lo general el sesgo θ se lo considera como otro peso más conectado a una

entrada que siempre tiene el valor de uno es por eso que la salida de cada neurona se la puede reescribir como la ecuación 3.7, por lo que de aquí en adelante solo se lo mencionara o graficará donde sea estrictamente necesario.

$$y = f(u) \quad (3.7)$$

Donde:

u = única entrada

f = función de activación.

y = salida de la neurona

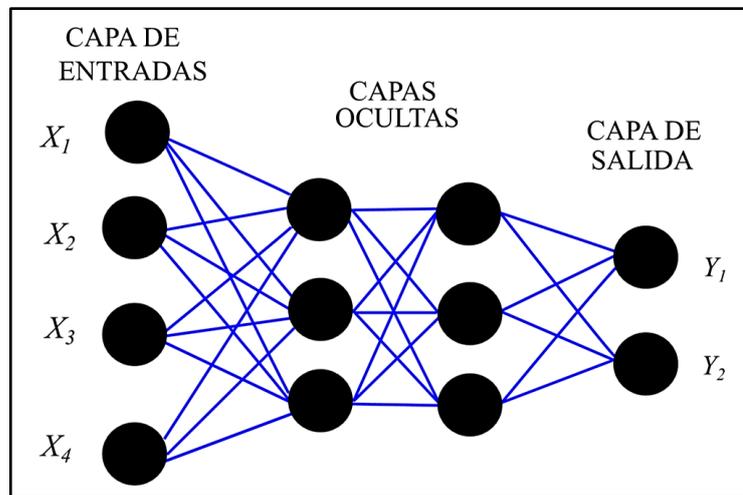


Figura 3.17: Esquema de una red neuronal artificial [34]

Los estímulos que provienen del exterior o de neuronas a las que se encuentran enlazadas, poseen una función de activación que les permiten cambiar los resultados de acuerdo con las señales que reciben. Al pasar por una función de activación, produce una señal de salida saturada, es decir, que a pesar del sumatorio sea un número grande positivo o negativo, la salida solo variará alrededor de un rango específico, utilizando la ecuación 3.8.

$$y_j(t) = F\left(\sum_{i=1}^n w_{ij}x_i(t) + \theta_j\right) \quad (3.8)$$

Donde:

$x_i(t)$ = señal de salida de otros nodos o entradas externas.

$y_j(t)$ = salida de la red neuronal

w_{ij} , = pesos de las conexiones

θ_j = sesgo

F = función de activación no lineal.

La figura 3.17, muestra como las redes neuronales artificiales poseen una estructura redundante por lo que destacan por su elevada capacidad de producir salidas correctas para entradas no vistas en el entrenamiento [34].

3.2.16.5. Células LSTM

La red neuronal recurrente *Long Short Term Memory* es semejante a las redes de Elman y de Jordan con la diferencia que sustituye las neuronas y las capas ocultas por un bloque de memoria, este bloque se denomina célula LSTM. En la siguiente figura se puede apreciar cómo es una célula LSTM en su interior [36].

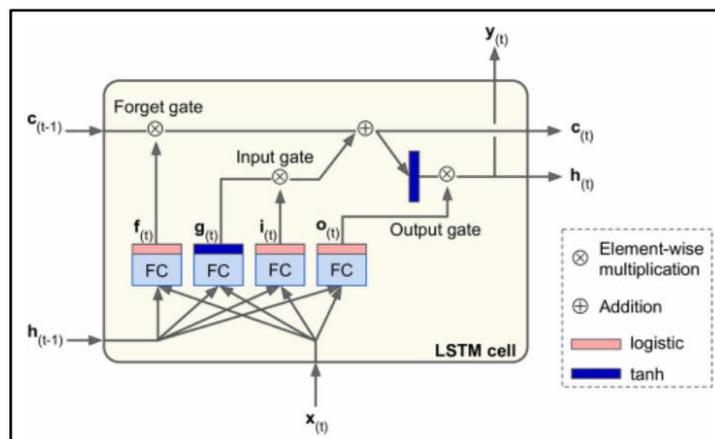


Figura 3.18: Estructura interna de una célula LSTM [37]

Como se puede observar en la figura 3.18, el interior del bloque que representa una célula LSTM la cual es similar a una célula normal con la diferencia que su estado ahora se divide en dos vectores, $h(t)$ y $c(t)$ (la letra c viene de “célula”). El término $h(t)$ hace referencia al estado de corto plazo y $c(t)$ al de largo plazo. La idea principal de la célula es que la red logre aprender qué información almacenar en el estado de largo plazo, qué desechar y qué leer de ellos. Si se logra fijarse bien en el término de largo plazo $c(t - 1)$ atraviesa la red de izquierda a derecha, primero atravesando por una puerta de olvido (*forget gate*), de esta forma se deshace de algunos datos almacenados, y luego añade nueva información que ingresa por la puerta de entrada (*input gate*) y el resultado $c(t)$ se envía directamente fuera de la célula dejando la información intacta

y esto servirá de entrada para la siguiente época, tal como se muestra en la ecuación 3.13. Por lo tanto, en cada paso parte de la información son eliminados mientras que otros nuevos se añaden. Además, una vez añadidos nueva información, se hace una copia del estado a largo plazo y pasa por una función tangente hiperbólica para después ser filtrado por la puerta de salida (*output gate*). Este paso lo produce el estado de corto plazo $h(t)$ (que es igual a la salida de la célula ($y(t)$) para este paso temporal t), tal como se presenta en la ecuación 3.14.

Para conocer el funcionamiento de la célula se debe conocer sus estados, primero se puede observar que el vector de entrada actual $x(t)$ y el estado de corto plazo anterior $h(t - 1)$ van a pasar a cuatro capas conectadas. Todas ellas con un distinto funcionamiento:

- La capa principal es la que tiene como salida a $g(t)$. Tiene el típico rol de analizar las entradas actuales $x(t)$ y el estado a corto plazo anterior $h(t - 1)$, tal como se describe en la ecuación 3.12. En una célula normal sólo existiría esta capa y su salida se dirige directamente a $y(t)$ y $h(t)$, sin embargo, en una célula LSTM la salida de esta capa queda directamente fuera, y se almacena parcialmente en el estado de largo plazo.
- Las otras tres capas, son controladores de puertas (*gate controllers*) debido a que usan la función sigmoideal como función de activación, luego su salida varía entre 0 y 1. Como se puede observar en la figura 3.18, sus salidas van directas hacia operaciones multiplicativas, por lo que, si la salida es cercana a 0, menos información logra pasar y como consecuencia se cierra la puerta, mientras que si se acerca a 1 más información seguirá fluyendo, logrando abrir la puerta.

De forma resumida se puede decir que:

- La *forget gate* ($f(t)$) controla qué partes del estado a largo plazo deben ser eliminadas utilizando la ecuación 3.10.
- La *input gate* ($i(t)$) controla qué partes de $g(t)$ deben ser añadidas al estado de largo plazo (por esta razón se mencionó que se almacenan parcialmente), utilizando la ecuación 3.9.
- La *output gate* ($o(t)$) controla qué partes del estado de largo plazo deben ser leídas, utilizando la ecuación 3.11 y las salidas correspondientes se encuentra representado por $h(t)$ y también por $y(t)$.

Una célula LSTM puede aprender a reconocer datos *inputs* importantes (que es el rol de la puerta de entrada) para almacenarla en el estado de largo plazo, aprendiendo a guardarla siempre que sea necesario (cuyo rol es el de la puerta de olvido) y también aprender a extraer su información siempre y cuando se necesite. Toda esta explicación es necesaria para reconocer el por qué la LSTM ha tenido tanto éxito a la hora de encontrar patrones a largo plazo en series temporales, largos textos, grabaciones de audio, etc. Las siguientes ecuaciones resumen cómo calcular el estado de largo plazo, el de corto plazo y su salida para un paso temporal [36], [37].

$$i_{(t)} = \sigma(W_{xi}^T * x_{(t)} + W_{hi}^T * h_{(t-1)} + b_i) \quad (3.9)$$

$$f_{(t)} = \sigma(W_{xf}^T * x_{(t)} + W_{hf}^T * h_{(t-1)} + b_f) \quad (3.10)$$

$$o_{(t)} = \sigma(W_{xo}^T * x_{(t)} + W_{ho}^T * h_{(t-1)} + b_o) \quad (3.11)$$

$$g_{(t)} = \tanh(W_{xg}^T * x_{(t)} + W_{hg}^T * h_{(t-1)} + b_g) \quad (3.12)$$

$$c_{(t)} = f_{(t)} \otimes c_{(t-1)} + i_{(t)} \otimes g_{(t)} \quad (3.13)$$

$$y_{(t)} = h_{(t)} = o_{(t)} \otimes \tanh(c_{(t)}) \quad (3.14)$$

Donde:

$W_{xi}, W_{xf}, W_{xo}, W_{xg}$ son las matrices de pesos de las conexiones entre las capas y el vector de entrada $x_{(t)}$, tal como se muestra en las ecuaciones anteriores.

$W_{hi}, W_{hf}, W_{ho}, W_{hg}$ son las matrices de pesos de las conexiones entre las capas y el estado de corto plazo previo $h(t - 1)$, tal como se muestra en las ecuaciones anteriores.

b_i, b_f, b_o, b_g son los términos de *bias* para las capas, tal como se muestra en las ecuaciones anteriores.

3.2.17. Arquitectura de redes neuronales

3.2.17.1. Unidad de proceso

Cuando se habla de la estructura de una red neuronal artificial, se refiere a que existen enlaces entre cada una de las neuronas pertenecientes a la red. Estas neuronas se encuentran organizadas a través de diferentes capas, cada uno de ellos con características diferentes, en un modelo simple se encuentran 3 capas cómo se puede ver en la figura 3.17.

- **Capa de Entrada.**

En esta capa se encuentran una parte de las neuronas que reciben los datos esenciales procedentes de fuentes externas.

- **Capa Oculta.**

Particularmente estas capas no tienen ninguna conexión externa debido a que son capas internas de la red, estas capas están encargadas de recibir todos los datos que generalmente entrega la capa de entrada u otras capas ocultas.

- **Capa Salida.**

En la capa de salida se encuentran aquellas neuronas que se encargan de procesar toda la información recibida por las capas anteriores su propósito es entregar el resultado final. Este proceso dependerá de la arquitectura de la red, es decir, la variación en la cantidad de neuronas, la aplicación de funciones de activación y el número de capas ocultas que contenga la red neuronal artificial, cabe mencionar que tomará más esfuerzo en el procesamiento de los resultados, pero elevará la capacidad para lograr resolver problemas complejos [11].

3.2.17.2. Según la estructura de capas

- **Monocapa**

Como su nombre lo indica, está compuesta por una sola capa de neuronas, donde se establecen conexiones laterales entre las diferentes neuronas de la única capa que constituye la red. Un claro ejemplo se puede observar en la figura 3.17.

- **Multicapa**

Este tipo de redes son aquellos que disponen de conjunto de neuronas que se encuentran agrupados en varios niveles o capas. Una de las formas para lograr distinguir las capas a la que pertenece cada neurona, consiste en analizar el origen de las señales que se recibe hacia la capa de entrada y el destino de la señal de la capa de salida. Algunos ejemplos se pueden observar en las figuras 3.19 y 3.20.

3.2.17.3. Según el tipo de respuesta

- **Heteroasociativas**

Las redes heteroasociativas asocia una variedad de información de entrada con diferentes informaciones de salida, necesitan de al menos 2 capas, una para captar y retener la información

de entrada y la otra ayuda a mantener la salida con la información asociada. Si no fuese así, se perdería la información inicial al obtenerse los datos asociados, lo cual no debe ocurrir, debido que, en el proceso de obtener la información de salida, será necesario acceder varias veces a esta información, por lo tanto, deberá permanecer en la capa de entrada.

- **Autoasociativas**

Pero una red autoasociativa asocia una información de entrada con el ejemplar más parecido de los datos almacenados o conocidos por la red. Esta capa comenzará reteniendo la información inicial y terminará representando la información autoasociada. Si se desea mantener la información de entrada y salida se deberán adjuntar capas adicionales. En comparación al caso anterior esta red se puede implementarse utilizando una sola capa [38].

3.2.17.4. Según el flujo de los datos

- **Propagación hacia adelante (feedforward)**

La propagación de la señal se produce desde la entrada hacia la salida, no existe ningún tipo de realimentación tal como se presenta en la figura 3.19.

Donde:

(a) = Conexiones hacia adelante

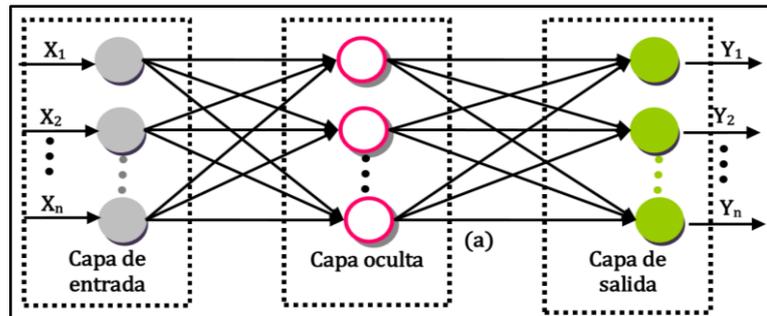


Figura 3.19: Red multicapa aplicando la propagación hacia adelante [29]

- **Propagación hacia atrás (feedback)**

A este tipo de redes también se las conoce como redes recurrentes. A diferencia de la red anterior esta se caracteriza por disponer de lazos de realimentación que pueden darse sobre una misma neurona, entre neuronas de una misma capa o neuronas de capas distintas como se muestra en la figura 3.20 [39].

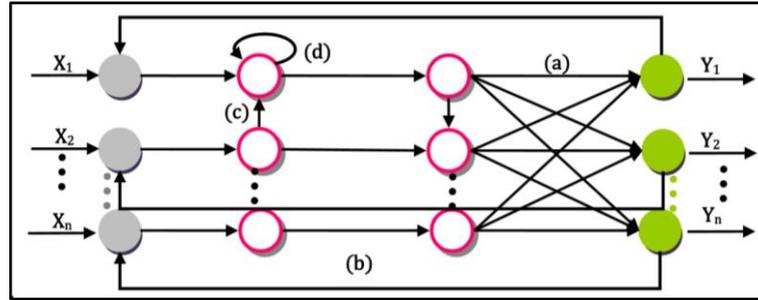


Figura 3.20: Red multicapa aplicando la propagación hacia atrás [29]

Donde:

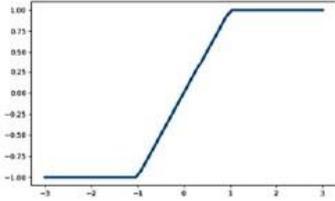
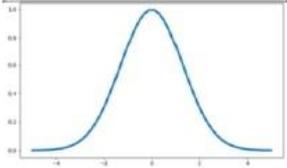
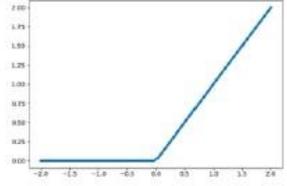
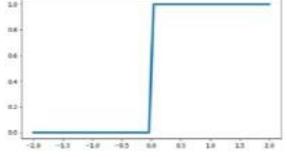
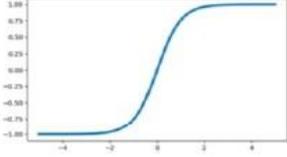
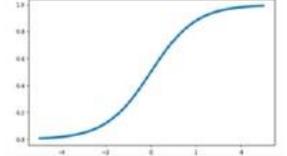
- (a) = Conexiones hacia adelante
- (b) = Conexiones hacia atrás
- (c) = Conexiones laterales
- (d) = Conexiones autorrecurrentes

3.2.18. Funciones de activación para la aplicación de redes neuronales artificiales

Es un proceso fundamental que sigue las redes neuronales artificiales para el procesamiento de la información, la manera de conocer la activación o el estado de una neurona, en función de las entradas que ingresen a dicha neurona se lo hace mediante una función de activación. Estas funciones pueden ser lineales o no lineales tal como se muestra en la tabla 3.4, en donde se puede apreciar una variedad de funciones de activación que comúnmente son aplicados en el desarrollo de redes neuronales artificiales [28]:

Tabla 3.4: Funciones de activación para la aplicación de redes neuronales artificiales [28]

Función	Ecuación	Gráfica
Lineal	$y(x) = y$	

Función	Ecuación	Gráfica
Lineal a tramos	$y(x) = -1, x, 1$ $\text{si } x \leq -1$ $\text{si } -1 < x < 1$ $\text{si } x \geq 1$	
Gaussiano	$y(x) = Ae^{-Bx^2}$	
Rampa (RELU)	$y(x) = x, 0$ $\text{si } x \geq 0$ $\text{si } x < 0$	
Escalón	$y(x) = 1, 0$ $\text{si } x \geq 0$ $\text{si } x < 0$	
Tangente hiperbólica	$y(x) = \tanh x$	
Sigmoidal	$y(x) = \frac{1}{1 + e^{-x}}$	

3.2.19. Mecanismo de aprendizaje para el uso de redes neuronales artificiales.

El mecanismo de aprendizaje está relacionado con los procesos de adaptación hacia el entorno en donde se crean y se pueden modificar las representaciones con el propósito de explicar dicho entorno. Con esta idea, se puede mencionar que el aprendizaje es el proceso de modificación de los pesos de una red neuronal artificial, en respuesta a una información de entrada. Estos cambios que se producen en el proceso de aprendizaje los cuales se derivan en la eliminación, modificación y creación de interconexiones entre las neuronas, para la formación de un nuevo enlace también se encuentra involucrado el peso, de esta forma se logra obtener un valor que sea diferente de cero, cuando una conexión se elimina el valor del peso pasa a ser cero o no contienen ningún valor. Se puede confirmar que el proceso de aprendizaje de la red fue finalizado es decir la red ya logró aprender siempre y cuando los valores de los pesos se mantengan estables [11].

Según afirma [30] existen tres grandes categorías de aprendizaje automático.

3.2.19.1. Aprendizaje supervisado

Un algoritmo recibe un conjunto de entradas y sus correspondientes salidas, con el propósito que el algoritmo averigüe cuál será la salida para una entrada desconocida. Durante el entrenamiento la red neuronal artificial va ajustando los pesos de manera que se minimice la diferencia entre el valor de salida proporcionado y el valor de la salida objetivo. Algunos ejemplos de estos los algoritmos son conocidos como: regresión lineal, árboles de decisión, entre otras.

3.2.19.2. Aprendizaje no supervisado

Sin utilizar la relación que existe entre un conjunto de variables de entradas y salidas, el algoritmo de aprendizaje no supervisado utiliza sólo las entradas para desenterrar grupos, patrones y *clusters* a partir de una información previa. En este tipo de aprendizaje la red neuronal no recibe un vector de valores de salida objetivo es decir no recibe información ninguna información externa para intentar encontrar un patrón que le permita clasificar los valores de entrada.

3.2.19.3. Aprendizaje por refuerzo

En este tipo de aprendizaje, la red neuronal artificial no recibe un vector de salida objetivo, pero recibe información sobre si la salida proporcionada es la esperada o no [39].

3.2.20. Algoritmos de aprendizaje para el uso de redes neuronales artificiales

Como se mencionó anteriormente las redes neuronales artificiales tienen una cierta similitud al igual que su equivalente biológico, es decir que logran aprender a través de los entrenamientos, por esa razón la cantidad de datos que se encuentren disponibles para entrenar la red y las veces que la red sea entrenada (épocas) son directamente proporcionales a obtener mejores resultados de la predicción, esta información pronosticada es entregado por la red neuronal artificial que sea implementada [11].

En la figura 3.21, se muestra de forma agrupada algunos de los algoritmos que se pueden aplicar en la predicción de la demanda de energía eléctrica. El objetivo no es explicar la base matemática de cada uno de ellos sino mostrar algunos de los problemas que pretenden resolver. Logrando que el lector tenga noción y se pueda entender en que situaciones se pueden aplicarse.

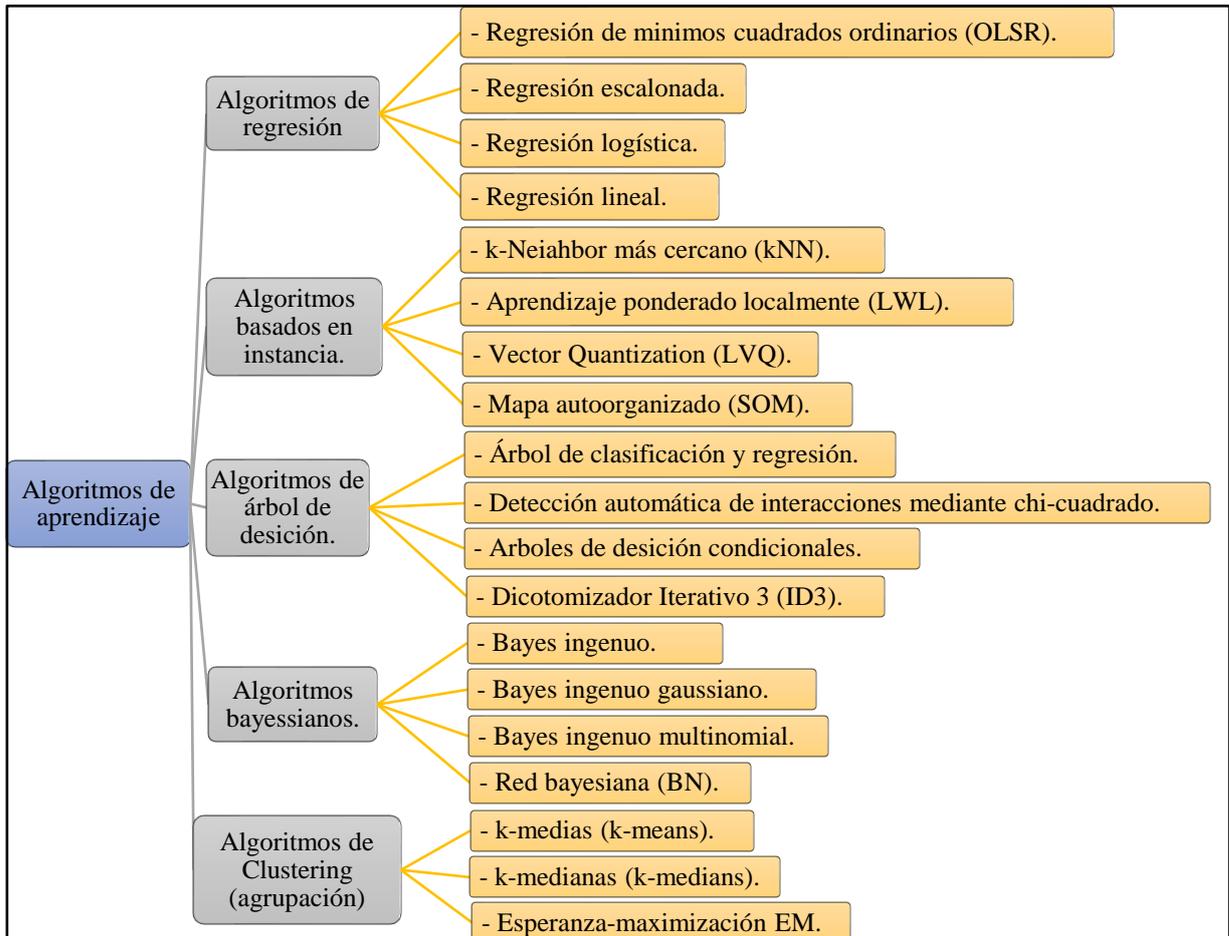


Figura 3.21: Clasificación de algoritmos para el uso de redes neuronales artificiales [40]

3.2.20.1. Algoritmos de regresión

Este tipo de algoritmos se aplican en modelos de aprendizaje automático supervisado que buscan estimar y determinar la existencia de relaciones entre variables que forman parte del objetivo de estudio. Para ello, se establece una variable dependiente para estudiar su comportamiento en relación con otra serie de variables independientes y/o cambiantes.

3.2.20.2. Algoritmos basados en instancias

Estos algoritmos se emplean en modelos de aprendizaje para resolver problemas de decisión con instancias de datos de entrenamiento que son importantes o requeridos por el modelo. Memoriza las instancias de entrenamiento y su clase, las instancias constituyen el conocimiento del sistema.

3.2.20.3. Algoritmos de árbol de decisión.

A través de estos algoritmos es posible construir modelos de decisiones basados en los valores de los datos analizados en sus atributos. Estos algoritmos suelen emplearse para resolver problemas de clasificación de datos y también para regresión. Suelen ser bastante rápidos y precisos en su ejecución y se pueden representarse fácilmente.

3.2.20.4. Algoritmos bayesianos

Estos algoritmos aplican el Teorema de Bayes y son empleados tanto para resolver problemas de clasificación como de regresión.

3.2.20.5. Algoritmos de Clustering (agrupación)

Es un tipo algoritmo de Machine Learning que está relacionado al aprendizaje no supervisado. Gracias a ellos se puede agrupar datos no etiquetados en categorías (clusters), es decir ayuda a organizar un conjunto de datos desordenados para agruparlos en varias categorías. Estos algoritmos realizan búsquedas a partir de un conjunto de datos, estableciendo una variable que representa el grupo y posteriormente de forma iterativa va asignando en cada punto de datos la variable establecida, según las características que se determinen [40].

3.2.21. Optimizadores de redes neuronales artificiales.

En primer lugar, cuando se entrena una red neuronal artificial se debe plantear como objetivo encontrar los pesos apropiados para cada una de los enlaces de la red, esto se consigue minimizando la función de coste, al mencionar función de coste se refiere a al cálculo del error

entre los valores reales y los valores que son pronosticados por la red. Cada uno de los optimizadores ayudan a minimizar el valor de la función de coste, esto se logra al generar pesos que cada vez sean más ajustados. Cabe recalcar que los optimizadores se basan en el cálculo del gradiente de la función de coste (derivada parcial) para cada uno de los pesos. A continuación, se menciona de forma resumida la variedad de optimizadores que son empleados en la predicción empleando redes neuronales artificiales.

3.2.21.1. SGD (Stochastic Gradient Descent)

Al escoger de forma aleatoria un conjunto de datos para calcular el descenso del gradiente y actualizar todos los pesos para buscar y encontrar una convergencia con mayor velocidad y precisión.

3.2.21.2. RMSprop (Root Mean Square prop)

Este optimizador emplea una media móvil de los cuadrados del descenso del gradiente para obtener el factor que influye en la variación de los pesos de la red.

3.2.21.3. Adaptive Gradient Algorithm (AdaGrad)

El optimizador denominado AdaGrad considera un factor de variación para cada uno de los pesos de la red, partiendo de un factor inicial.

3.2.21.4. Adaptive Adam (Adaptive moment estimation)

Este optimizador combina los conceptos de AdaGrad y RMSProp, para calcular un factor de entrenamiento relacionado a cada peso, también es necesario mencionar que utiliza el cálculo de RMSProp [11].

3.2.21.5. Adadelta

Este optimizador de aprendizaje por dimensión se adapta correctamente con respecto al tiempo, además elimina la necesidad de experimentar mediante un factor de aprendizaje. Adadelta es una variación del optimizador AdaGrad debido a que este método restringe el cálculo de gradientes anteriores que se acumulan con un tamaño fijo y en su lugar realiza una estimación específica aplicando gradientes recientemente calculados, de esta forma calcula un promedio exponencialmente decreciente al cuadrado [41].

3.2.22. Problemas derivados del entrenamiento en el uso de RNA.

El principal desafío que se presenta al trabajar con redes neuronales artificiales es el desarrollo del algoritmo, este debe tener un excelente rendimiento sobre la nueva información de entrada que no han sido estudiadas previamente, y no solo en aquellos rendimientos por las cuales el modelo de red neuronal artificial fue entrenado. Esta habilidad de lograr desempeñarse de forma correcta sobre las nuevas variables de entradas se denomina generalización.

En el desarrollo de un modelo mediante de redes neuronales, se debe tener acceso a un conjunto de datos que se denomina datos de entrenamientos y se puede calcular alguna medida relacionada con el error sobre este conjunto, que se denomina error de entrenamiento. Este error de entrenamiento se define como la esperanza del error sobre una nueva entrada. Esta esperanza se toma sobre diferentes entradas posibles mediante una selección de variables, extraídas a partir de la distribución de entradas, lo que se espera que el sistema logre encontrar en los entrenamientos previos. Es usual evaluar el error de generalización del modelo implementado calculando el rendimiento sobre un nuevo conjunto de datos denominado datos de validación, la cual contiene ejemplos que se lograron obtener separadamente del conjunto de entrenamiento [42].

3.2.22.1. Overfitting

El criterio de overfitting está relacionado a los entrenamientos y la cantidad de iteraciones empleados en un modelo planteado, la capacidad de predicción que no puede mejorar debido al sobreentrenamiento. De forma matemática es posible obtener una función que ajuste para cualquier conjunto de datos ya sean de entrenamiento, validación o prueba. Sin embargo, el modelo genera mayor complejidad si se quiere minimizar el error de entrenamiento. Este aumento de la complejidad solo producirá un ajuste de peor calidad, es decir, mientras mayor aumente los entrenamientos de la red se obtendrá un sobreentrenamiento y afectará a los resultados pronosticados.

3.2.22.2. Underfitting

Este caso es contrario al anterior debido a que el modelo de la red neuronal artificial no puede mantenerse ajustado lo suficiente debido al escaso tiempo en los entrenamientos o la falta de conseguir resultados correctos por carecer de suficientes entrenamientos. Es un problema que se puede detectar con facilidad.

3.2.22.3. Normal fitting

El normal fitting se relaciona con el punto de entrenamiento adecuado para el modelo de la red. El error correspondiente a una serie de entrenamientos y en la generación de datos pronosticados deben ser lo más cercano posible a los datos reales. De esta forma el modelo tiene una complejidad adecuada para obtener un comportamiento robusto, a diferencia de los criterios mencionados anteriormente, este, se debe tener en consideración para desarrollar un correcto modelo de predicción [43].

3.2.23. Criterios para la validación de los resultados aplicando un método de análisis.

3.2.23.1. Error medio cuadrático (MSE – mean square error)

Este error representa el promedio de todas las diferencias entre la salida obtenida y la salida que se deseada obtener, utilizando la ecuación 3.15 [11]. Esta medida se penaliza los errores mayores en la predicción, debido a que cada error es elevado al cuadrado. La predicción es mejor cuando más pequeño es el valor del MSE [29].

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2 \quad (3.15)$$

3.2.23.2. Raíz del Error Medio Cuadrático (Root Mean Squared Error – RMSE)

Este error es simplemente el resultado de extraer la raíz del Error Medio Cuadrático (MSE), utilizando la ecuación 3.16.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (3.16)$$

3.2.23.3. Error Medio Absoluto (Mean Absolute Error MAE)

Este error está representado por el promedio del valor absoluto de la diferencia entre la salida de los datos reales y la salida de los datos pronosticados, este valor se obtiene utilizando la ecuación 3.17.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}| \quad (3.17)$$

3.2.23.4. Error Medio Absoluto Porcentual (Mean Absolute Percentage Error - MAPE)

Este error está relacionado con el promedio de los errores absolutos el resultado de este error está expresado en términos de porcentaje tal como se observa en la ecuación 3.18 [11].

$$MAPE = \sum_{i=1}^N \left| \frac{y_i - \hat{y}}{y_i} \right| \times 100\% \quad (3.18)$$

3.2.23.5. Error residual

Según [44] define al error residual como la diferencia entre el valor estimado y el valor real. Para lograr calcular el error residual se utiliza la ecuación 3.19.

$$e_r = y_i - \hat{y} \quad (3.19)$$

3.2.23.6. Error estándar múltiple

El error estándar múltiple, mide la dispersión de los datos obtenidos en la predicción [45]. Su cálculo está representado por la ecuación 3.20.

$$EEM = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y})^2}{(N - k - 1)}} \quad (3.20)$$

Donde:

y_i = valor histórico real de la variable independiente

\hat{y} = Valor estimado de la variable independiente

N = Cantidad de datos utilizados

k = Número de variables independientes

3.2.24. Lenguaje de programación Python versión 3.8.6

El lenguaje de programación Python es el lenguaje elegido para muchas aplicaciones en el análisis de datos avanzados por una buena razón. Es uno de los lenguajes de programación avanzada más fáciles de aprender. Python es una forma sencilla de realizar una gran variedad de investigaciones relacionadas con el análisis de datos [30].

3.2.24.1. Librería Numpy

La librería Numpy es el paquete de Python principal para la informática científica. Donde proporciona estructuras de datos (realizando matrices y matrices multidimensionales) en la que se tiene varios elementos que están almacenado es sus respectivas ubicaciones de memoria, y con los que se pueden trabajar con todas las operaciones que puedan ser involucradas [9].

3.2.24.2. Librería Pandas

Pandas es una librería para facilitar la manipulación y el análisis de los datos. Consta de dos estructuras de datos: series y dataframes. Está implementada sobre la librería NumPy. Algunas de las muchas características que tiene es de agrupar datos, filtrarlos, convertirlos, unirlos o usar series temporales [46].

3.2.24.3. Librería Matplotlib

Corresponde a un módulo en Python que además de crear gráficos, histogramas, visualizaciones de líneas, barras y diagramas de dispersión, entre otros, puede hacer visualizaciones en 2D o 3D dependiendo su aplicación. Es la librería más utilizada en Python, para ciencia de datos. Su éxito está basado en la facilidad que brinda a los desarrolladores, a la hora de diseñar visualizaciones con datos a partir de muy pocas líneas de código, mezclada con la posibilidad de incluir esos gráficos en cualquier proyecto web [47].

3.2.24.4. Librería Scikit-Learn

Scikit Learn es una librería de código abierto, proporciona una gama de algoritmos de aprendizaje supervisados y no supervisados que implementa una gran variedad de algoritmos de aprendizaje automático (regresión, clasificación, agrupación). Esta librería está construida sobre SciPy e incluye soporte para varias librerías o paquetes, como Numpy, Pandas, SciPy, Matplotlib, IPy, SymPy, etc [9].

3.2.24.5. Librería Keras

Esta librería dispone de una *frontend* para la modelización de sistemas neuronales y un *backend* computacional para el entrenamiento de éstos. La modelización es el punto fuerte de esta librería, ya que ofrece una API sencilla y modular para la definición de sistemas neuronales. Es interesante observar la evolución y supervivencia de esta librería gracias a su simplicidad a la hora de definir modelos y cómo se ha convertido en parte fundamental de otras librerías para la definición de modelos de alto nivel.

3.2.24.6. Librería Tensorflow

Es una librería de código abierto para el aprendizaje automático desarrollada por Google. La librería Tensorflow es un paquete de Python para aprendizaje automático. El nombre de la librería hace referencia a cómo ésta procesa la información, ya que un tensor es una matriz de números y el flujo de éstas son las operaciones que se realizan para transformarlas [48]. Algunas características de esta librería se mencionan a continuación:

- Fácil construcción de modelos. - Se cuenta con múltiples niveles de abstracción para que pueda elegir el más adecuado para sus necesidades. Permite crear y entrenar modelos utilizando la API de keras de alto nivel.
- Robusta producción de aprendizaje automático. - Permite entrenar e implementar su modelo fácilmente, sin importar el idioma o la plataforma que utilice.
- Potente experimentación para la investigación. – Permite construir y entrenar modelos de última generación sin sacrificar velocidad o rendimiento. TensorFlow cuenta con un ecosistema de potentes bibliotecas [28].

4. METODOLOGÍA

Una vez terminado el capítulo anterior ya se obtiene un conocimiento previo relacionado con la demanda de energía eléctrica y redes neuronales artificiales. Este nuevo capítulo tiene el objetivo de detallar las fases necesarias para la construcción del modelo de red neuronal artificial a implementarse. Evaluando del modelo construido con los datos reales y de esta manera dar solución al problema planteado.

A continuación, se presenta el tipo de investigación y el método de investigación en los cuales se basa nuestra investigación.

4.1. TIPO DE INVESTIGACIÓN

Este proyecto de investigación revela la situación del sistema de generación relacionado con la predicción a corto plazo de la demanda de energía eléctrica donde la CENTRAL HIDROELÉCTRICA ILLUCHI 2 involucra una gran cantidad de información de la demanda de energía eléctrica en diferentes momentos que se encuentra en operación, para lo cual se despliega una serie de alternativas que permitan analizar la variación de la demanda de la energía eléctrica.

4.1.1. Investigación descriptiva

En primer lugar, para descomponer las características o rasgos de la situación, fenómeno u objeto de estudio en sus diversas características para lograr alcanzar un mejor entendimiento técnico. En este caso se realiza un reconocimiento de hechos e ideas para definir las situaciones del comportamiento en la CENTRAL HIDROELÉCTRICA ILLUCHI 2, adquiriendo una base de datos históricos con valores de la corriente, la potencia y la demanda de energía eléctrica, adicionalmente se crea una vista previa del funcionamiento de la central.

4.1.2. Investigación diagnóstica

Esta forma de investigación ofrece acceso a las características del problema planteado mediante datos de campo, ayudando a comprender la situación actual por la cual se encuentra sometido la CENTRAL HIDROELÉCTRICA ILLUCHI 2 en los sistemas de generación, identificando los factores analizar para adentrar más al problema que ha planteado, ayudando a obtener un análisis mediante los datos históricos para obtener una alternativa que brinde una solución al problema de la demanda de la energía eléctrica.

4.1.3. Investigación aplicada

En esta parte de la investigación se pondrá en práctica todos los conocimientos técnicos y científicos que se han adquirido, mediante uso del programa computacional Python que ayuda a desarrollar los análisis necesarios y la programación de un algoritmo que permita realizar el pronóstico de la demanda de energía eléctrica para obtener resultados suficientemente aproximados a los valores reales.

4.2. MÉTODO DE INVESTIGACIÓN

4.2.1. Metodología de la investigación bibliográfica

La investigación bibliográfica ayuda con el desarrollo del análisis, el cual se basa en indagar en documentos físicos o digitales como: artículos científicos, libros, trabajos de fin de grado y publicaciones en internet, que estén relacionados con la demanda de energía eléctrica, la aplicación de redes neuronales artificiales e información necesaria sobre el programa computacional Python. Lo que se ha proporcionado a la formulación de teorías, hipótesis, análisis y resultados, este es un procedimiento necesario para lograr solucionar el problema planteado.

4.2.2. Inductivo – deductivo

Este método de investigación examina de forma descriptiva todos los temas y subtemas que se emplearon en el desarrollo del presente trabajo de investigación, este procedimiento ayuda a formular las conclusiones y recomendaciones que surgieron a través de todo el proceso de investigación. En relación a los métodos aplicados se analizó cada uno de las metodologías existentes para el pronóstico de la demanda de energía eléctrica, a partir del análisis de investigaciones desarrolladas en diferentes áreas, se desarrolló la implementación de un algoritmo que permitió obtener los datos pronosticados, de esta forma elaborando propios criterios para recomendar trabajos futuros que pueden ser elaborados y hasta mejorarlos en este tipo de investigaciones.

4.3. TÉCNICAS E INSTRUMENTOS

4.3.1. Procedimiento a través de un diagrama de flujo para realizar la predicción de la demanda de energía eléctrica mediante la aplicación de redes neuronales artificiales.

Al haber indagado toda la información fundamental se plantea elaborar el procedimiento para predecir la demanda de energía eléctrica mediante redes neuronales artificiales, presentándose de la siguiente forma.

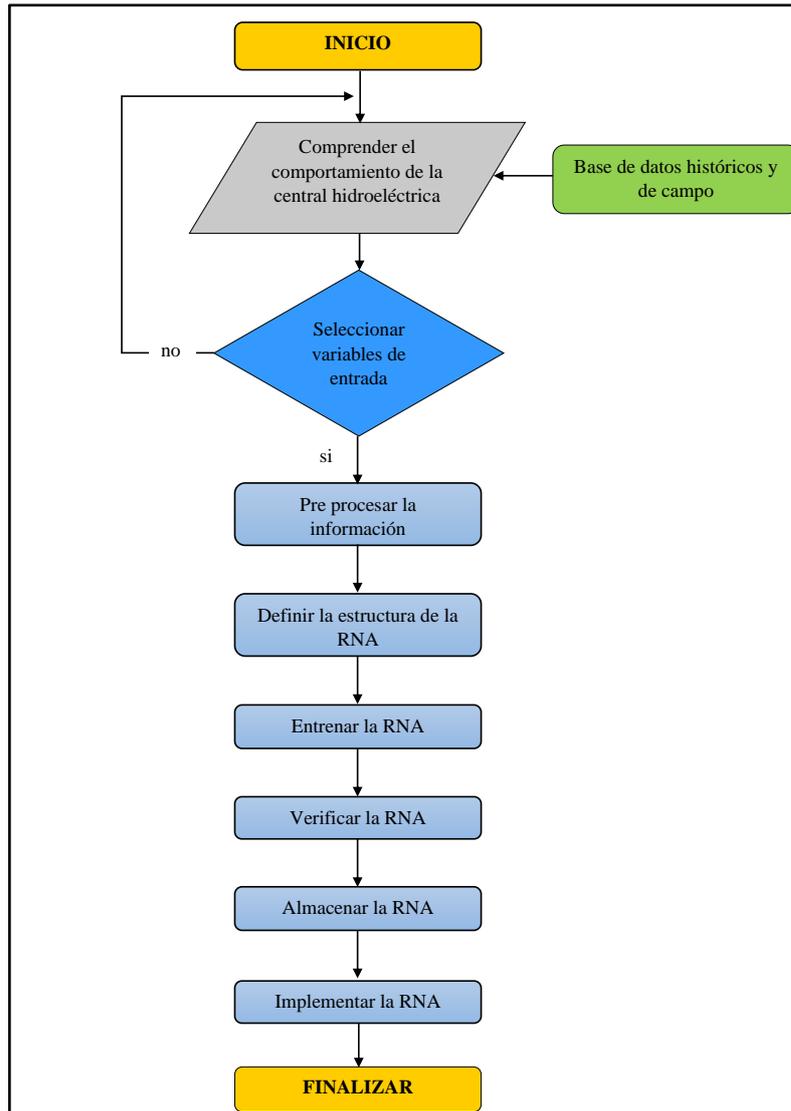


Figura 4.1: Flujograma metodológico empleado para la predicción de la demanda de la energía eléctrica utilizando redes neuronales artificiales

Fuente: Los autores

El esquema presenta el procedimiento para lograr construir el modelo de red neuronal, tal como se lo representa en el diagrama de flujo presentado en la figura 4.1. Los pasos principales de este modelo de pronóstico de demanda de consumo de energía propuesto son los siguientes:

- **Paso 1.-** En primer lugar, se plantea comprender el comportamiento la variación de la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2 este paso está relacionado a buscar toda la información que permita conocer de correcta manera la operación de la central (análisis de las curvas de la demanda de energía eléctrica, semanal, fines de semana y diario). El resultado final de este paso permite comprender toda la base de datos históricos y para los datos de campo se utilizará la técnica de fotogrametría que permite mediante la obtención de una o varias fotografías obtener el área, el perímetro del tanque estudiado y la profundidad del fluido se obtendrá mediante mediciones.

La CENTRAL HIDROELÉCTRICA ILLUCHI 2 cuenta con diferentes características con respecto a la central hidroeléctrica Illuchi 1, debido a que es una central de paso. Esta central fue construida en el año 1984 por lo tanto sus equipos tienen mayor vida útil, y hasta la fecha se encuentra funcionando de manera adecuada. Esta central utiliza el agua turbinada que sale de la central hidroeléctrica Illuchi 1 para producir la energía eléctrica; esto con el fin de aprovechar la energía potencial del agua tal como se presenta en las figuras 4.2 y 4.3 [15].



Figura 4.2: Tubería de presión perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2

Fuente: Los autores



Figura 4.3. Tubería de presión perteneciente a la CENTRAL HIDROELÉCTRICA ILLUCHI 2 [15]

Es necesario obtener una base de datos previa, de esta forma hacer una estimación de una posible técnica de predicción que se pretende utilizar. Un punto de partida que se propone emplear, es visualizando el comportamiento de la demanda máxima utilizando el 100 % del total de nuestra base de datos, (año 2 010 hasta el año 2 019) obtenidos en la figura 4.4.

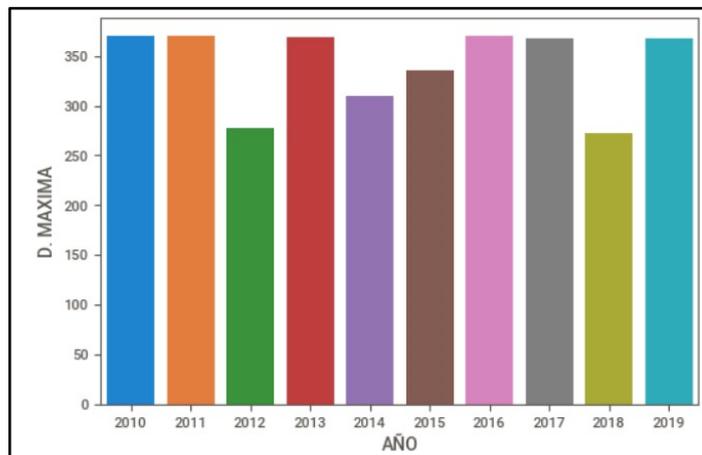


Figura 4.4: Comportamiento de la demanda de energía eléctrica procedente de una base de datos

Fuente: Los autores

- **Paso 2.-** Seleccionar las variables de entrada de la base de datos acorde a la aplicación. En base a los datos adquiridos en el paso 1, se plantea seleccionar las variables de entrada que influyan en la variación de la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

La selección de las variables de entrada que se presenta en la tabla 4.1, utilizados para la predicción de la demanda de energía eléctrica se desarrolla previo a una base de datos que está compuesta por varios documentos en Excel, estos datos fueron recogidas por los operadores de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, desde el año del 2 010 hasta el año del 2 019.

Tabla 4.1: Selección preliminar de las variables para la predicción de la demanda de energía eléctrica

Variable	Descripción	Unidad de medida
Año	Tiempo de consumo de energía eléctrica	Año
Mes	Tiempo de consumo de energía eléctrica	Mes
Día	Tiempo de consumo de energía eléctrica	Día
Hora	Tiempo de consumo de energía eléctrica	Hora
Energía consumida	Energía activa consumida en Kilovatio-Hora	KWh

Fuente: Los autores

- **Paso 3.-** El tercer paso se encuentra la validación y preprocesamiento de los datos seleccionados como variables de entrada. La red neuronal artificial debe aprender y predecir en función de los datos históricos de las variables antes mencionadas. Se eliminarán la mayoría de datos erróneos que existieron, para luego preprocesarlos mediante el lenguaje de programación denominado “Python” tal como se muestra en la figura 4.5.

```

#Variable categórica DIA a numérica
#TODO Borrar al final de cuentas no se usa este dato
data['DIA'] = data['DIA'].map({'lunes': 1 ,
                              'martes': 2,
                              'miercoles': 3,
                              'miércoles': 3,
                              'jueves': 4 ,
                              'viernes': 5,
                              'sábado': 6,
                              'sabado': 6, #inconsistencia en la data por las tildes
                              'domingo': 7})

data.tail(50)
# data.to_csv('data_total.csv')

```

	AÑO	MES	DIA	FECHA	HORA	KW-H
43774	2019	12	7	29	22	3200
43775	2019	12	7	29	23	2800
43776	2019	12	1	30	0	2400
43777	2019	12	1	30	1	2400
43778	2019	12	1	30	2	2000
43779	2019	12	1	30	3	2000

Figura 4.5: Validación y preprocesamiento de la información procedente de una base de datos

Fuente: Los autores

- **Paso 4.-** Como cuarto paso se encuentra la definición la red neuronal artificial es decir la arquitectura de la red como: el número de neuronas de entrada, oculta y salida, el número de capas ocultas, número de enlaces entre las diferentes neuronas, funciones de activación empleados. Este paso es el más importante debido a que dependerá de una gran cantidad de entrenamientos y conseguir experiencias de las predicciones, es necesario comparar entre diferentes estructuras de la red para encontrar el que mejor se ajuste a nuestras necesidades. En la figura 4.6 se presenta el diagrama de flujo necesario para la aplicación del algoritmo de predicción planteado.

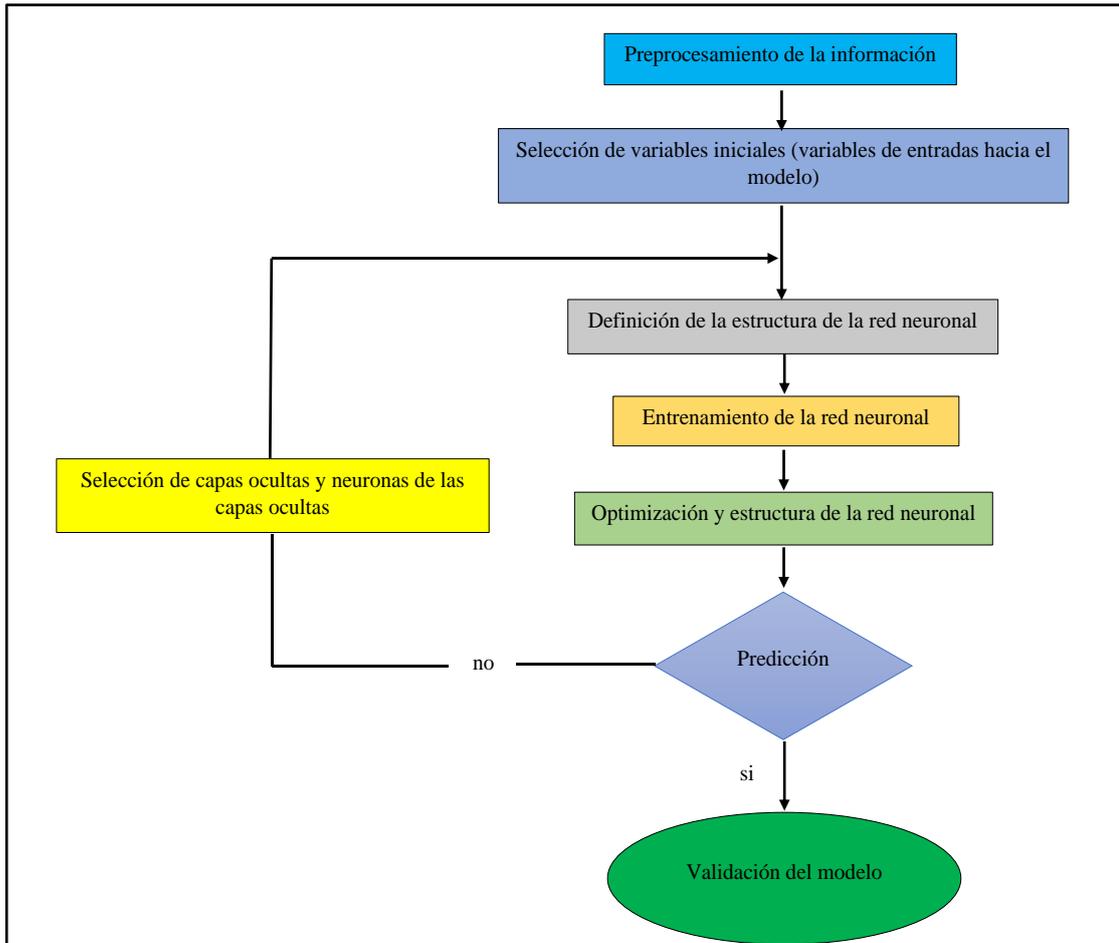


Figura 4.6: Flujograma del algoritmo utilizado para la predicción de la demanda eléctrica

Fuente: Los autores

El pseudocódigo inicia sistema con la llamada a `Sequential()`, este comando crea una red neuronal artificial vacía a la que se debe agregar las capas correspondientes mediante la instrucción `model.add()`. La siguiente capa en ser agregada es de tipo LSTM, el comando aplicado es `return_sequences = True`, se utiliza para que la salida del estado oculto de cada una de las neuronas se use como entrada para la siguiente capa LSTM creando una secuencia, mientras que el valor de 1 es el número de neuronas que contiene cada capa, en si la red neuronal recurrente consta de una primera capa LSTM con 1 neurona (capa de entrada), una segunda capa LSTM con `num_neuronas` (capa oculta), adicionalmente se agrega una capa de congelamiento de neuronas para evitar overfitting, una tercera capa LSTM con `num_neuronas` (capa oculta) y por último una capa con una sola neurona de salida (no es LSTM). Cada uno de los criterios mencionados se presenta en la figura 4.7.

```

#MODELO
from keras.layers import LSTM
from sklearn.metrics import mean_squared_error

def NN_LSTM(optimizador, neuronas, epocas):
    dim_entrada = (X_train.shape[1],X_train.shape[2])
    dim_salida = 1
    num_neuronas = neuronas

    modelo = Sequential()
    #Primera capa LSTM con 1 neurona (Capa de entrada)
    #Segunda capa LSTM con num_neuronas (Capa oculta)
    modelo.add(LSTM(units=num_neuronas, return_sequences = True, input_shape=dim_entrada))
    #Esto no es una capa de neuronas, solo es una capa de congelamiento de neuronas
    #congela el 40% de las neuronas para evitar overfitting
    modelo.add(Dropout(0.4))
    # Tercera capa LSTM con num_neuronas (Capa oculta)
    modelo.add(LSTM(units=num_neuronas))
    # modelo.add(Dropout(0.2))
    #Cuarta y última capa (no es LSTM) tiene una sola neurona de salida
    modelo.add(Dense(units = dim_salida))
    modelo.compile(optimizer= optimizador, loss='mse', metrics = ['mean_absolute_error']) #mean_squared_error

    #Entrenamiento
    history = modelo.fit(X_train, Y_train, epochs = epocas, batch_size = 64)
    return modelo, history

def predDataTest(modelo):
    x_test = data_test.values
    x_test = sc.transform(x_test)
    # # x_test
    X_test = []
    for i in range(time_step, len(x_test)):
        X_test.append(x_test[i-time_step: i, 0])
    X_test= np.array(X_test)
    X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
    X_test.shape
    prediccion = modelo.predict(X_test)
    prediccion = sc.inverse_transform(prediccion)
    return prediccion

```

Figura 4.7: Pseudocódigo elaborado para el desarrollo de un modelo de predicción de la demanda de energía eléctrica

Fuente: Los autores

- **Paso 5.-** Este paso se centra en el entrenamiento de la red neuronal artificial, para ello se debe tener en consideración los criterios de aprendizaje, el número de iteraciones, la aplicación de un conjunto de datos de entrenamiento. Al aplicar este paso se deberán asignar los valores finales, tanto en el número de retrasos y el algoritmo de entrenamiento a emplear para minimizar la función de coste aplicando el valor del criterio para la validación de los resultados.

Para el entrenamiento se selecciona inicialmente 3 epochs de entrenamiento, debido que se recomienda iniciar con un número pequeño y luego ir incrementando. Un epoch es el número de veces que se ejecuta el algoritmo de la red neuronal. En cada ciclo (epoch) todos los datos de entrenamiento pasan por la red neuronal para que esta logre aprender sobre ellos [49].

```

#Entrenamiento
history = model.fit(X_train, Y_train, epochs = epocas, batch_size = 64)
return model, history

def predDataTest(modelo):
    x_test = data_test.values
    x_test = sc.transform(x_test)
    # # x_test
    X_test = []
    for i in range(time_step, len(x_test)):
        X_test.append(x_test[i-time_step: i, 0])
    X_test = np.array(X_test)
    X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
    X_test.shape
    prediccion = modelo.predict(X_test)
    prediccion = sc.inverse_transform(prediccion)
    return prediccion

#rmsprop LOS MEJORES RESULTADOS
model, history = NN_LSTM(optimizador = 'rmsprop', neuronas = 10, epocas = 3)
#Guardamos el modelo para no tener que entrenar otra vez para probar
model.save('modelos/model.h5')

2022-01-23 00:54:50.298835: I tensorflow/core/platform/cpu_feature_guard.cc:145] This TensorFlow binary is optimized with Intel(R) MKL-DNN to use the fo
llowing CPU instructions in performance critical operations: SSE4.1 SSE4.2 AVX AVX2 AVX512F FMA
To enable them in non-MKL-DNN operations, rebuild TensorFlow with the appropriate compiler flags.
2022-01-23 00:54:50.299985: I tensorflow/core/common_runtime/process_util.cc:115] Creating new thread pool with default inter op setting: 8. Tune using
inter_op_parallelism_threads for best performance.
Epoch 1/10
35748/35748 [=====] - 129s 4ms/step - loss: 0.0236 - mean_absolute_error: 0.0933
Epoch 2/10
35748/35748 [=====] - 142s 4ms/step - loss: 0.0059 - mean_absolute_error: 0.0520
Epoch 3/10
35748/35748 [=====] - 157s 4ms/step - loss: 0.0043 - mean_absolute_error: 0.0428
Epoch 4/10
35748/35748 [=====] - 140s 4ms/step - loss: 0.0037 - mean_absolute_error: 0.0391
Epoch 5/10
35748/35748 [=====] - 169s 5ms/step - loss: 0.0035 - mean_absolute_error: 0.0376
Epoch 6/10
35748/35748 [=====] - 145s 4ms/step - loss: 0.0034 - mean_absolute_error: 0.0368
Epoch 7/10
35748/35748 [=====] - 156s 4ms/step - loss: 0.0034 - mean_absolute_error: 0.0362

```

Figura 4.8: Modelo para el entrenamiento de la red neuronal recurrente implementado

Fuente: Los autores

La librería de Keras ofrece varios optimizadores que se emplean en los entrenamientos de una RNA, como se observa en la figura 4.8.

- **Paso 6.-** Como siguiente paso se encuentra la verificación de la red neuronal artificial, mediante un conjunto de datos denominados datos de validación. La verificación del funcionamiento de la red neuronal artificial se la realiza al predecir valores de la demanda de energía eléctrica con nuevos datos que no han sido utilizados en los entrenamientos anteriores para luego compararlos con datos reales.

Conjunto de entrenamiento: mediante los datos de entrenamiento se ajustan los parámetros de la red neuronal, como por ejemplo los pesos que interconectan las neuronas en las diferentes capas. Para ello se utiliza algún método de entrenamiento supervisado, para intentar predecir la salida a partir de los datos de entrada. Habitualmente este conjunto de datos representa alrededor del 70 % de toda la base de datos.

Conjunto de validación: cuando se cree que se ha obtenido un modelo ajustado, se utilizan nuevos datos para realizar una nueva predicción de la demanda. Los datos de validación permiten detectar insuficiencias en el modelo para modificar su estructura (cantidad de neuronas en la capa oculta). Habitualmente este conjunto de datos representa un 10 % de nuestra base de datos.

Conjunto de testeo: estos datos se utilizan para realizar una evaluación final del modelo. Habitualmente se representa un 20 % de los datos [39].

Una vez analizado las variables del modelo, los datos se dividen en tres grupos: entrenamiento, prueba y validación. Se utilizan los porcentajes 80 % y 20 % respectivamente tal como se presenta en la figura 4.9, estos porcentajes se modificarán al menos que los responsables lo crean necesario.



Figura 4.9: Partición de los datos en subconjuntos para la predicción de la demanda eléctrica

Fuente: Los autores

En la partición de los datos en subconjuntos se comprende la función de pérdida (loss), y el error medio absoluto (MAE) tal como se muestra en la figura 4.10.

Epoch 1/10	35748/35748 [=====]	- 129s 4ms/step -	0.0236 - mean_absolute_error: 0.0933
Epoch 2/10	35748/35748 [=====]	- 142s 4ms/step -	0.0059 - mean_absolute_error: 0.0520
Epoch 3/10	35748/35748 [=====]	- 157s 4ms/step -	loss: 0.0043 - mean_absolute_error: 0.0428
Epoch 4/10	35748/35748 [=====]	- 140s 4ms/step -	loss: 0.0037 - mean_absolute_error: 0.0391
Epoch 5/10	35748/35748 [=====]	- 169s 5ms/step -	loss: 0.0035 - mean_absolute_error: 0.0376
Epoch 6/10	35748/35748 [=====]	- 145s 4ms/step -	loss: 0.0034 - mean_absolute_error: 0.0368
Epoch 7/10	35748/35748 [=====]	- 156s 4ms/step -	loss: 0.0034 - mean_absolute_error: 0.0362
Epoch 8/10	35748/35748 [=====]	- 162s 5ms/step -	loss: 0.0033 - mean_absolute_error: 0.0358
Epoch 9/10	35748/35748 [=====]	- 156s 4ms/step -	loss: 0.0033 - mean_absolute_error: 0.0354
Epoch 10/10	35748/35748 [=====]	- 165s 5ms/step -	loss: 0.0033 - mean absolute error: 0.0352

Figura 4.10: Función de pérdida y el error medio absoluto para validar los entrenamientos de la RNA

Fuente: Los autores

- **Paso 7.-** Como penúltimo paso se encuentra el almacenamiento de los parámetros de la red neuronal artificial una vez verificada. Es necesario almacenar los entrenamientos de la red neuronal artificial para aplicarlos en un futuro estudio, este paso ayuda a no tener la necesidad de repetir los dos últimos pasos, al menos que los responsables de este estudio lo crean necesario.
- **Paso 8.-** Finalmente se debe implementar la red neuronal artificial para la predicción de la demanda de energía eléctrica mediante la aplicación de una interfaz gráfica, amigable con el usuario de esta forma ayuda a proporcionar resultados que se plantean pronosticar.

Es necesario crear la interfaz tal como se muestra en la figura 4.11, con la ayuda de Python y Visual Studio Code y así obtener un correcto funcionamiento del programa computacional para pronosticar la demanda eléctrica de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, cada módulo tiene asociada una interfaz gráfica de usuario (GUI).

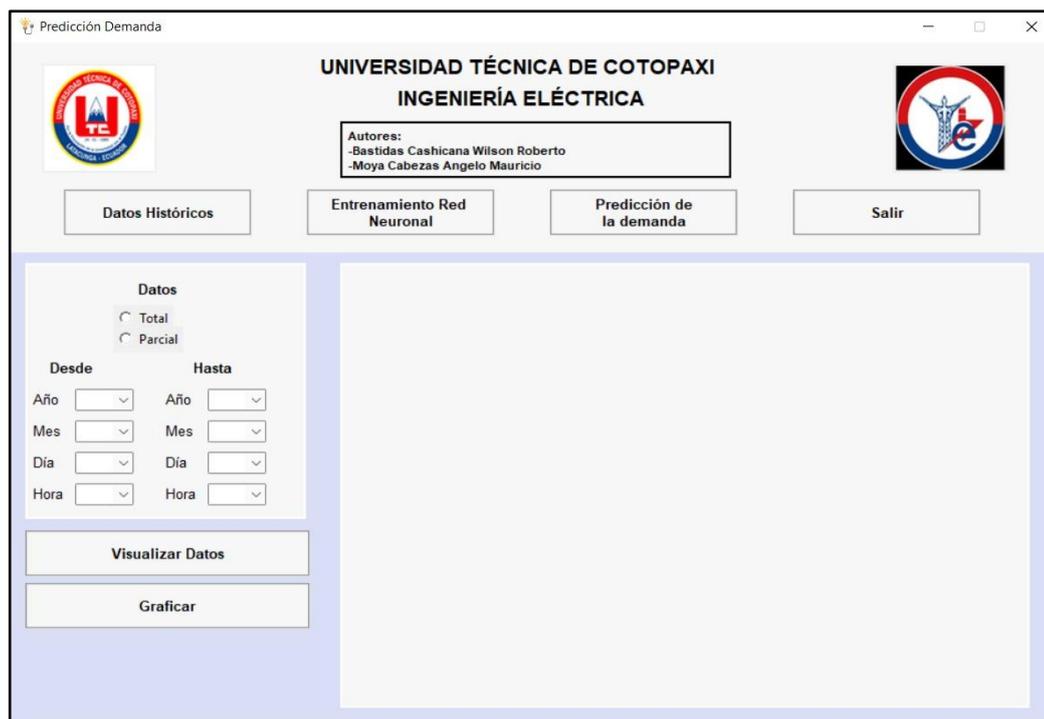


Figura 4.11: Propuesta de la interfaz gráfica para la predicción de la demanda de energía eléctrica

Fuente: Los autores

En resumen, todos estos pasos mencionados anteriormente son un punto de partida para la lograr implementar un modelo de red neuronal artificial y posteriormente presentar la interfaz.

5. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS

Como en el capítulo 4 se propone definiciones como: el tipo de neurona, funciones de activación, algoritmos de entrenamiento se utilizarán, en este capítulo se presentan los resultados del entrenamiento y validación de nuestra RNA propuesta y creada a través del lenguaje de programación Python. Para el aprendizaje y validación de la RNA se utiliza datos diarios del último año (año 2019). Además, se compara la predicción de la demanda de energía eléctrica utilizando redes neuronales artificiales con la que existe actualmente en ELEPCO S.A. la cual es regresión lineal simple, esto para evidenciar la bondad de la RNA para la aplicación y finalmente se presenta los resultados de la predicción de la demanda de energía eléctrica.

5.1. ANÁLISIS DE LA CENTRAL HIDROELÉCTRICA ILLUCHI 2

Una vez que se analizó el comportamiento de la demanda utilizando el total de nuestra base de datos. Se procede a utilizar el 50 % de nuestra base de datos que están comprendidos entre el 2015 hasta el 2019 escogiendo los valores máximos para representar la variación de la demanda de energía eléctrica. En la figura 5.1, los meses de Enero, Abril, Julio, Agosto y Diciembre son los meses que se consume gran cantidad energía eléctrica, lo que no pasa con el mes de Septiembre que es el mes que tiene una demanda menor a los demás meses del año.

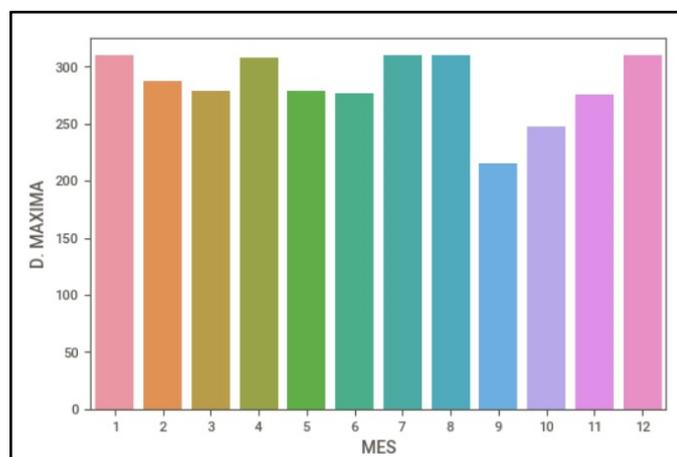


Figura 5.1: Análisis de la demanda de energía eléctrica por un periodo de un año

Fuente: Los autores

Como se puede visualizar en la figura 5.1, existe un consumo mínimo en el mes de Septiembre, una de las razones por la cuales existe una disminución en el consumo de energía es debido a que en la provincia de Latacunga entra en una etapa de festividades tradicionales que se celebran cada año y en consecuencia el sector industrial, residencial realizan menos actividades, otra de

la razones está relacionada con los estudiantes universitarios que estudian en la provincia y se encuentran en vacaciones, estos estudiantes toman la decisión de regresar a su provincia de origen. Los meses que siguen a continuación, progresivamente aumentan su consumo debido a que varios sectores como el sector comercial y residencial requieren de mayor energía eléctrica, este es el caso de Diciembre y Enero, al ser las fechas que se utilizan una gran variedad de iluminación como las luces navideñas y en consecuencia aumenta la demanda de energía eléctrica.

De la misma manera que el caso anterior se utilizó la información de la demanda máxima de cada mes para mostrar la variación que está sujeta a los elementos que consumen la energía eléctrica en la central hidroeléctrica. Tal como se muestra en la figura 5.2, donde la demanda máxima se mantiene constante durante los primeros 28 días, formándose una variación durante los últimos días del mes.

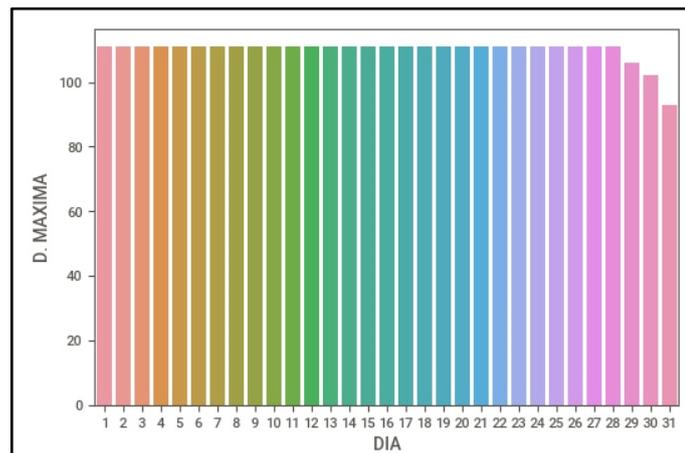


Figura 5.2: Análisis de la demanda de energía eléctrica mensual por un periodo de 5 años

Fuente: Los autores

Una de las razones por las cuales la demanda varía en los últimos tres días del mes planteado es debido a que todos los meses no tienen exactamente 31 días, un claro ejemplo es febrero las cuales tiene 28 o 29 días cuando es año bisiesto, noviembre también tiene 30 días. Son factores que afecta en la variación de la demanda.

Las figuras 5.3 y 5.4, ayudan a comprender el comportamiento de la demanda máxima de cada uno de los grupos generadores que está compuesto la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

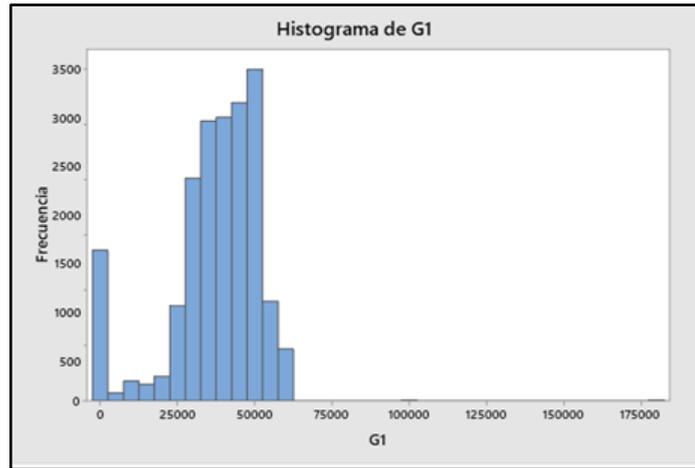


Figura 5.3: Comportamiento de la demanda de energía eléctrica en el generador 1

Fuente: Los autores

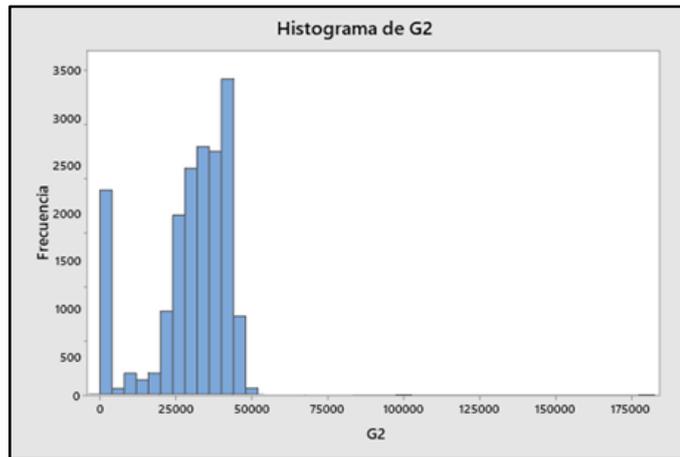


Figura 5.4: Comportamiento de la demanda de energía eléctrica en el generador 2

Fuente: Los autores

Cabe recalcar que el estudio no está centrado en la demanda de energía eléctrica en cada uno de los generadores, sino de forma global.

5.2. ANALISIS DE CORRELACIÓN DE LA INFORMACIÓN DE LA CENTRAL HIDROELÉCTRICA ILLUCHI 2

Uno de los dilemas que se presentan al momento de depurar la base de datos original es conocer si las variables pueden tener un comportamiento similar, es decir si están correlacionadas una a la otra. Esto se muestra en la figura 5.5, las variables de año, mes, día, hora, demanda de energía eléctrica si tienen un comportamiento similar es decir están correlacionadas.

	DIA	MES	AÑO	G1	G2	TOTAL	D. MAXIMA
DIA	1.000000	0.011726	-0.006109	-0.012916	-0.028274	-0.027828	-0.019256
MES	0.011726	1.000000	0.042998	-0.100125	0.069436	-0.014784	-0.000606
AÑO	-0.006109	0.042998	1.000000	0.114879	0.140095	0.169962	0.001297
G1	-0.012916	-0.100125	0.114879	1.000000	0.134210	0.723899	0.062664
G2	-0.028274	0.069436	0.140095	0.134210	1.000000	0.780818	0.076846
TOTAL	-0.027828	-0.014784	0.169962	0.723899	0.780818	1.000000	0.093008
D. MAXIMA	-0.019256	-0.000606	0.001297	0.062664	0.076846	0.093008	1.000000

Figura 5.5: Información relevante de las variables para la predicción de la demanda de energía eléctrica

Fuente: Los autores

Otra forma de demostrar esta correlación de variables es mediante un mapa de calor tal como se muestra en la figura 5.6.

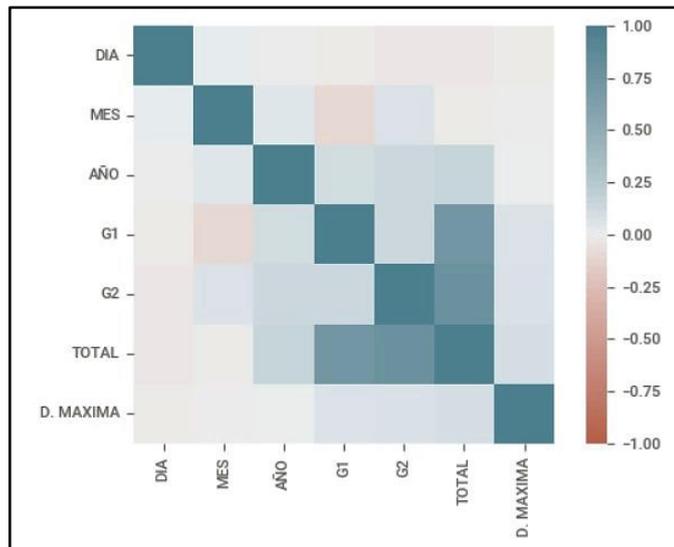


Figura 5.6: Mapa de calor para verificar la correlación entre las variables de entrada

Fuente: Los autores

El mapa de calor muestra las relaciones entre múltiples variables. Las áreas que están marcadas de color verde permiten entender que están perfectamente relacionadas, esta es una de las razones principales por las cuales se han seleccionado las variables que ayudarán a realizar la predicción, además con el mapa de calor se puede analizar los grupos generados con respecto al comportamiento de la demanda de energía eléctrica, como el generador 1 en la cual se observó que el grupo generador que está consumiendo gran parte de energía eléctrica total que genera la CENTRAL HIDROELÉCTRICA ILLUCHI 2, una de las razones por las cuales tiene

este efecto es que el generador 1 lleva más tiempo en funcionamiento en comparación que el generador 2. Otra razón está relacionada con el mantenimiento de cada grupo generador, es decir cuando el generador 1, sufra daños o deje de funcionar el generador 2 lo apoya e inmediatamente entra en funcionamiento, de esta forma la central mantiene su funcionamiento.

5.3. PREPROCESAMIENTO DE LA INFORMACIÓN DE LA CENTRAL HIDROELÉCTRICA ILLUCHI 2

El preprocesamiento de datos es uno de los procesos que son utilizados en cualquier aplicación de aprendizaje automático, debido a que debe disponer de datos de calidad este paso es fundamental para poder obtener buenos resultados. Desafortunadamente los datos procedentes de la vida real suelen presentar ciertas deficiencias originadas por múltiples causas, como errores de escritura, errores de actualización de los datos, errores en la transmisión de los datos, etc. Si los datos no son preparados previamente el algoritmo de aprendizaje de la red neuronal no podrá funcionar, y si funciona lo más seguro es que no presente resultados aceptables [39]. En la figura 5.7, se menciona se menciona una serie de etapas para el preprocesamiento de datos:

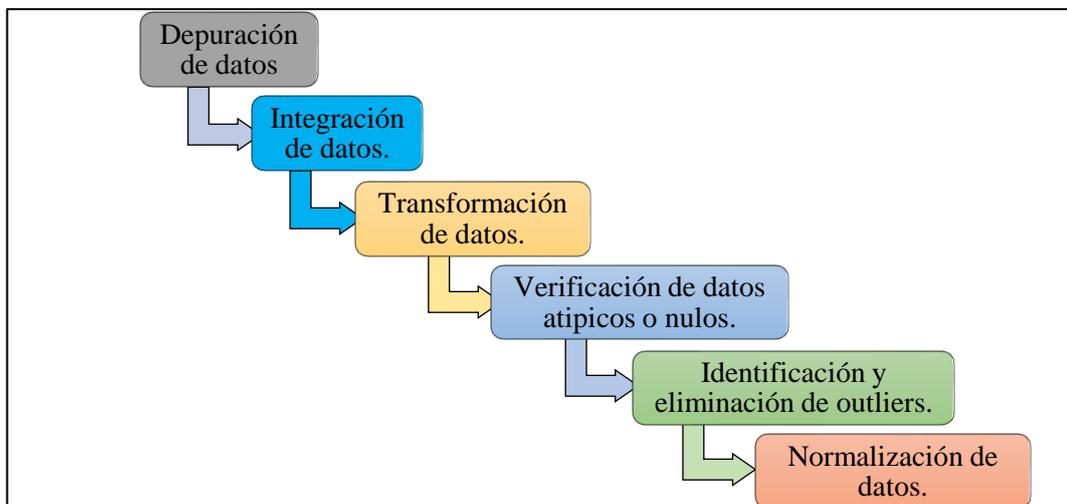


Figura 5.7: Secuencia de pasos a seguir para el preprocesamiento de la información procedente de una base de datos [39]

5.3.1. Depuración de datos de la central hidroeléctrica Illuchi 2

Tener un registro almacenado de la información de un sistema siempre ha sido muy importante en un sistema de potencia. Archivos con valores exactos de las señales y mediciones del sistema son necesarios para satisfacer requerimientos técnicos, legales y otros con regulaciones y

permitirán proveer y tener un respaldo de la información para futuras operaciones del sistema además de aprovechar esta información para realizar una mejor planificación del mantenimiento de cada uno de los componentes del sistema [15]. La información de los grupos generadores de la CENTRAL HIDROELÉCTRICA ELÉCTRICA ILLUCHI 2, están generados por los operarios encargados de obtener registros como: potencia, corriente, energía, temperatura, nivel de caudal, etc. La frecuencia de almacenamiento de los datos es de aproximadamente una hora.

Los operarios encargados diariamente verifican la información y los almacenan en un archivo en formato Excel tal como se muestra en la figura 5.8, especificando las mediciones con respecto a las horas de trabajo. Una vez que finalice el mes de trabajo, operación y almacenamiento de todas las mediciones, esta base de datos es enviada a las oficinas de ELEPCO S.A. para su verificación.

EMPRESA ELECTRICA PROVINCIAL COTOPAXI S.A.																						
REPORTE DIARIO DE GENERACION															FECHA:		DIA:					
CENTRAL HIDROELECTRICA ILLUCHI No. 2															01/01/2016		Viernes					
GENERADOR No.1										GENERADOR No.2										TOTAL		NIVEL
HORAS	I (A)	P (MW)	E (KWH)	E (MWH)	LEX (A)	Q (M3/S)	T (°C)	I (A)	P (MW)	E (KWH)	E (MWH)	LEX (A)	Q (M3/S)	T (°C)	Vφ (V)	COSE φ	E (KWH)	PT (KWH)	QT (KWH)	AGUAS (CM)		
0:00			32.589,7	0,0						31.110,9	0,0						0			-80		
0:30	390	1,6			53	0,53	51	390	1,6				54	0,53	22	2,550	0,95		3,200	1,052		
1:00	390	1,6	32.591,3	1,6	53	0,53	51	390	1,6	31.112,5	1,6	54	0,53	22	2,550	0,95	3,200		3,200	1,052		
1:30	350	1,5			51	0,54	52	350	1,5				52	0,54	22	2,550	0,94		3,000	1,089		
2:00	350	1,5	32.592,8	1,5	51	0,54	52	350	1,5	31.114,0	1,5	52	0,54	22	2,550	0,94	3,000		3,000	1,089		
2:30	350	1,5			51	0,54	52	350	1,5				52	0,54	22	2,550	0,94		3,000	1,089		
3:00	350	1,5	32.594,3	1,5	51	0,54	52	350	1,5	31.115,5	1,5	52	0,54	22	2,550	0,94	3,000		3,000	1,089		
3:30	350	1,5			51	0,54	52	350	1,5				52	0,54	22	2,550	0,94		3,000	1,089		
4:00	350	1,5	32.595,8	1,5	51	0,54	52	350	1,5	31.117,0	1,5	52	0,54	22	2,550	0,94	3,000		3,000	1,089		
4:30	350	1,5			51	0,54	52	350	1,5				52	0,54	22	2,550	0,94		3,000	1,089		
5:00	350	1,5	32.597,3	1,5	51	0,54	52	350	1,5	31.118,5	1,5	52	0,54	22	2,550	0,94	3,000		3,000	1,089		
5:30	350	1,5			51	0,54	52	350	1,5				52	0,54	22	2,550	0,94		3,000	1,089		
6:00	350	1,5	32.598,8	1,5	51	0,54	52	350	1,5	31.120,0	1,5	52	0,54	22	2,550	0,94	3,000		3,000	1,089		
6:30	300	1,2			49	0,51	52	300	1,2				49	0,51	24	2,550	0,92		2,400	1,022		
7:00	300	1,2	32.600,0	1,2	49	0,51	52	300	1,2	31.121,2	1,2	49	0,51	24	2,550	0,92	2,400		2,400	1,022		
7:30	270	1,1			49	0,50	52	270	1,1				48	0,50	24	2,550	0,91		2,200	1,002		
8:00	270	1,1	32.601,1	1,1	49	0,50	52	270	1,1	31.122,3	1,1	48	0,50	24	2,550	0,91	2,200		2,200	1,002		
8:30	290	1,1			49	0,53	52	290	1,1				48	0,53	24	2,550	0,90		2,200	1,066		
9:00	290	1,1	32.602,2	1,1	49	0,53	54	290	1,1	31.123,4	1,1	48	0,53	24	2,550	0,90	2,200		2,200	1,066		
9:30	290	1,1			49	0,53	54	290	1,1				48	0,53	24	2,550	0,90		2,200	1,066		
10:00	290	1,1	32.603,3	1,1	49	0,53	54	290	1,1	31.124,5	1,1	48	0,53	24	2,550	0,90	2,200		2,200	1,066		
10:30	290	1,1			49	0,53	54	290	1,1				48	0,53	24	2,550	0,90		2,200	1,066		
11:00	290	1,1	32.604,4	1,1	49	0,53	54	290	1,1	31.125,6	1,1	48	0,53	24	2,550	0,90	2,200		2,200	1,066		
11:30	290	1,1			49	0,53	54	270	1,0				47	0,48	24	2,550	0,90		2,100	1,017		
12:00	290	1,1	32.605,5	1,1	49	0,53	54	270	1,0	31.126,8	1,0	47	0,48	24	2,550	0,90	2,100		2,100	1,017		

Figura 5.8: Muestra de la base de datos del proceso de generación de la CENTRAL HIDROELÉCTRICA ILLUCHI 2 en enero del año 2 016

Fuente: Los autores

La limpieza de datos consiste en filtrar la información que contiene la base de datos, eliminado datos que son irrelevantes o innecesarias. Esta nueva información fue suministrado a través de un conjunto de hojas de cálculo en Excel, el objetivo de este paso es obtener un archivo final que contenga las variables seleccionadas, con las series de datos relacionados con la demanda de energía eléctrica, es te paso es largo y tedioso debido a que se lo realiza de forma manual.

	A	B	C	D	E	F
1						
2						
3						
4	AÑO	MES	DIA	FECHA	HORA	KW-H
5	2016	1	viernes	1	0	3400
6	2016	1	viernes	1	1	3200
7	2016	1	viernes	1	2	3000
8	2016	1	viernes	1	3	3000
9	2016	1	viernes	1	4	3000
10	2016	1	viernes	1	5	3000
11	2016	1	viernes	1	6	3000
12	2016	1	viernes	1	7	2400
13	2016	1	viernes	1	8	2200
14	2016	1	viernes	1	9	2200
15	2016	1	viernes	1	10	2200
16	2016	1	viernes	1	11	2200
17	2016	1	viernes	1	12	2100
18	2016	1	viernes	1	13	2000
19	2016	1	viernes	1	14	2000
20	2016	1	viernes	1	15	2000
21	2016	1	viernes	1	16	2000
22	2016	1	viernes	1	17	2000
23	2016	1	viernes	1	18	2000

Figura 5.9: Parte de la base de datos después de filtrar los datos que fueron innecesarios

Fuente: Los autores

La base de datos que se observa en la figura 5.9, es distinta en comparación con lo mostrado en la figura 5.8, se observa que la información filtrada se reduce considerablemente.

5.3.2. Integración de datos de la CENTRAL HIDROELÉCTRICA ILLUCHI 2

Esta etapa consistió en la unión de datos procedentes de diferentes bases de datos como se presenta en la figura 5.10. Este proceso se debe realizar de forma cuidadosa para evitar redundancias o inconsistencias en la base de datos final.

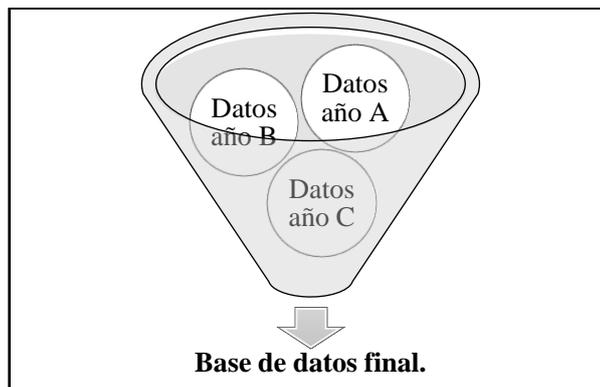


Figura 5.10: Integración de la información hacia una nueva base de datos

Fuente: Los autores

5.3.3.Verificación de datos atípicos o nulos de la CENTRAL HIDROELÉCTRICA ILLUCHI 2

Este proceso consistió en verificar aquellos datos que no tienen valor o tiene un valor igual a cero. Estos valores inexactos se obtuvieron debido a algunos factores entre ellos: errores de medida, errores realizados por los operadores encargados de recopilar información, desconexiones de red o de transferencia de la información, etc. Estos datos se pueden observar en la figura 5.11, estos valores pueden afectar en los entrenamientos aplicadas a las redes neuronales artificiales complicándolo a la hora de analizar y manejar los datos.

	A	B	C	D	E	F	G
6242	2015	9	jueves	17	21	0	0
6243	2015	9	jueves	17	22	0	0
6244	2015	9	jueves	17	23	0	0
6245	2015	9	viernes	18	0	0	0
6246	2015	9	viernes	18	1	0	0
6247	2015	9	viernes	18	2	0	0
6248	2015	9	viernes	18	3	0	0
6249	2015	9	viernes	18	4	0	0
6250	2015	9	viernes	18	5	0	0
6251	2015	9	viernes	18	6	0	0
6252	2015	9	viernes	18	7	0	0
6253	2015	9	viernes	18	8	0	0
6254	2015	9	viernes	18	9	0	0
6255	2015	9	viernes	18	10	0	0
6256	2015	9	viernes	18	11	0	0
6257	2015	9	viernes	18	12	0	0
6258	2015	9	viernes	18	13	0	0
6259	2015	9	viernes	18	14	0	0
6260	2015	9	viernes	18	15	0	0
6261	2015	9	viernes	18	16	0	0
6262	2015	9	viernes	18	17	0	0
6263	2015	9	viernes	18	18	0	0
6264	2015	9	viernes	18	19	0	0

Figura 5.11: Base de datos que contienen valores incoherentes con respecto a la demanda de energía eléctrica

Fuente: Los autores

Como se muestra en la figura anterior se puede observar que la demanda tiene valores de cero, para cambiar los valores incoherentes se plantea utilizar el análisis aplicando medidas de tendencia central o interpolación de datos, con el objetivo de disponer de un valor aproximado que ayude a complementar la información. Para solucionar este problema se utilizó el modelo de predicción de la demandade energía eléctrica utilizando datos anteriores. Para concluir con este proceso, es necesario mencionar lo importante de analizar los resultados con el fin de eliminar la información que no fueron relevantes, también se encontró con datos que a primera vista parecen ser inofensivos, pero al no analizarlos correctamente se tendrá consecuencias negativas que afectarán en la calidad de los resultados que se pretenden predecir. Algunas

etapas que no fueron mencionados, debido a que nuestra metodología no lo requería por esa razón no fueron aplicados.

5.4. SELECCIÓN DE LAS VARIABLES DE ENTRADA PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN

En primer lugar, la selección de las variables de entrada se obtuvo mediante el tratamiento de nuestra base de datos para filtrar la información útil, debido a que la información seleccionada preliminarmente en la tabla 4.1, no fue de utilidad, para lo cual se optó en reducirlos realizando algunos cambios.

- En la matriz inicial se identificó las variables de entrada clave, es decir los datos que proporcionarán la información hacia la red neuronal recurrente para su respectivo entrenamiento y posterior validación de los resultados.
- Para este caso la información de los datos que formarán parte de las nuevas variables de entrada se describe en la tabla 5.1.

Tabla 5.1: Selección final de las variables de entrada para la predicción de la demanda de energía eléctrica

Variable	Descripción	Unidad de medida
Fecha (año, día, mes, hora)	Tiempo de consumo de energía eléctrica	Tiempo
Energía consumida	Energía activa consumida en Kilovatio-Hora	KWh

Fuente: Los autores

5.5. VALIDACIÓN Y PREPROCESAMIENTO DE DATOS DE ENTRADA PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN

Los datos empleados para el entrenamiento se basaron en datos históricos de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, que inicia desde el año 2015, para este proceso se toma como referencia los dos años en específico es decir el año 2015 y 2019.

Una de las formas para definir correctamente el conjunto de datos de entrenamiento, deben cumplir con dos características fundamentales:

- El conjunto de datos debe ser lo suficientemente grande como para obtener resultados significativos.

- Todo el conjunto de datos debe ser representativos, es decir, no se debe elegir un conjunto de datos de validación con características diferentes al conjunto de datos de entrenamiento.

5.5.1. Desarrollo del algoritmo de predicción en Python

Una vez visto y analizado cómo es nuestra serie temporal se procede a crear algunas redes que ayuden a predecir la demanda eléctrica durante un año a horizonte 1. Es decir, el objetivo es simular un año entero prediciendo para el día siguiente y así poder obtener un error comparable. En la figura 5.12, se presentan los pasos a seguir para su implementación, mediante las librerías de Python en su versión 3.8.6.

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import LabelEncoder
from sklearn.model_selection import train_test_split
import keras
from keras.models import Sequential
from keras.layers import Dense, Activation, Dropout
from keras.optimizers import SGD
from sklearn.metrics import mean_squared_error
```

Figura 5.12: Aplicación de las librerías de Python para implementar el algoritmo de predicción

Fuente: Los autores

Keras es un interfaz de programación de aplicaciones de redes neuronales de alto nivel escrita en Python. Proporciona una forma rápida y sencilla de definir y entrenar casi todos los tipos de modelos de aprendizaje profundo. Fue desarrollado con un enfoque en permitir la experimentación rápida. Keras se puede centrar en el diseño de las redes y su entrenamiento dejando un poco de lado los tecnicismos que hay por detrás. Las principales ventajas que proporciona esta librería son su facilidad de uso, su modularidad, su capacidad de ampliación y que trabaja con Python. La estructura de Keras es un modelo, una forma de organizar capas. También se debe considerar que el comando Sequential donde se van añadiendo capas una detrás de otra [36].

5.5.2. Preprocesado de los datos en Python.

Para el preprocesamiento de los datos se lleva la hora y la fecha para los índices porque lo que interesa es KW-H, y se crea un nuevo dataframe con el formato de fecha correcto y el valor de KW-H, esta estructura se observa en la figura 5.13.

```

from datetime import datetime
data_final = pd.DataFrame()
fechas_dt = []
kwh_dt = []
for registro in data.values:
    fecha = "{}-{}-{} {}".format(registro[0], registro[1], registro[3], registro[4])
    fecha_dt = datetime.strptime(fecha, '%Y-%m-%d %H')
    fechas_dt.append(fecha_dt)
    kwh_dt.append(registro[5])
#Creamos un nuevo dataframe con el formato de fecha correcto y el valor de KW-H
data_final['FECHA'] = fechas_dt
data_final['KW-H'] = kwh_dt
data_final

```

Figura 5.13: Estructura del pseudocódigo para el preprocesamiento de datos

Fuente: Los autores

Una vez creado el nuevo dataframe se lleva la FECHA al índice, de esta manera tener una sola columna de datos tal como se observa en la figura 5.14.

	KW-H
FECHA	
2015-01-01 00:00:00	3200
2015-01-01 01:00:00	3200
2015-01-01 02:00:00	2400
2015-01-01 03:00:00	2400
2015-01-01 04:00:00	2400

Figura 5.14: Datos creados por el nuevo Dataframe para la implementación del algoritmo de predicción

Fuente: Los autores

Se dividieron los datos de entrenamiento y de testeo, para lo cual no se puede utilizar "train test split" (dividir un conjunto de datos de una matriz), por ende, se debe dividir el ultimo segmento de datos.

Se tomó el 20 % del final de los datos para la validación (desde el año 2 015 hasta el 31 de enero del 2 019). Una vez clasificados los datos de entrenamiento y de validación se procede a transformar los datos a variables numéricas para no tener errores en la predicción, tal como se muestra en la figura 5.15.

	FECHA	KW-H
<code>data_train['KW-H'] = [valor.replace(",",".") for valor in data_train['KW-H']]</code>	2015-01-01 00:00:00	3200.0
<code>data_train['KW-H'] = [float(valor) for valor in data_train['KW-H']]</code>	2015-01-01 01:00:00	3200.0
<code>data_test['KW-H'] = [valor.replace(",",".") for valor in data_test['KW-H']]</code>	2015-01-01 02:00:00	2400.0
<code>data_test['KW-H'] = [float(valor) for valor in data_test['KW-H']]</code>	2015-01-01 03:00:00	2400.0
<code>data_train</code>	2015-01-01 04:00:00	2400.0

Figura 5.15: Estructura para el preprocesamiento de los datos finales

Fuente: Los autores

5.6. DEFINIR LA ESTRUCTURA DE LA RED NEURONAL ARTIFICIAL PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN

5.6.1. Estructura de la red neuronal recurrente LSTM

Las redes de memoria largo-corto plazo denominado por sus siglas LSTM es un tipo de red neuronal recurrente que se utiliza en el aprendizaje profundo debido a sus grandes arquitecturas las cuales pueden ser entrenados con éxito. La estructura planteada por la célula LSTM se puede observar en la figura 3.18 en la sección 3.2.16.5.

La selección de conjuntos de datos es un requisito necesario para muchos que utilizan el aprendizaje automático. Pero estos métodos pueden ser erróneos si los datos de entrada no están distribuidos normalmente. Las redes neuronales profundas son sensibles a la escala en la que estén los datos de las variables de redes neuronales recurrentes, especialmente cuando se usan la sigmoideal o la tangente hiperbólica como funciones de activación. La normalización de los datos es una alternativa que permite escalar las características necesarias para conseguir valores que se encuentren entre un valor mínimo y un valor máximo (en la práctica se aplican intervalos con valores de $[-1,1]$ y $[0,1]$) para lograr que el valor absoluto máximo de cada variable se modifique a la unidad, se lo realiza mediante el módulo sklearn y su método MinMaxScaler.

La razón para usar este escalado está relacionado con la solidez en el cálculo de las desviaciones estándar con valores pequeños de las variables. La fórmula explícita que aplica el método MinMaxScaler para modificar un vector X , estos valores mínimos (min) y máximos (max) de entrada deben seleccionarse correctamente para evitar inconsistencias en los resultados. La ecuación 5.1, se describe a continuación:

$$X_{std} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (5.1)$$

$$X_{\text{escalado}} = X_{\text{std}} \cdot (\max - \min) + \min \quad (5.2)$$

Donde:

X_{std} está escalado entre 0 y 1 luego, X_{escalado} se pone para que esté escalado en el intervalo $[\min, \max]$ deseado, utilizando la ecuación 5.2 [50].

En la figura 5.16, se puede visualizar el pseudocódigo denominado MinMaxScaler, este es un método propio aplicado en la implementación de redes neuronales recurrentes y utilizado en Python para la normalización de los datos.

```
#Normalizacion de los datos
#Para LSTM es obligatoria la normalización, en este caso lo hacemos de 0 a 1
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0,1))
data_train_scaled = sc.fit_transform(data_train)
print(data_train_scaled.shape)
data_train_scaled
```

Figura 5.16: Estructura del pseudocódigo MinMaxScaler para la normalización de los datos e implementar el algoritmo de predicción

Fuente: Los autores

La centralización de los datos es muy importante a la hora de asignar pesos iguales hacia las variables, esto ayuda a que todas las variables sean igual de importantes al inicio de la red.

En el interior de cada red hay un gran número de parámetros con los que experimentar hasta obtener mejores resultados ya que se puede jugar con las funciones de activación de cada neurona, con las funciones de pérdida a minimizar, con el número de variables explicativas, con el número de capas y el número de neuronas en cada capa (hay algunas recomendaciones según la topología de la red, pero ninguna es 100 % efectiva), etc. En este trabajo de investigación se detallan las redes, con los mejores resultados que han proporcionado a nuestra red neuronal propuesta. Antes de centrarse en cómo construir redes neuronales recurrentes en Python se explicará la técnica del *Dropout*. El término de *Dropout* se refiere a “eliminar” o “perder” neuronas en una red neuronal. Es decir, ignorar un conjunto de neuronas (elegidas aleatoriamente) durante la fase de entrenamiento. De una manera más técnica, el *Dropout* hace que en cada iteración del entrenamiento algunas neuronas no se tengan en cuenta con probabilidad $1 - p$ y así se obtiene una red más reducida. El dropout es necesario para prevenir el sobreentrenamiento (overfitting) ya que una capa totalmente conectada ocupa la mayor parte de los parámetros y por tanto las neuronas desarrollan codependencia entre ellas, lo que

restringe la potencia individual de cada una y produce este sobreentrenamiento. En la figura 4.7 se observa la función que cumple el *Dropout* en el pseudocódigo.

No hay un valor de probabilidad p para el *dropout* pero después de pruebas preliminares se puede concluir que el valor 0,4 y 0,2 son los que mejor funciona, tal como se muestra en la figura 5.17. Una vez explicada esta técnica que se usa (se probó sin utilizarla y se obtuvieron peores resultados por lo que se decidió utilizar esta técnica), los modelos de redes que se implementarán serán sencillos y con pocas capas. Como ya se ha dicho, se utiliza el modelo *Sequential* para crear las redes, esto se puede observar en la figura 4.7. Además, todas nuestras redes tendrán la capa de entrada en la que se indica el número de variables explicativas x que entran al modelo y la capa de salida con una única neurona que hace referencia a nuestra predicción de demanda y . Una vez declaradas las librerías y la estructura de la red neuronal LSTM como se observa en el paso 4 de la sección 4.3.1.

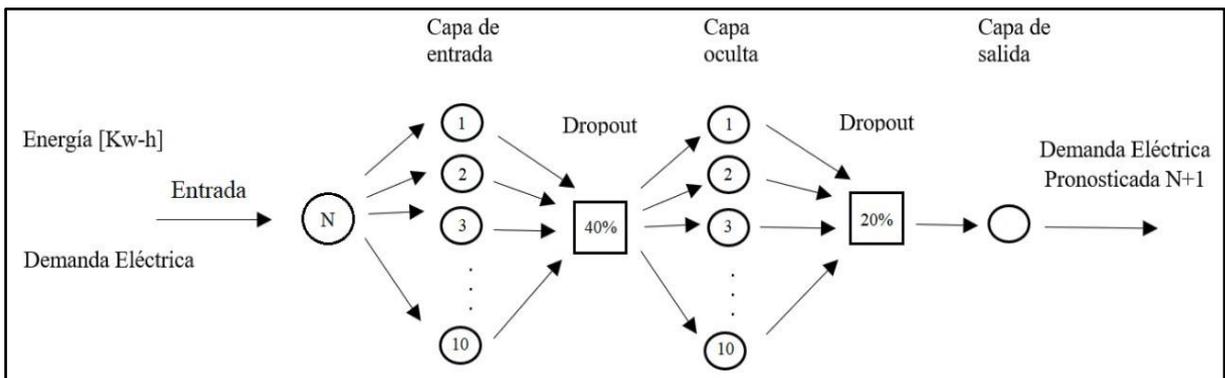


Figura 5.17: Estructura de la red neuronal artificial implementado en el algoritmo de predicción

Fuente: Los autores

5.6.2. Normal fitting

Los datos históricos ingresados en los parámetros que se consideró, varios factores como: el número de retrasos aplicados a la red, la selección de número de neuronas que fueron 10, los epoch o el número de entrenamientos que también fueron 10, de esta forma se consideró que nuestra red neuronal recurrente se mantiene en estado de normalfitting, También se puede mencionar que nuestra red consta de una capa de congelamiento de neuronas denominada *Dropout* la cual congela el 40 % de las neuronas para evitar overfitting, se ingresó los datos específicos logrando el entrenamiento correcto para la implementación del modelo de predicción.

5.7. VERIFICACIÓN DE LA RED NEURONAL ARTIFICIAL PARA EL DESARROLLO DEL ALGORITMO DE PREDICCIÓN

Dicha verificación se realizó con un conjunto de datos como se menciona en la sección 4.3.1. en el paso 7, este conjunto de datos está conformado por un 80 % para el entrenamiento, un 20 % para la validación de datos, se entrena y se calcula el error medio absoluto de la red LSTM mediante optimizadores. Los cuales se realizó los respectivos entrenamientos para brindar mejores resultados e implementarlos en nuestra RNA.

Luego de realizar las respectivas pruebas con todos los optimizadores que presenta la librería Keras, solo tres de los optimizadores brindaron mejores resultados en cada una de las predicciones planteadas, los optimizadores elegidos de presentan en la figura 5.18.

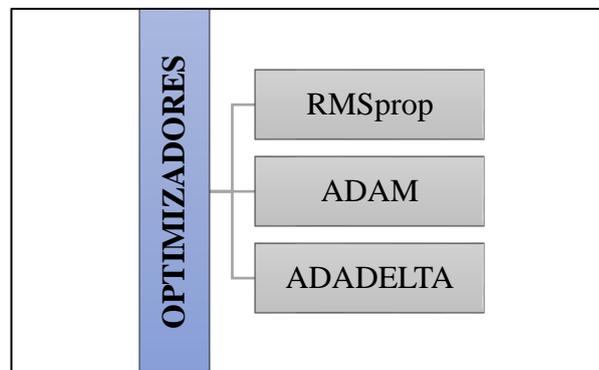


Figura 5.18: Optimizadores utilizados para los entrenamientos de la red neuronal recurrente implementado

Fuente: Los autores

En la figura 5.19, se puede apreciar el comportamiento del histograma de error, el mismo que toma valores entre el error medio absoluto del optimizador adecuado para la predicción y los datos de predicción obtenidos, También se analizó el correcto funcionamiento del modelo de predicción de la demanda de energía eléctrica implementado en el trabajo de investigación.

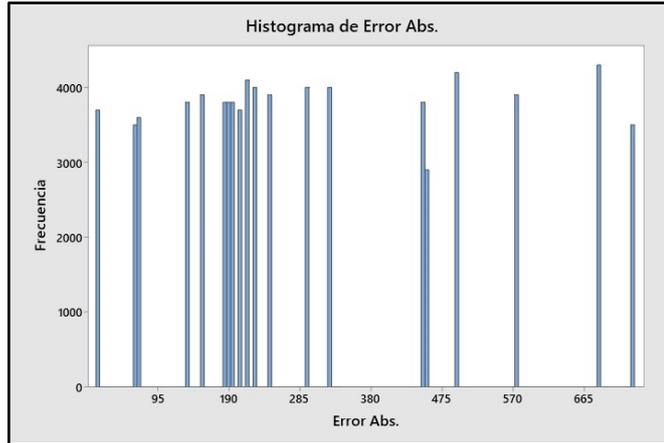


Figura 5.19: Histograma de error mostrados en los entrenamientos de la red neuronal recurrente implementado

Fuente: Los autores

En la figura 5.20 se aprecia el comportamiento en el entrenamiento de la red neuronal recurrente, por ende, este es un modelo en donde se analizó toda la información ingresada de forma correcta, el cual mantiene el estado de normal fitting o estado óptimo considerando la variación del número de neuronas, capas, optimizadores empleados y épocas siendo así el modelo más aceptable para el caso de estudio planteado.

```
#rmsprop LOS MEJORES RESULTADOS
model, history = NN_LSTM(optimizador = 'rmsprop', neuronas = 10, epocas = 10)
#Guardamos el modelo para no tener que entrenar otra vez para probar
model.save('modelos/model.h5')

Epoch 1/10
280/280 [=====] - 18s 50ms/step - loss: 0.0375 - mean_absolute_error: 0.1386
Epoch 2/10
280/280 [=====] - 22s 80ms/step - loss: 0.0137 - mean_absolute_error: 0.0862
Epoch 3/10
280/280 [=====] - 14s 50ms/step - loss: 0.0101 - mean_absolute_error: 0.0727
Epoch 4/10
280/280 [=====] - 14s 50ms/step - loss: 0.0080 - mean_absolute_error: 0.0640
Epoch 5/10
280/280 [=====] - 19s 67ms/step - loss: 0.0069 - mean_absolute_error: 0.0584
Epoch 6/10
280/280 [=====] - 14s 49ms/step - loss: 0.0062 - mean_absolute_error: 0.0545
Epoch 7/10
280/280 [=====] - 14s 49ms/step - loss: 0.0057 - mean_absolute_error: 0.0521
Epoch 8/10
280/280 [=====] - 14s 49ms/step - loss: 0.0055 - mean_absolute_error: 0.0507
Epoch 9/10
280/280 [=====] - 14s 52ms/step - loss: 0.0052 - mean_absolute_error: 0.0496
Epoch 10/10
280/280 [=====] - 14s 50ms/step - loss: 0.0051 - mean_absolute_error: 0.0485
```

Figura 5.20: Estructura de la red neuronal LSTM al aplicar 10 épocas (entrenamientos) con una muestra de datos

Fuente: Los autores

5.8. ALMACENAMIENTO DE LOS PARAMETROS DE ENTRENAMIENTO DE LA RED NEURONAL RECURRENTE IMPLEMENTADO

Para evitar repetir el entrenamiento y provocar un sobreentrenamiento de la neurona se procedió a almacenar todos los entrenamientos realizados en archivos de datos en formato de datos jerárquicos conocidos por sus siglas HDF, tal como se observa en la figura 5.21.

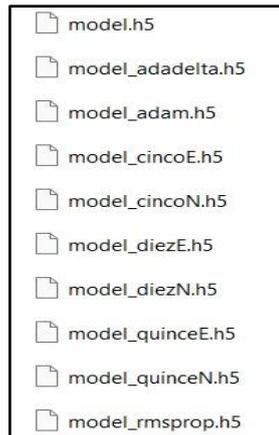


Figura 5.21: Almacenamiento de entrenamientos en formato jerárquico h5

Fuente: Los autores

5.9. ANALISIS DE LA VARIACIÓN EN LA ESTRUCTURA DE LA RNA PARA LA PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA

Para lograr un correcto diseño de una red neuronal artificial recurrente, es desarrollado mediante la comparación de diferentes configuraciones propuestas por los diseñadores, en este punto se analizó las diferentes configuraciones empleadas para la aplicación redes neuronales artificiales recurrentes, tomando en cuenta los criterios como: el tipo de algoritmo de entrenamiento a emplear, numero de neuronas y numero de entrenamientos (épocas). El programa computacional que se empleó en el desarrollo del presente trabajo de investigación en primer lugar, se ingresa como variable de entrada los datos históricos de la demanda de energía eléctrica proveniente de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, toda la información empleada fue proporcionado por ELEPCO S.A.

5.9.1. Variación del algoritmo de entrenamiento

Como se mencionó en la sección 5.6, se utilizaron 3 optimizadores: RMSprop, Adadelata y Adam. En el análisis de este caso se mantienen constantes los parámetros: el número de neuronas (10) y numero de entrenamientos (10). En la tabla 5.2, se presenta los resultados del

rendimiento que se obtuvo para cada algoritmo de entrenamiento, de la misma forma en la figura 5.22, se puede apreciar gráficamente los resultados del pronóstico de la demanda de energía eléctrica.

Tabla 5.2: Resultados obtenidos aplicando diferentes tipos de optimizadores para la predicción de la demanda de energía eléctrica

ALGORITMOS DE ENTRENAMIENTOS	
OPTIMIZADOR	ERROR MAE
RMSprop	0,0352
Adam	0,0359
Adadelata	0,0370

Fuente: Los autores

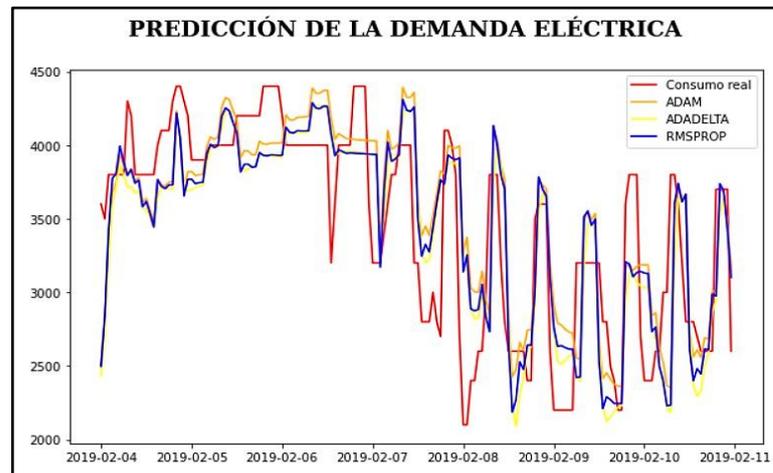


Figura 5.22: Comportamiento de la predicción de la demanda de energía eléctrica aplicando diferentes optimizadores

Fuente: Los autores

La variación de los resultados para cada uno de los optimizadores de entrenamiento, fueron de ayuda para seleccionar el que mejor resultados proporcionó en la predicción de la demanda de energía eléctrica en este caso el optimizador RMSprop es el que se acercó a los datos reales.

5.9.2. Variación del número de neuronas

Otro de los parámetros que se analizó fue el número de neuronas que conforma la RNA, en este caso los parámetros que permanecen constante son: el tipo de optimizador de entrenamiento del caso anterior (RMSprop) y número de entrenamientos (10). En la tabla 5.3, se muestra los resultados del rendimiento que se obtuvo para cada caso propuesto de la misma forma en la

figura 5.23, se muestra gráficamente los resultados de la predicción de la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

Tabla 5.3: Resultados del error MAE con la variación de neuronas para la predicción de la demanda de energía

NÚMERO DE NEURONAS	ERROR MAE
1	0,0642
3	0,0431
5	0,0382
10	0,0349
15	0,0337

Fuente: Los autores

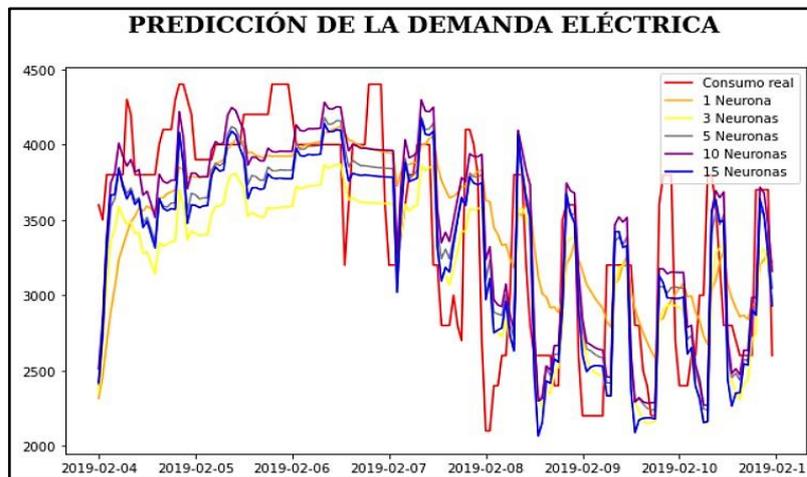


Figura 5.23: Comportamiento de la predicción de la demanda de energía eléctrica dependiendo del número de neuronas

Fuente: Los autores

Una vez analizados los resultados presentados en el número de neuronas de la red neuronal artificial recurrente, el que mejores resultados proporcionó en la predicción de la demanda de energía eléctrica fueron de 10 neuronas, si se utiliza en un entrenamiento con un mayor número de 10 neuronas da como resultado un menor error, pero con overfitting.

5.9.3. Variación del número de épocas

El tercer parámetro que se analizó es el número de entrenamientos (epoch) que conforma la RNA, en este caso los parámetros que permanecen constante son: el tipo de optimizador de entrenamiento del caso anterior (RMSprom) y también el número de neuronas (10). En la tabla

5.4, se muestra los resultados de rendimiento que se obtuvo para cada caso propuesto y de la misma forma en la figura 5.24, se aprecia gráficamente los resultados de la predicción de la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

Tabla 5.4: Resultados derivados de la variación del número de épocas para la predicción de la demanda de energía eléctrica

NÚMERO DE EPOCAS	ERROR MAE
3	0,0402
5	0,0368
10	0,0329

Fuente: Los autores

Como se puede observar en la tabla 5.4, se utilizan de 3 a 5 epoch (épocas) la predicción es un underfitting, es decir un bajo entrenamiento, de tal manera que se necesitarían un total de 10 epoch con las que la red neuronal LSTM trabaja en un estado de normalfitting, en caso de aplicar más de 10 epoch o mayor número de epoch, la red neuronal empieza a realizar sobreentrenamientos (overfitting).

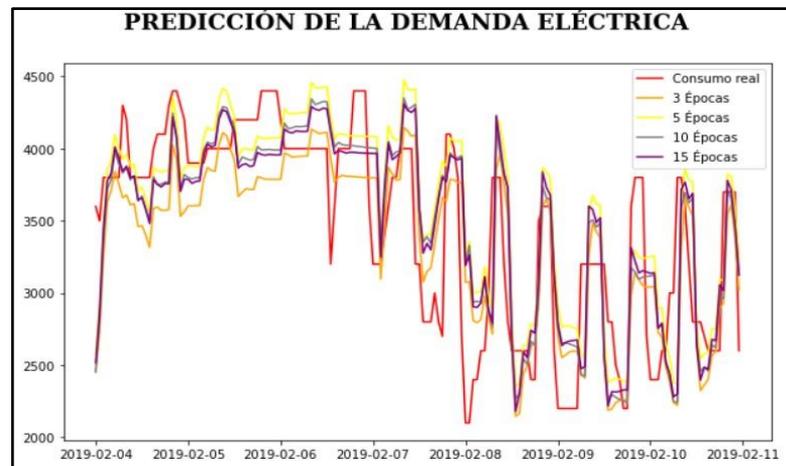


Figura 5.24: Comportamiento de la predicción de la demanda de energía eléctrica aplicando varios epoch (épocas)

Fuente: Los autores

Conforme a los resultados que se presentaron relacionado con el número de épocas o entrenamientos en la RNA, el que mejor resultados en el pronóstico de la demanda de energía eléctrica utiliza alrededor de 10 épocas.

5.10. ANÁLISIS DE RESULTADOS

5.10.1. Análisis del comportamiento de la demanda de energía eléctrica real de la CENTRAL HIDROELÉCTRICA ILLUCHI 2

En primer lugar, para analizar el pronóstico de la demanda de energía eléctrica, fue necesario crear una nueva base de datos, es decir crear una nueva hoja de Excel, con el objetivo de reducir considerablemente la información poco relevante, La información de los datos históricos que inicia desde el 1 de enero del año 2 015 hasta el 31 de diciembre del año 2 019. Para conocer el comportamiento de la serie de los datos dentro del análisis de esta forma hacer una estimación de la técnica de predicción que se plantea utilizar y luego realizar el pronóstico de los siguientes periodos; cabe recalcar que esto es con fines académicos, la base de datos que se tiene son datos históricos reales, el tamaño de la muestra es de suma importancia para la precisión del pronóstico, debido a que la demanda es variable en el transcurso del día, también se debe considerar un análisis de tiempo, para estimar su variación. En la práctica se utilizan datos históricos anuales para proyectarlo a un horizonte de tiempo ya sean estos (diarios o semanales), para conseguir un pronóstico seguro y confiable en la previsión de la demanda.

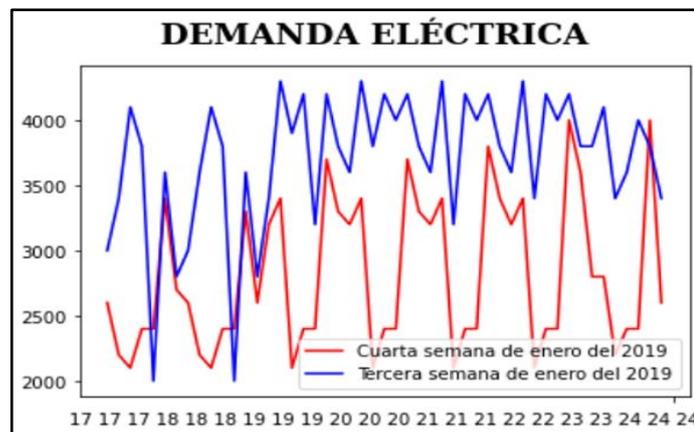


Figura 5.25: Variación del comportamiento de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana

Fuente: Los autores

En la figura 5.25, se aprecia la variación de la curva de la demanda semanal, en este caso se analizó la tercera y cuarta semana del mes de enero, concretamente desde el 17 al 24 del mes antes mencionado en el año del 2 019 de la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

También se puede analizar que el comportamiento de la demanda de energía eléctrica de la última semana del mes de enero, es menor en ciertos días y similares para varios días.

En la tabla 5.5, se detallan los valores de los datos analizados, el cual pertenece a los últimos 8 días del mes de enero del año 2 019, se analizó los valores máximos y mínimos de la demanda eléctrica donde se muestra un rango de 1 900 kWh, el cálculo de la frecuencia no es necesario hacerlo debido a que los datos no se repiten, es decir que son diferentes en el transcurso del tiempo.

Tabla 5.5: Análisis descriptivo de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana

ANÁLISIS DESCRIPTIVO	
Máximo	4000 kWh
Mínimo	2100 kWh
Rango	1900 kWh
Media	2804,08 kWh
Mediana	2600 kWh
Varianza	335816,32 kWh
Desviación estándar	573,55
Coefficiente de variación	20,45 %
Límite superior	3377,63 kWh
Límite inferior	2230,52 kWh

Fuente: Los autores

Los valores reales que se obtuvieron para las medidas de tendencia central, muestran un valor de la media o promedio con un valor de 2 804,08 kWh este valor representa el promedio de la energía que consume la central hidroeléctrica, la mediana tiene un valor de 2 600 kWh que representa el valor que ocupa la parte central en el conjunto todos de datos analizados. El cálculo de la moda no se pretende calcular debido a que muestran valores que más repiten y el caso de la demanda carece de valores similares, como se muestra en la figura 5.24, son pocos los casos que las demandas son iguales. Mencionando la información con respecto a las medidas de dispersión se obtiene el valor de la desviación estándar de 573,55 con un coeficiente de variación de 20,45 %, con los valores analizado se comprueba que los valores de la demanda no son homogéneos.



Figura 5.26: Desviación estándar aplicando los datos reales de la demanda de energía eléctrica

Fuente: Los autores

En la figura 5.26, se observa el comportamiento de los valores reales, adicionalmente se visualiza el promedio, los valores máximo y mínimo, observando los intervalos que difieren en la dispersión de los datos que fueron analizados.

En la figura 5.27, se puede apreciar la variación de la demanda de energía eléctrica semanal analizando los últimos 8 días del mes de enero del año 2019 de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, los con intervalos de tiempo empleados fueron de días del mes. En este caso su forma y variación dependieron de las variables que afectaron a la demanda, también se puede analizar que el comportamiento de la demanda tiende a crecer mientras transcurren las horas de la tarde y en la noche, cabe recalcar que no se considera las horas de la madrugada donde existe menos consumo de energía eléctrica.

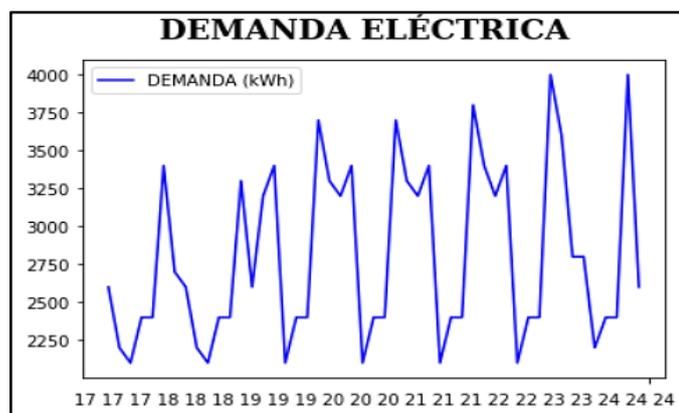


Figura 5.27: Comportamiento de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana

Fuente: Los autores

En la figura 5.28, se puede apreciar con detalle la capacidad de proceso relacionado a la demanda de energía eléctrica utilizando los datos reales, donde se presenta 6 comportamientos, uno de ellos se muestra la gráfica Xbarra observando el límite de caso superior e inferior como los datos atípicos o nulos en los cuales se obtiene como resultado un promedio de 2 804 kWh, este valor es fundamental para un correcto resultado en la predicción de la demanda de energía eléctrica a corto plazo. La mayoría de los datos se encuentran en el rango de los límites de especificación requeridos, cabe recalcar que existen partes que se encuentran fuera de los límites de especificación inferior (LEI) y por encima del límite de especificación superior (LES) estos valores representan los elementos no conformes, es decir son valores atípicos. La gráfica R permite conocer la estabilidad del proceso en el tiempo, para lograr identificar y corregir las inestabilidades en un proceso, existen tres puntos fuera de los límites de control y el resto varían aleatoriamente alrededor de la línea central para encontrarse con los límites de control requeridos, por lo tanto, la variación del proceso se encuentra bajo control. También se debe mencionar la gráfica de probabilidad normal, esta controla si los datos siguen una distribución normal, con estos resultados la línea de distribución ajustada es la línea recta intermedia en la gráfica, las líneas continuas externas en la gráfica se denominan intervalos de confianza de los percentiles individuales por ende los datos se mantienen normales.

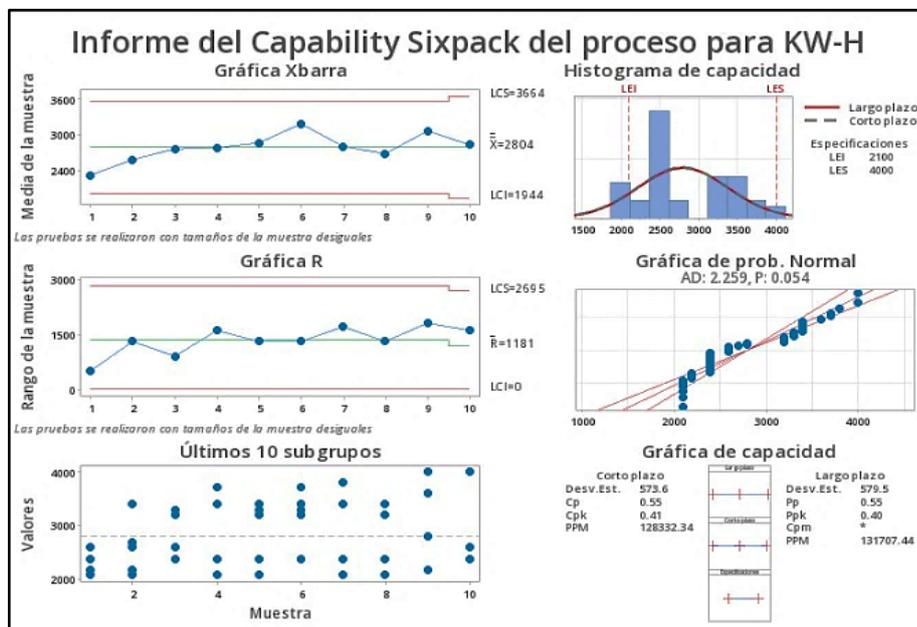


Figura 5.28: Visualización de las capacidades del proceso para la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana

Fuente: Los autores

La gráfica que muestra los últimos 10 subgrupos se hace referencia al grupo de unidades que se crean bajo un mismo conjunto de condiciones, los datos en análisis demuestran estabilidad y por último para la capacidad de subgrupos relacionado a corto plazo, el Cp tiene un valor de 0,55 esto indica que la dispersión de especificación es 0,55 veces mayor que la dispersión en todo el proceso. Se puede mencionar que los valores de Cp (0,55) y Cpk (0,41) se encuentran muy cercanos entre ellos, lo que indica que el proceso está aproximadamente centrado. Para la capacidad general, se tiene un valor de Pp (0,55), Ppk (0,40) que también se encuentran muy cercanos entre ellos, lo que indica que el proceso de los datos es aceptado para realizar un proceso que permitan realizar un pronóstico.

Para tener una mejor visualización del comportamiento de la curva de la demanda eléctrica en la figura 5.29, se grafica datos diarios de dos últimos días del mes de enero del año 2019, con datos reales donde se observa un comportamiento casi similar, tanto en el crecimiento y la disminución de la carga eléctrica durante todo el día.

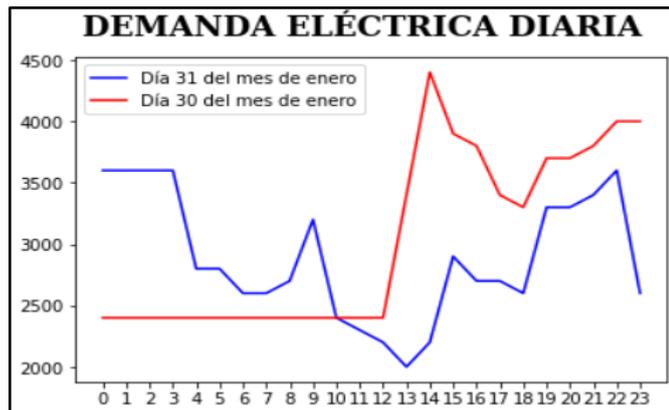


Figura 5.29: Comportamiento de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 día

Fuente: Los autores

Para lograr un análisis con mayor detalle se presenta en la figura 5.30, donde se realiza un intervalo de estudio de un día en los cuales se puede apreciar con detalle la capacidad de proceso relacionado a la demanda de energía eléctrica utilizando los datos reales, donde se presenta 6 comportamientos, uno de ellos se muestra la gráfica Xbarra y R indican que los procesos se mantienen estables. La mayoría de los datos se encuentran en el rango de los límites de especificación requeridos, cabe recalcar que existen partes que se encuentran fuera de los

límites de especificación inferior (LEI) y por encima del límite de especificación superior (LES) estos valores representan los elementos no conformes, es decir son valores atípicos.

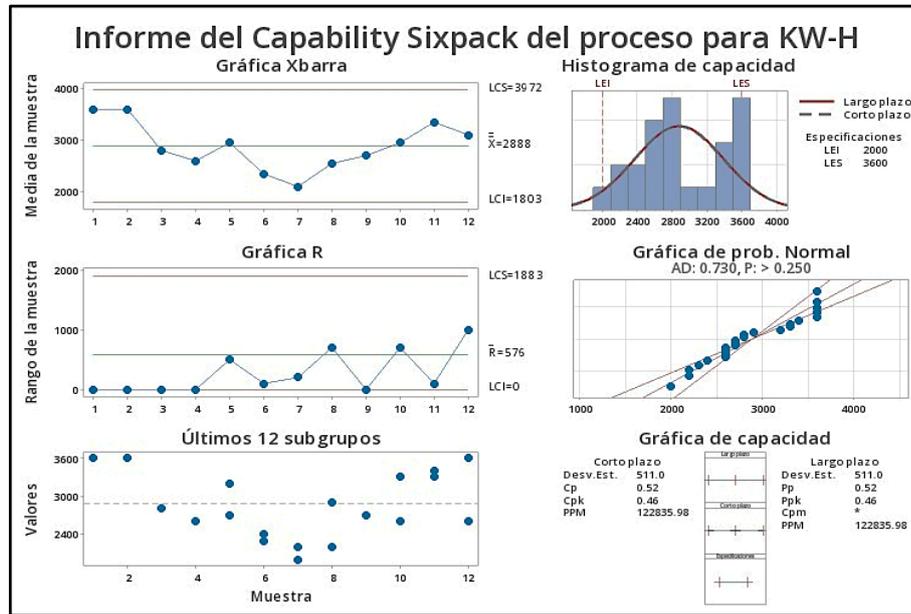


Figura 5.30: Capacidades del proceso para la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 día

Fuente: Los autores

5.10.2. Análisis del comportamiento de la demanda eléctrica pronosticada.

En la figura 5.31, se puede apreciar el comportamiento de la demanda pronosticada, en este caso se analizó los datos desde el 4 al 11 de febrero representando los primeros 8 días del mes en el año 2019 de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, la cual se caracteriza por tener intervalos de tiempo de horas para cada día de la semana. La variación de la demanda eléctrica pronosticada, tiende a crecer mientras transcurren las horas de la tarde y noche, cabe aclarar que no se toma en cuenta las horas de la madrugada, el cual decrece debido a que existe menos consumo eléctrico.



Figura 5.31: Comportamiento de la demanda de energía eléctrica analizando los datos pronosticados en un intervalo de 1 semana

Fuente: Los autores

En la tabla 5.6, se detalla el valor de los datos que se pronosticaron, los cuales pertenecen a los primeros días del mes de febrero datos analizados de una semana para obtener los datos de valor máximo de la demanda eléctrica y el valor mínimo donde se presenta un rango de 2 117,44 kWh, del mismo modo no se puede realizar el cálculo de la frecuencia por que los datos no se repiten.

Tabla 5.6: Análisis descriptivo de la demanda de energía eléctrica analizando los datos reales en un intervalo de 1 semana

ANÁLISIS DESCRIPTIVO	
Máximo	4216 kWh
Mínimo	2099 kWh
Rango	2117,44 kWh
Media	3325,90 kWh
Mediana	3559,52 kWh
Varianza	386201,06 kWh
Desviación estándar	619,59
Coefficiente de variación	18,62 %
Límite superior	3945,50 kWh
Límite inferior	2706,30 kWh

Fuente: Los autores

Para el cálculo de las medidas de tendencia central para analizar el cálculo de la media o el promedio con un valor de 3 325,90 kWh este valor representa el promedio de la energía que se consume en el intervalo de análisis, la mediana representa el valor que ocupa la parte central

del conjunto de datos, donde se representa el 50 % de datos por debajo y 50 % por encima de 3 559,52 kWh, cabe recalcar que no se puede realizar el cálculo de la moda, debido que antes ya se mencionó que representa el valor que más se repite. En datos de medidas de dispersión, el cálculo de la desviación estándar se obtiene un valor de 619,59 con un coeficiente de variación de 18,62 %, comprobando la no homogeneidad en los datos de análisis. En la figura 5.32, se observa el comportamiento de los valores de pronóstico de la demanda de energía eléctrica, donde representa el valor límite máximo y mínimo, observando el intervalo de la dispersión de los datos.



Figura 5.32: Desviación estándar aplicando los datos pronosticados de la demanda de energía eléctrica

Fuente: Los autores

En la figura 5.33, se puede apreciar la capacidad del proceso para la demanda de energía eléctrica analizando los datos pronosticados, donde nos presenta 6 comportamientos, las gráficas Xbarra y R indican que el proceso es estable, con pocos puntos más allá de los límites de control, la gráfica de los últimos 25 subgrupos indica que los datos están distribuidos de forma aleatoria y simétrica alrededor de la media del proceso. La gráfica de probabilidad normal indica que los datos están distribuidos normalmente, entonces los supuestos del análisis de capacidad normal se cumplen. El histograma y los índices de capacidad indican que el proceso está aproximadamente centrado en el objetivo y que las mediciones están en los límites de especificación requeridos.

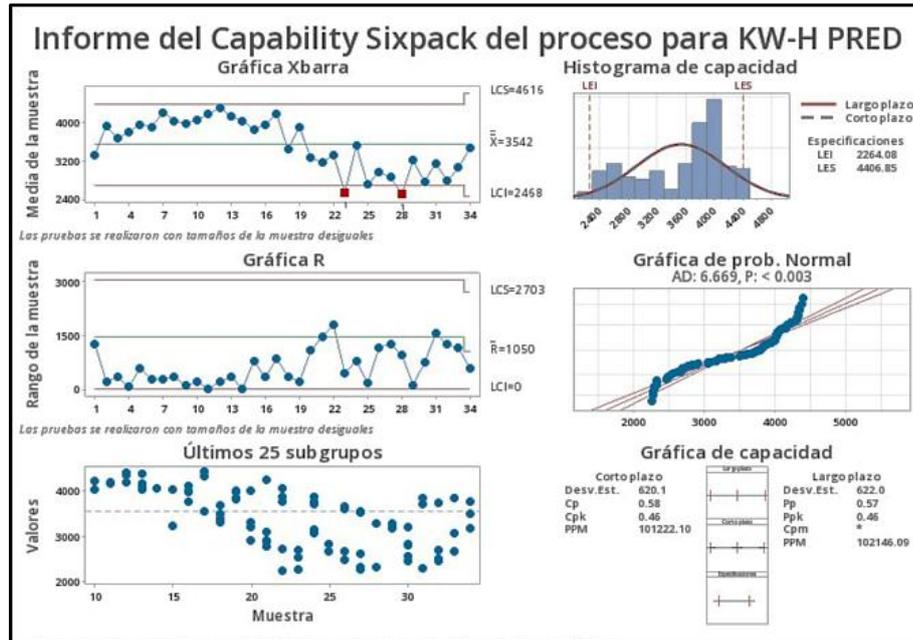


Figura 5.33: Capacidades del proceso para la demanda de energía eléctrica analizando los datos pronosticados en el intervalo de 1 semana

Fuente: Los autores

Para tener una mejor visualización del comportamiento de la curva de la demanda eléctrica pronosticada en la figura 5.34, se grafica datos horarios donde se observa un comportamiento muy singular del comportamiento de la curva de la demanda eléctrica, tanto en el crecimiento y la disminución de la carga durante todo el día.

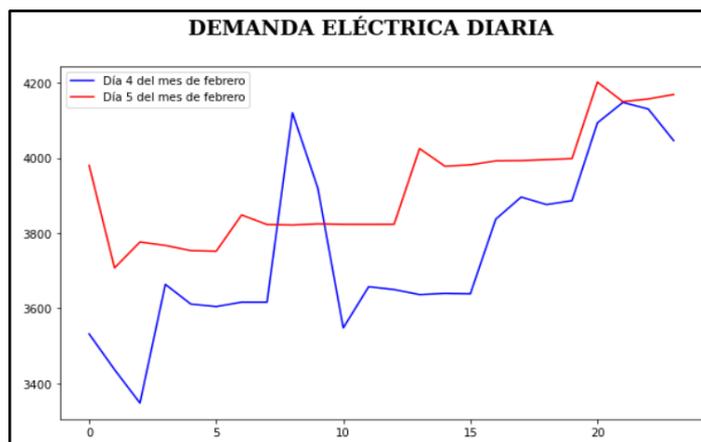


Figura 5.34: Comportamiento de la demanda de energía eléctrica analizando los datos pronosticados en un intervalo de 1 día

Fuente: Los autores

Para un análisis con mayor detalle en la figura 5.35, se presenta datos pronosticados de 1 día, donde las gráficas Xbarra y R indican que el proceso es estable, sin puntos más allá de los límites de control. La gráfica de probabilidad normal indica que los datos están distribuidos normalmente. Por lo tanto, los supuestos del análisis de capacidad (subgrupos/corto plazo) se cumplen y se puede analizar la capacidad del proceso.

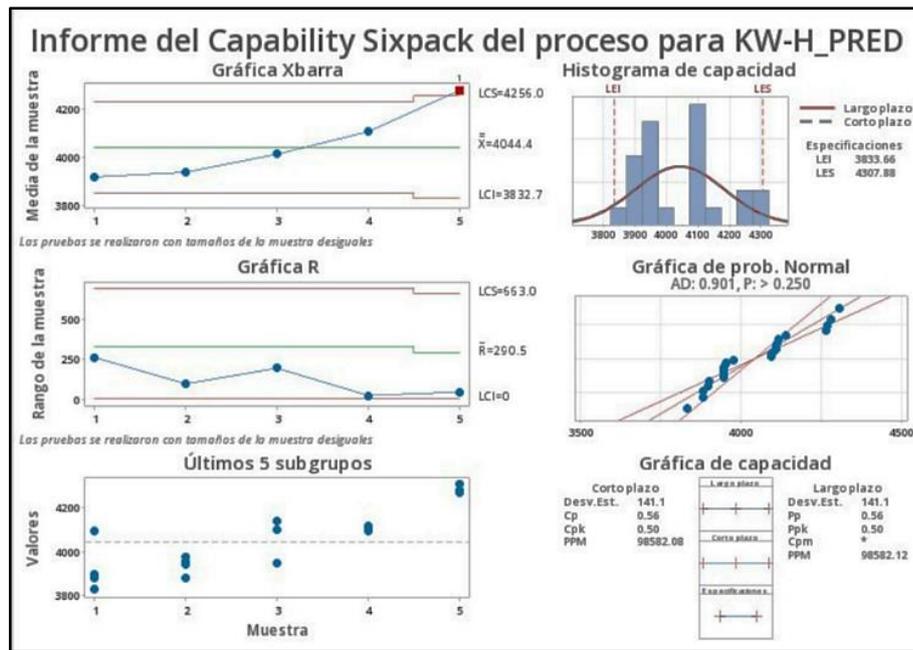


Figura 5.35: Capacidades del proceso para la demanda de energía eléctrica analizando los datos pronosticados en el intervalo de 1 día

Fuente: Los autores

5.10.3. Análisis del comportamiento de la demanda de energía eléctrica pronosticada a los años 2 020 y 2 021.

En la figura 5.36, se puede observar el comportamiento de la curva de la demanda pronosticada, analizados desde el 1 de enero hasta el 31 de diciembre del año 2 020, debido a la gran cantidad de datos se optó por depurar toda la información pronosticada con el fin de obtener la demanda máxima de cada mes.

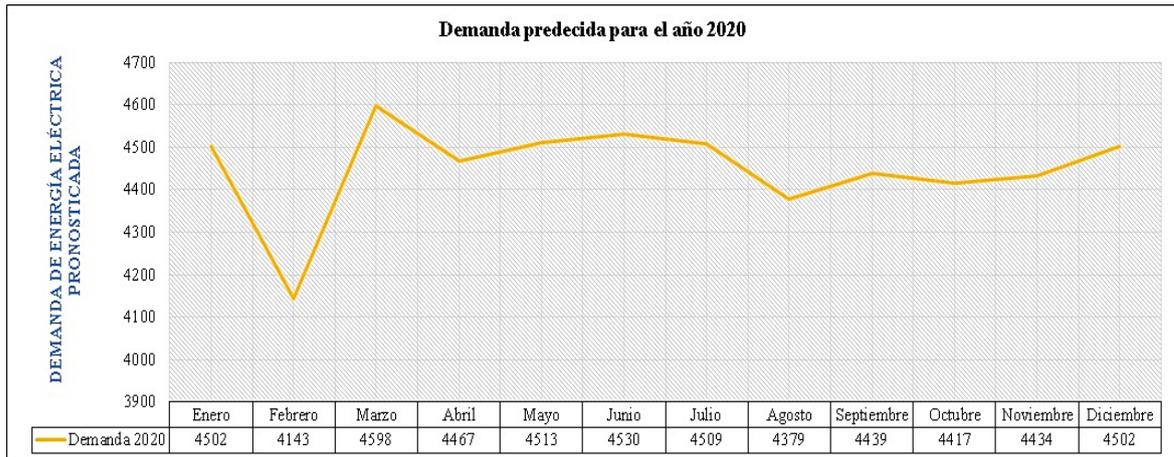


Figura 5.36: Comportamiento de la curva de la demanda eléctrica pronosticada para el año 2 020

Fuente: Los autores

Se puede apreciar que el valor de la demanda en el mes de febrero decrece con respecto a los demás meses, esto es puede observar en el análisis descriptivo realizado en la tabla 5.7. Adicionalmente se puede mencionar que los demás meses me mantienen con valores casi cercanos entre cada mes.

En la tabla 5.7, se detalla el valor de los datos que se pronosticaron, los cuales pertenecen al año 2 020, se obtiene datos de valor máximo de la demanda eléctrica y el valor mínimo donde se presenta un rango de 455,47 kWh, del mismo modo no se puede realizar el cálculo de la frecuencia debido que los datos no se repiten.

Tabla 5.7: Análisis descriptivo de la demanda de energía eléctrica pronosticada para el año 2 020

ANÁLISIS DESCRIPTIVO	
Máximo	4598,235 kWh
Mínimo	4142,762 kWh
Rango	455,473 kWh
Media	4452,68 kWh
Mediana	4484,568 kWh
Varianza	12947,71 kWh
Desviación estándar	113,79
Coefficiente de variación	3 %
Límite superior	4566,46 kWh
Límite inferior	4338,89 kWh

Fuente: Los autores

En el análisis de las medidas de tendencia central, como el cálculo de la media o el promedio es de 4 452,68 kWh este valor representa el promedio de la energía que se consume en el intervalo de los datos analizados, la mediana representa el valor que ocupa la parte central del conjunto de datos, donde se representa el 50 % de datos por debajo y 50 % por encima de 4 484,56 kWh. En datos de medidas de dispersión, el cálculo de la desviación estándar se obtiene un valor de 113,79, con un coeficiente de variación de 3 %, comprobando la no homogeneidad en los datos de análisis. En la figura 5.37, se observa el comportamiento de los valores de pronóstico de la demanda de energía eléctrica, donde representa el valor límite máximo y mínimo, observando el intervalo de la dispersión de los datos.

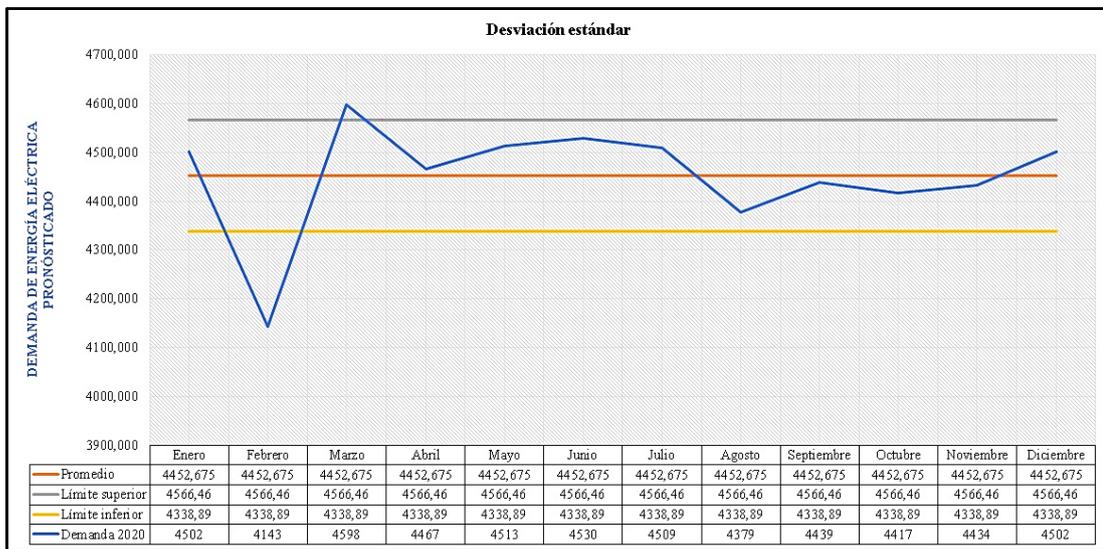


Figura 5.37: Desviación estándar utilizado en el análisis de la demanda de energía eléctrica pronosticada para el año 2 020

Fuente: Los autores

En la figura 5.38, se detalla la capacidad del proceso para la demanda de energía eléctrica de los datos pronosticados para el año 2 020, donde se presenta 6 comportamientos, las gráficas Xbarra y R indican que el proceso es estable, con pocos puntos más allá de los límites de control, la gráfica de los últimos 25 subgrupos indica que los datos están distribuidos de forma aleatoria y simétrica alrededor de la media del proceso. La gráfica de probabilidad normal indica que los datos se encuentran distribuidos normalmente, entonces los supuestos del análisis de capacidad normal se cumplen correctamente. El histograma y los índices de capacidad indican que el proceso está aproximadamente centrado en el objetivo y las mediciones se encuentran en los límites de especificación requeridos.

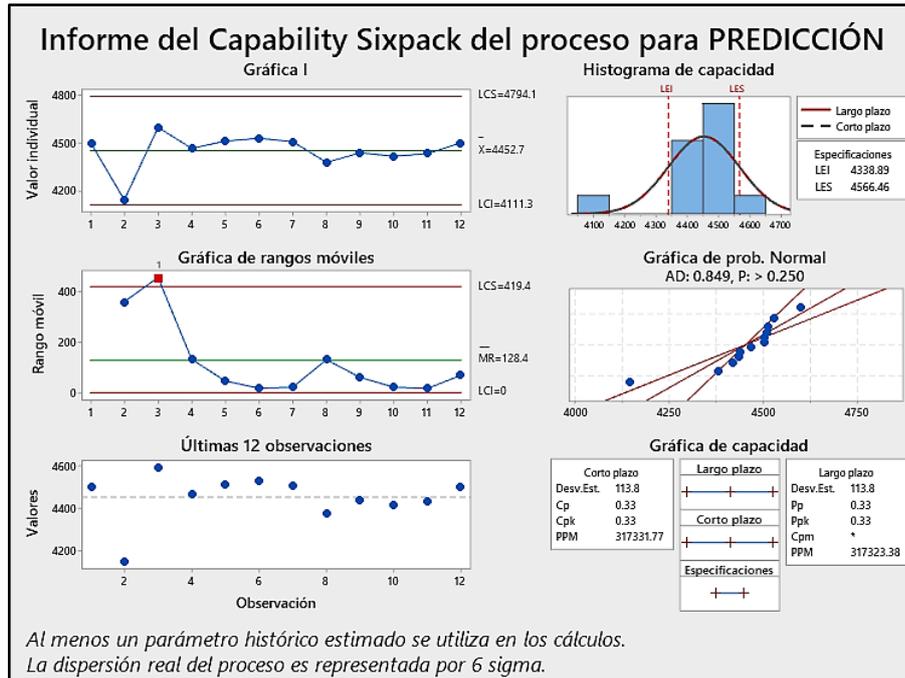


Figura 5.38: Capacidades del proceso para la demanda de energía eléctrica analizando los datos pronosticados para el año 2 020

Fuente: Los autores

En la figura 5.39, se puede observar el comportamiento de la curva de la demanda pronosticada, desde el 1 de enero hasta el 31 de diciembre del año 2 021, debido a la gran cantidad de datos se optó por depurar toda la información pronosticada con el fin de obtener la demanda máxima de cada mes.

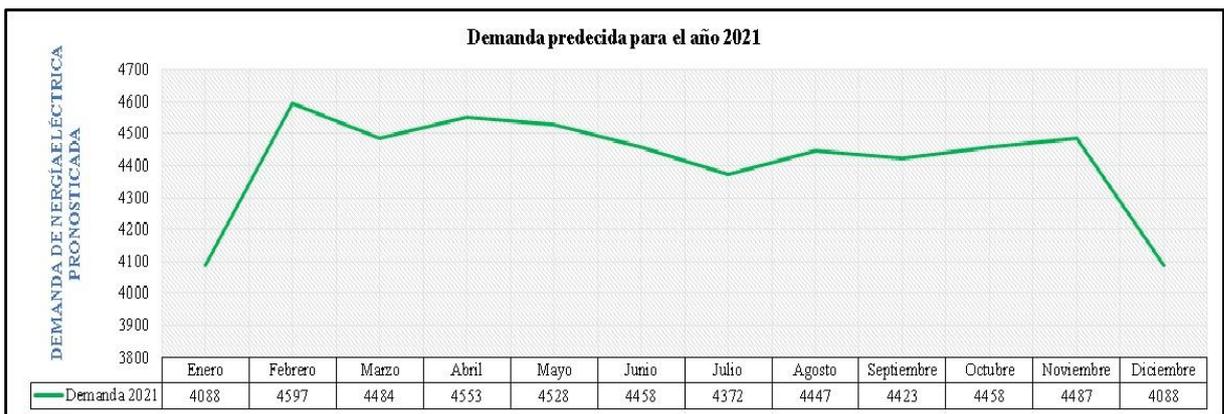


Figura 5.39: Comportamiento de la curva de la demanda eléctrica pronosticada para el año 2 021

Fuente: Los autores

Se puede apreciar que el valor de la demanda en el mes de enero y diciembre decrece con respecto a los demás meses, esto se puede observar en el análisis descriptivo realizado en la tabla 5.8. Adicionalmente se puede mencionar que los demás meses se mantienen con valores casi cercanos entre cada mes.

En la tabla 5.8, se detalla el valor de los datos que se pronosticaron, los cuales pertenecen al año 2021, se obtiene datos de valor máximo de la demanda eléctrica y el valor mínimo donde se presenta un rango de 508,66 kWh, del mismo modo no se puede realizar el cálculo de la frecuencia debido que los datos no se repiten.

Tabla 5.8: Análisis descriptivo de la demanda de energía eléctrica pronosticada para el año 2021

ANÁLISIS DESCRIPTIVO	
Máximo	4597,120 kWh
Mínimo	4088,457 kWh
Rango	508,6623 kWh
Media	4415,32 kWh
Mediana	3339,959 kWh
Varianza	26795,46 kWh
Desviación estándar	163,69
Coefficiente de variación	4 %
Límite superior	4579,01 kWh
Límite inferior	4251,62 kWh

Fuente: Los autores

En el análisis de las medidas de tendencia central, para el cálculo de la media o el promedio es de 4 415,32 kWh este valor representa el promedio de la energía que se consume en el intervalo de los datos analizados, la mediana representa el valor que ocupa la parte central del conjunto de datos, donde se representa el 50 % de datos por debajo y 50 % por encima de 3 339,95 kWh. En datos de medidas de dispersión, el cálculo de la desviación estándar se obtiene un valor de 163,69 con un coeficiente de variación de 4 %, comprobando la no homogeneidad en los datos de análisis. En la figura 5.40, se observa el comportamiento de los valores de pronóstico de la demanda de energía eléctrica, donde representa el valor límite máximo y mínimo, observando el intervalo de la dispersión de los datos.

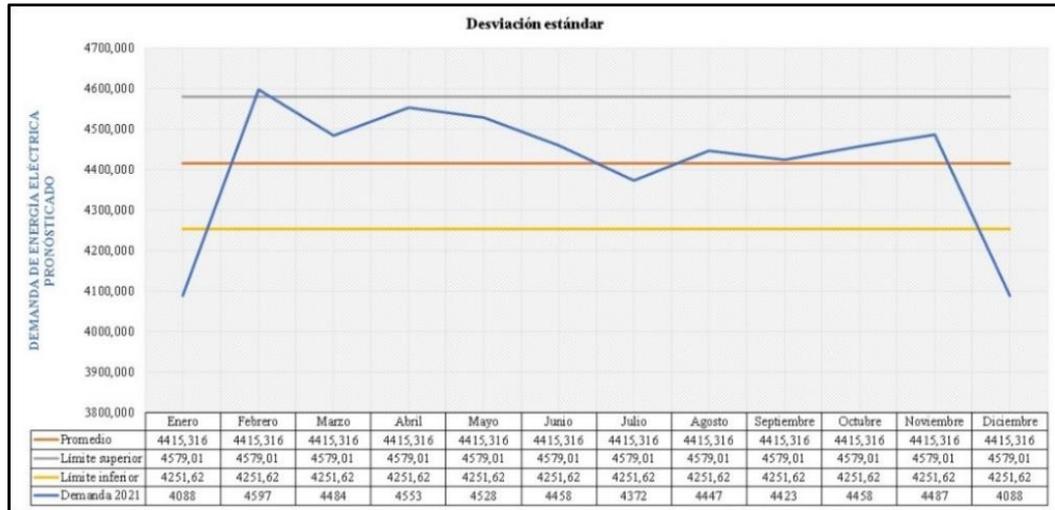


Figura 5.40: Desviación estándar para el análisis de la demanda de energía eléctrica para el año 2 021

Fuente: Los autores

En la figura 5.41, se detalla la capacidad del proceso para la demanda de energía eléctrica de los datos pronosticados para el año 2 021, donde se presenta 6 comportamientos, las gráficas Xbarra y R indican que el proceso es estable, con pocos puntos más allá de los límites de control, la gráfica de los últimos 25 subgrupos indica que los datos están distribuidos de forma aleatoria y simétrica alrededor de la media del proceso. La gráfica de probabilidad normal indica que los datos están distribuidos normalmente, entonces los supuestos del análisis de capacidad normal se cumplen. El histograma y los índices de capacidad indican que el proceso está aproximadamente centrado en el objetivo y las mediciones se encuentran en los límites de especificación requeridos.

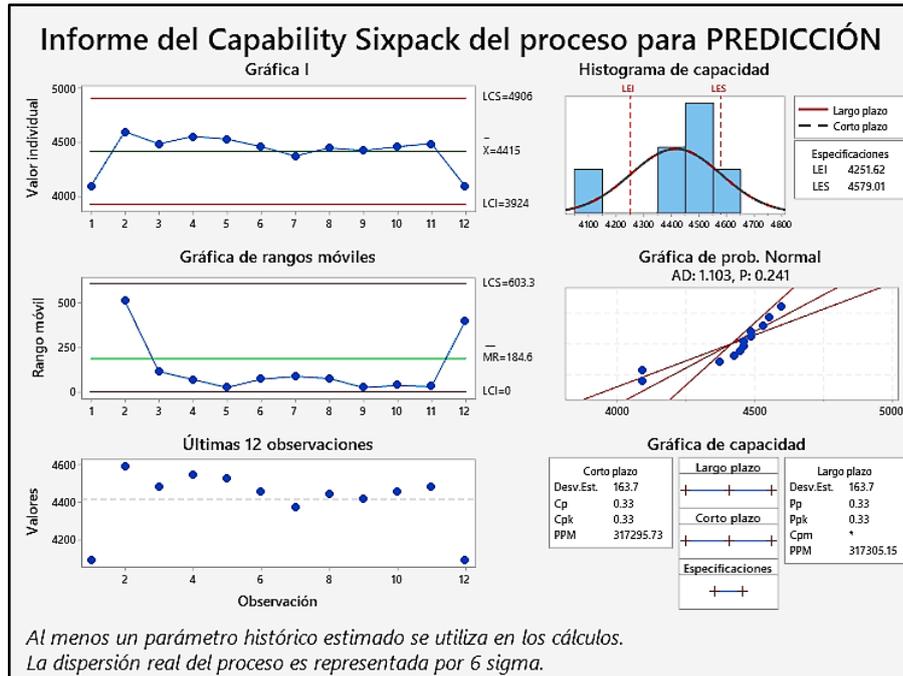


Figura 5.41: Capacidades del proceso para la demanda de energía eléctrica pronosticada para el año 2 021

Fuente: Los autores

5.11. ANALISIS DE LA COMPARACIÓN ENTRE LOS DATOS REALES Y LA DEMANDA PRONOSTICADA

En la figura 5.42, se puede observar el comportamiento de la variación de la curva de la demanda eléctrica con los datos reales de la primera semana del mes de febrero del 2 019 hasta segunda semana del mismo mes y el pronóstico de la demanda de energía eléctrica de los mismos años. Donde se puede observar que tienen una curva de manera muy similar tanto en el crecimiento y en la reducción de la demanda.

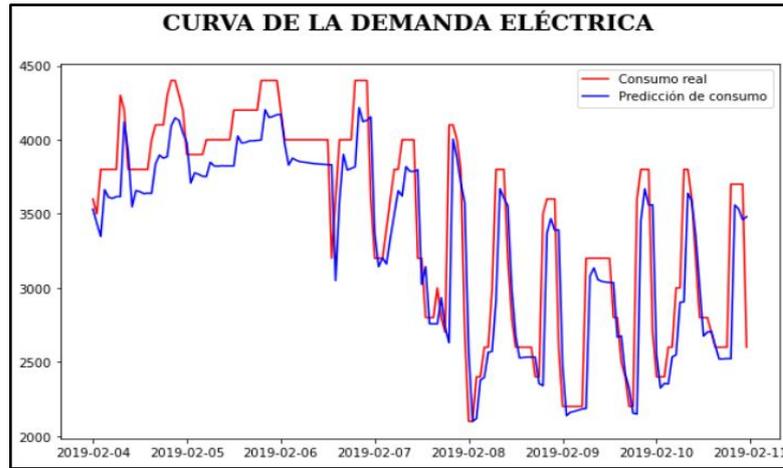


Figura 5.42: Comportamiento de la demanda de energía eléctrica real vs pronosticado analizando los datos en un intervalo de 1 semana

Fuente: Los autores

De la misma forma en la figura 5.43, se presenta el valor de los errores entre los datos reales con los datos del pronóstico de la demanda estos valores se resumen en la tabla 5.9, de esta forma ayuda a comprobar la calidad de los datos del pronóstico de la demanda de energía eléctrica.

Tabla 5.9: Valor del error promedio entre la demanda de energía eléctrica real y la pronosticada

ERROR MAE	
Valor del error	0,033

Fuente: Los autores

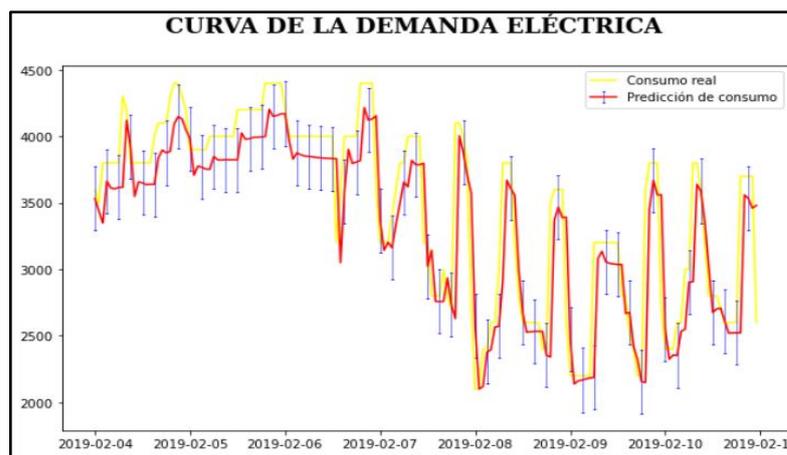


Figura 5.43: Gráfica de error entre demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 semana

Fuente: Los autores

Adicionalmente en la figura 5.44, se agregan figuras muestran los intervalos de la demanda de energía eléctrica comparando los datos reales y también los de pronóstico, en intervalos de 1 semana, donde se verifica el comportamiento de sus curvas existiendo una similitud considerable entre ellas, existiendo un valor grande de consumo de energía eléctrica en horas de la mañana.

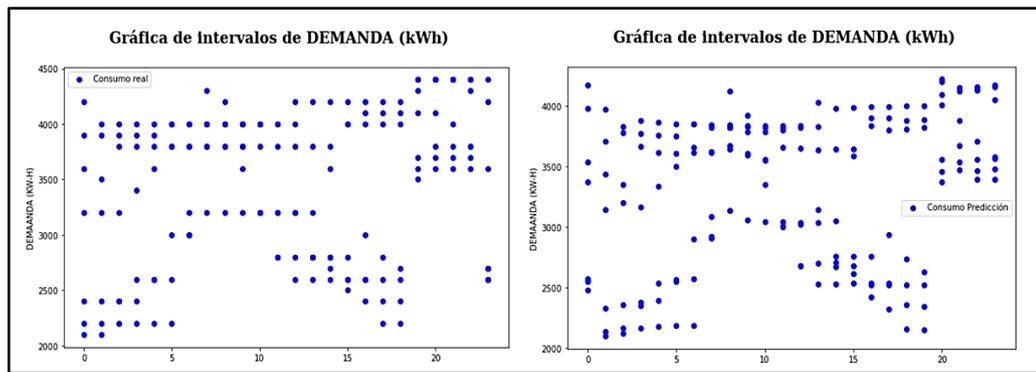


Figura 5.44: Intervalos que presenta la demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 semana

Fuente: Los autores

Para visualizar de mejor manera, el comportamiento de la curva de la demanda eléctrica analizando con datos reales y pronosticados, en la figura 5.45, representa la demanda eléctrica pronosticada y real que tienden a ser similares, en horas de la madrugada existe un incremento en la carga hasta las 10 am, entre 11:00 y 15:00 decreció existiendo menos consumo eléctrico, mientras que transcurren las horas de la tarde y noche tiende a elevar la carga.

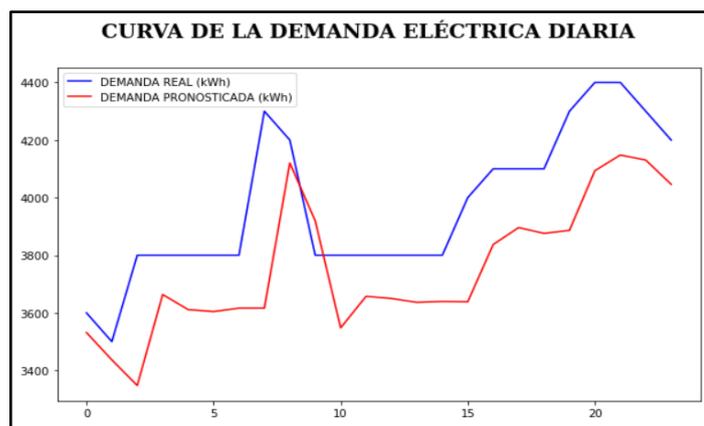


Figura 5.45: Curva demanda eléctrica real vs pronosticada analizando los datos en el intervalo de 1 día

Fuente: Los autores

Del mismo modo en la figura 5.46, representa el valor del porcentaje de error analizando los datos reales y el pronóstico de la demanda, en la tabla 5.10, se obtiene el error promedio que se tuvo en la comparativa de las dos curvas de la demanda eléctrica, el cual es de 0,0165 por ende los datos que se obtuvo del pronóstico de la demanda son correctos, confiables y con menor error.

Tabla 5.10: Valor del error promedio entre la demanda eléctrica real y la pronosticada

ERROR MAE	
Valor del error	0,0165

Fuente: Los autores

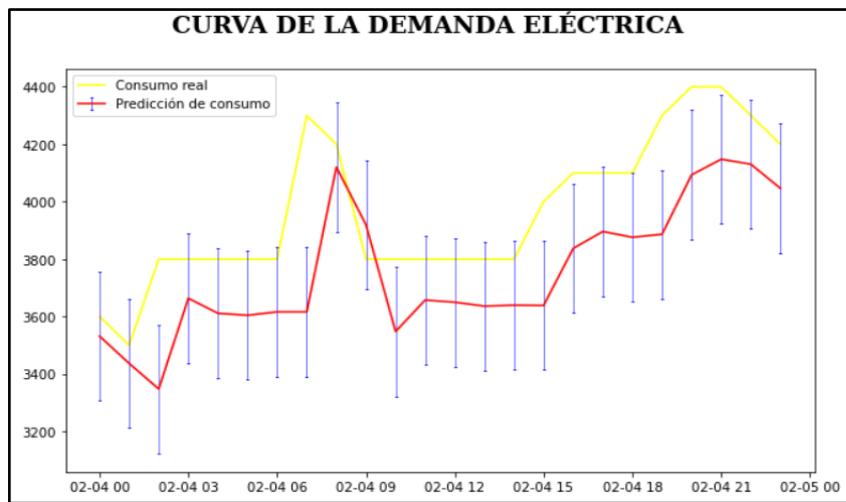


Figura 5.46: Gráfica de error entre demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 día

Fuente: Los autores

Para una apropiada visualización de la gráfica de intervalos de dispersión como se muestra en la figura 5.47, se ilustra intervalos de la demanda de energía eléctrica con datos reales y pronosticados de 1 día, donde se verifica el comportamiento de la curva eléctrica de gran similitud tanto en real como en pronóstico, existe valores elevados de demanda en horas de la madrugada, mientras que transcurren las horas de la tarde y noche tiende a crecer la carga de manera muy elevada.

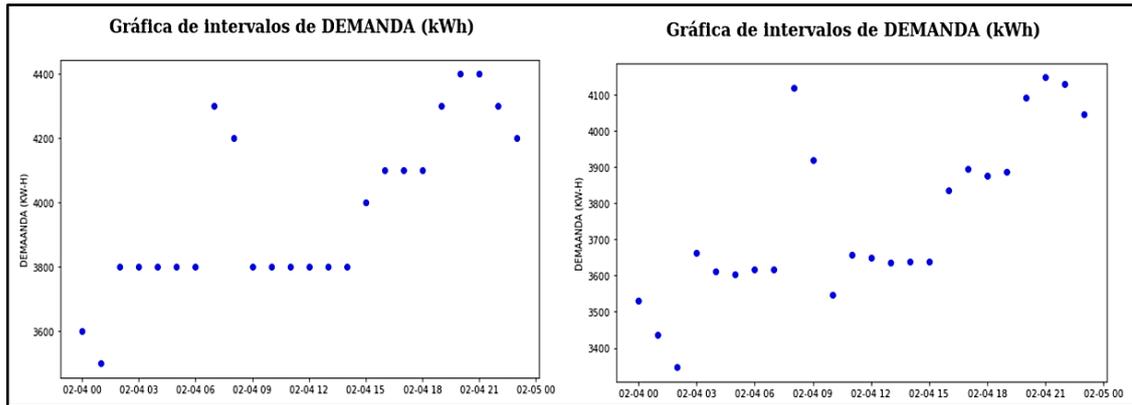


Figura 5.47: Intervalos que presenta la demanda de energía eléctrica real y la pronosticada analizando los datos en el intervalo de 1 día

Fuente: Los autores

5.11.1. Análisis del comportamiento de los errores de la demanda de energía eléctrica pronosticada en el año 2 019 para determinar la confiabilidad y validación del programa realizado en Python.

Para realizar una correcta validación de un programa computacional se debe tener en cuenta que dentro de la predicción con redes neuronales artificiales la manera correcta de su validación se la realiza mediante el criterio de aceptación, el cual se define por el dueño del producto y el equipo de desarrollo, estos describen los requisitos que el producto debe cumplir para estar terminado [51].

Una vez comprendido lo antes mencionado se procedió a definir el criterio de validación para el pronóstico de la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2, el cual debe cumplir que el error promedio de la RNA sea menor que el error promedio del pronóstico del otro método (Regresión lineal), para que los pronósticos de la RNA sean válidos.

En la figura 5.48, se realizó el pronóstico mediante el método de regresión lineal y se calculó sus respectivos errores para conocer el comportamiento de la demanda de energía eléctrica en el año 2 019, en donde se observó que no era el adecuado debido a que su error porcentual absoluto medio (MAPE) es de 19 % y según [52], una medida es buena cuando no supera el 5 %.

PRONÓSTICO DE LA DEMANDA DE ENERGIA MEDIANTE REGRESIÓN LINEAL										
n	Mes	Demanda Real	D.Pronosticada	Error Abs.	Error % Abs.	Σ Error Abs	MAD	Error Nor.	Σ Error Nor	TS
1	Enero	2799	3158	359.3441	12.84%	359.34409	359.3	-359.3441	-359.34409	-1
2	Febrero	3015	3176	161.2679	5.35%	520.61194	260.3	-161.2679	-520.61194	-2
3	Marzo	2487	3194	706.9032	28.42%	1227.5152	409.2	-706.9032	-1227.5152	-3
4	Abril	2629	3213	583.8333	22.21%	1811.3485	452.8	-583.8333	-1811.3485	-4.0
5	Mayo	3690	3231	459.0538	12.44%	2270.4023	454.1	459.0538	-1352.2947	-3
6	Junio	4104	3249	854.8889	20.83%	3125.2912	520.9	854.8889	-497.40585	-1
7	Julio	4201	3267	933.5376	22.22%	4058.8288	579.8	933.5376	436.13178	0.8
8	Agosto	4163	3285	877.6344	21.08%	4936.4632	617.1	877.6344	1313.7662	2.1
9	Septiembre	3642	3304	338.3611	9.29%	5274.8243	586.1	338.3611	1652.1273	2.8
10	Octubre	3355	3322	33.24194	0.99%	5308.0662	530.8	33.24194	1685.3692	3.2
11	Noviembre	2334	3340	1005.833	43.09%	6313.8996	574.0	-1005.833	679.53591	1.2
12	Diciembre	2678	3358	679.6398	25.38%	6993.5394	582.8	-679.6398	-0.1038786	0
				SUMA %	224.14%					
				n	12					
				MAPE	19%					

Figura 5.48: Comportamiento de la demanda de energía eléctrica mediante regresión lineal

Fuente: Los autores

En la figura 5.49, se realizó el pronóstico mediante Redes neuronales artificiales y se calculó sus respectivos errores para conocer el comportamiento de la demanda de energía eléctrica en el año 2 019 , en donde se observó que era el adecuado debido a que su error porcentual absoluto medio (MAPE) es de 3 % y según [52].Una medida es buena cuando no supera el 5 %.

PRONÓSTICO DE LA DEMANDA DE ENERGIA MEDIANTE REDES NEURONALES ARTIFICIALES (PYTHON)										
n	Mes	Demanda Real	D.Pronosticada	Error Abs.	Error % Abs.	Σ Error Abs	MAD	Error Nor.	Σ Error Nor	TS
1	Enero	2799	2786	12.33152	0.44%	12.331519	12.3	12.33152	12.331519	1
2	Febrero	3015	2840	174.3997	5.78%	186.73125	93.4	174.3997	186.73125	2
3	Marzo	2487	2590	102.8483	4.14%	289.57952	96.5	-102.8483	83.882985	0.9
4	Abril	2629	2610	19.18506	0.73%	308.76457	77.2	19.18506	103.06804	1.3
5	Mayo	3690	3815	125.2144	3.39%	433.97897	86.8	-125.2144	-22.146355	-0.3
6	Junio	4104	4059	44.78306	1.09%	478.76202	79.8	44.78306	22.636701	0.3
7	Julio	4201	4189	11.18103	0.27%	489.94306	70.0	11.18103	33.817736	0.5
8	Agosto	4163	4066	96.9545	2.33%	586.89756	73.4	96.9545	130.77224	1.8
9	Septiembre	3642	3549	93.42021	2.56%	680.31777	75.6	93.42021	224.19245	3
10	Octubre	3355	3228	127.1274	3.79%	807.44522	80.7	127.1274	351.31989	4.4
11	Noviembre	2334	2254	80.2149	3.44%	887.66012	80.7	80.2149	431.5348	5.3
12	Diciembre	2678	2950	271.654	10.14%	1159.3142	96.6	-271.654	159.88076	1.7
				SUMA %	38.10%					
				n	12					
				MAPE	3%					

Figura 5.49: Comportamiento de la demanda de energía eléctrica mediante Python

Fuente: Los autores

Con los datos obtenidos en figura 5,48 y en la figura 5,49 se realizó dos gráficos de barras en los cuales se especifica el comportamiento del MAD (Desviación media absoluta) para así

determinar la dispersión de los valores analizados que se alejan de los valores esperados, básicamente proporcionaron una medición de los errores promedios de los pronósticos como se observa en la figura 5.50, se puede observar que los valores MAD del análisis con redes neuronales presenta un error inferior en comparación al otro método.

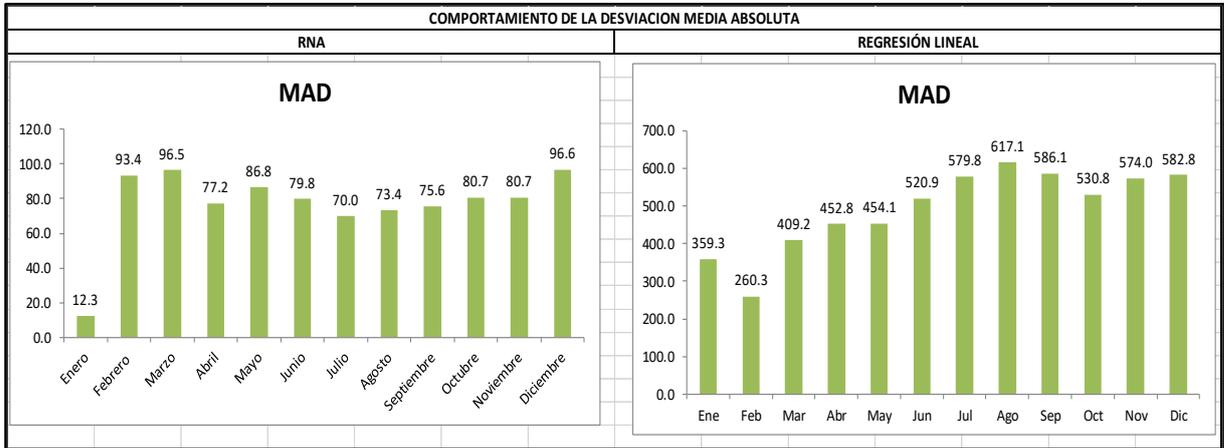


Figura 5.50: Comportamiento de la demanda de energía eléctrica mediante Python

Fuente: Los autores

Después de haber realizado los procedimientos anteriormente mencionados, en la figura 5.51, se elaboró un análisis con los resultados obtenidos de las predicciones de los dos métodos utilizados para la validación de la hipótesis y el cumplimiento del objetivo específico número cuatro. Se observa que la predicción más acertada es la que se realizó con redes neuronales artificiales en el software computacional Python obteniendo resultados de error porcentual absoluto medio del 3 %, como se mencionó anteriormente debe ser menor al 5 % por lo que se puede concluir que el análisis y validación son correctos lo cual nos permitió seguir realizando el análisis con RNAs, para los años del 2 020 y 2 021.

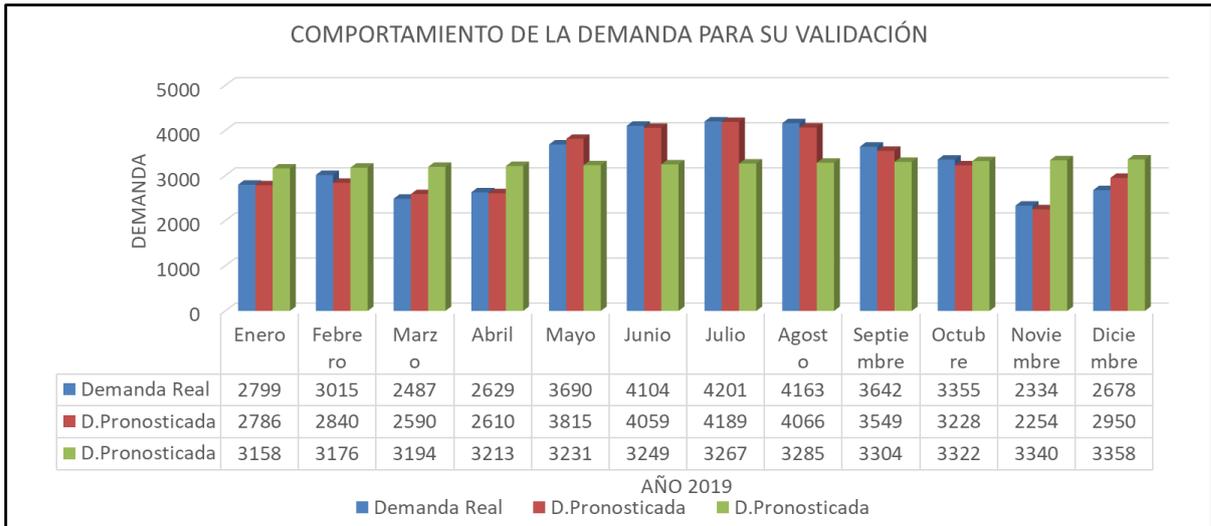


Figura 5.51: Comportamiento de la demanda de energía eléctrica para su validación

Fuente: Los autores

5.11.2. Análisis para la comparación entre la base de datos depurados y los datos pronosticados a los años 2020 y 2021

En la figura 5.52, se observó el comportamiento de la variación de la curva de la demanda eléctrica con la base de datos depurada de los 5 años, donde se analizó que tienen una curva de manera muy similar tanto en el crecimiento y en la reducción de la demanda, con la excepción de 2 años:

- Año 2016 - Presenta un bajo consumo en el mes de noviembre con una demanda de 2500 kWh y diciembre con una demanda de 2600 kWh.
- Año 2017- Presenta un bajo consumo en los meses de enero, febrero y marzo con una misma demanda de 2600 kWh.

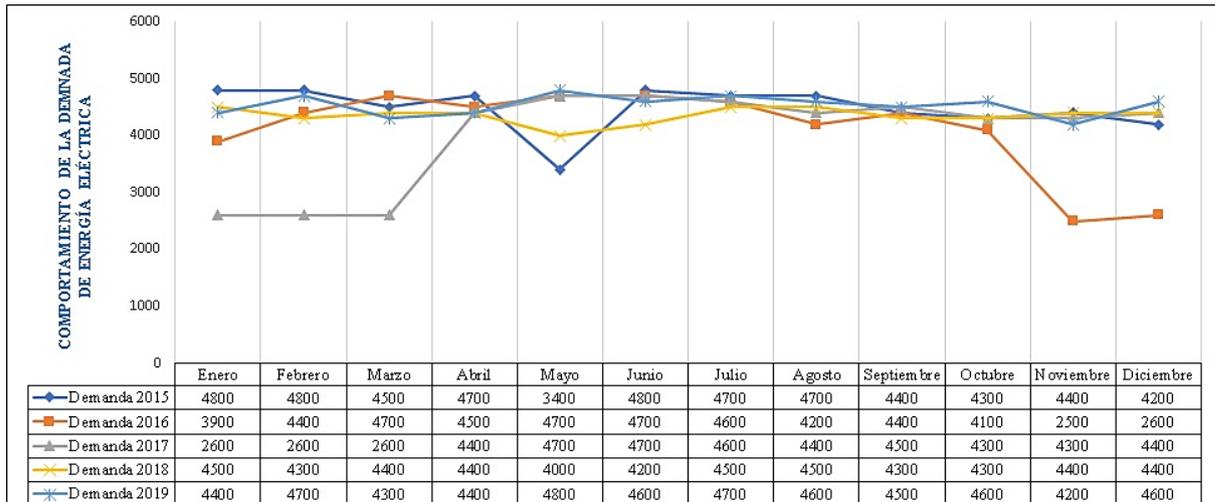


Figura 5.52: Comportamiento de la demanda de energía eléctrica real desde el año 2 015 hasta el año 2 019

Fuente: Los autores

En la figura 5.53, se puede observar el comportamiento de la variación de la curva de la demanda eléctrica de los años 2 020 y 2 021 con los datos pronosticados de los 12 meses del año, donde se puede observar que tienen una curva de manera muy similar tanto en el crecimiento y en la reducción de la demanda de energía eléctrica.

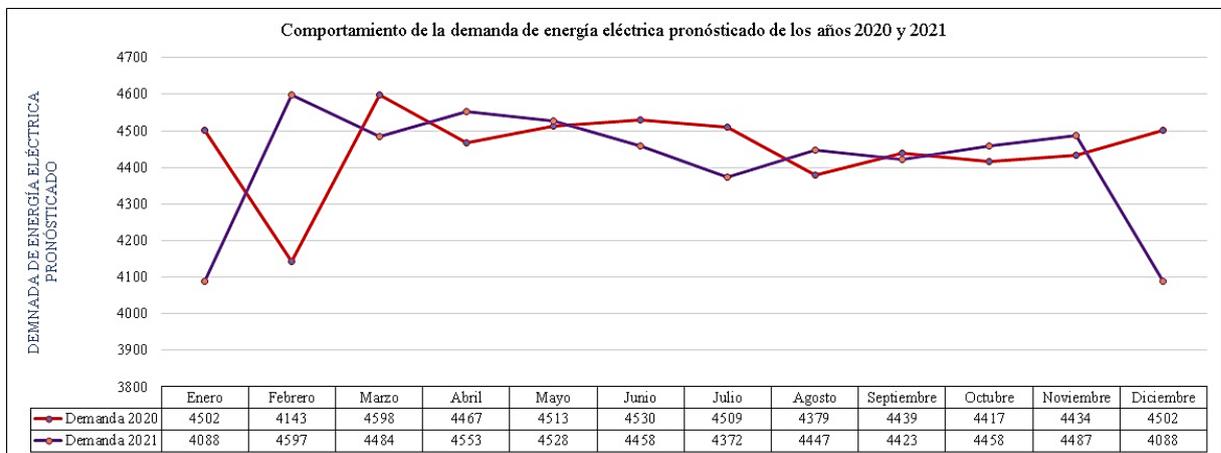


Figura 5.53: Comportamiento de la demanda de energía eléctrica pronosticada de los años 2 020 y 2 021

Fuente: Los autores

Adicionalmente en la figura 5.54, se muestran los intervalos de la demanda de energía eléctrica comparando los datos pronosticados para los años 2 020 y 2 021, en intervalos de los 12 meses del año, donde se verifico el comportamiento de sus curvas existiendo una similitud

considerable entre ellas, existiendo valores elevados de consumo de energía eléctrica en los meses de marzo y abril de los dos años pronosticados.

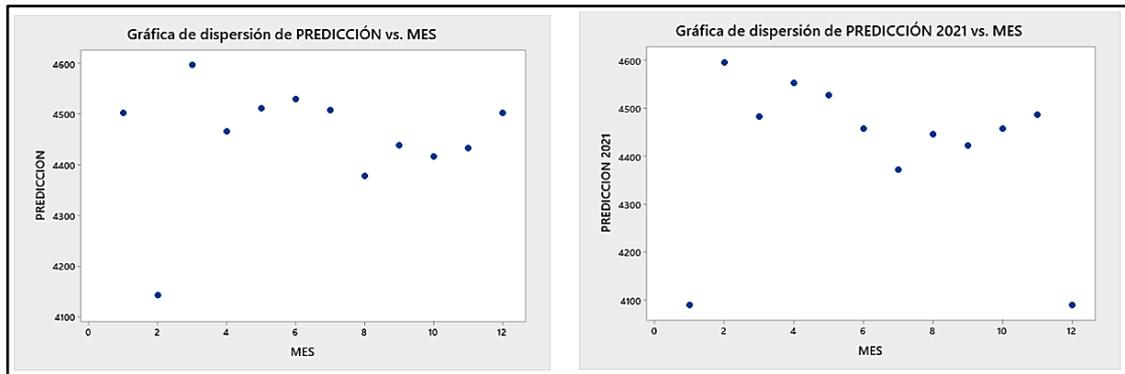


Figura 5.54: Intervalos que presenta la demanda de energía eléctrica pronosticada en los años 2 020 y 2 021

Fuente: Los autores

En la figura 5.55, se puede observar la curva de la demanda pronosticada, desde el 1 de enero del año 2 015 hasta el 31 de diciembre del año 2 021, debido a la gran cantidad de datos se optó por depurar toda la información real y pronosticada con el fin de obtener la demanda máxima de cada mes para cada año.

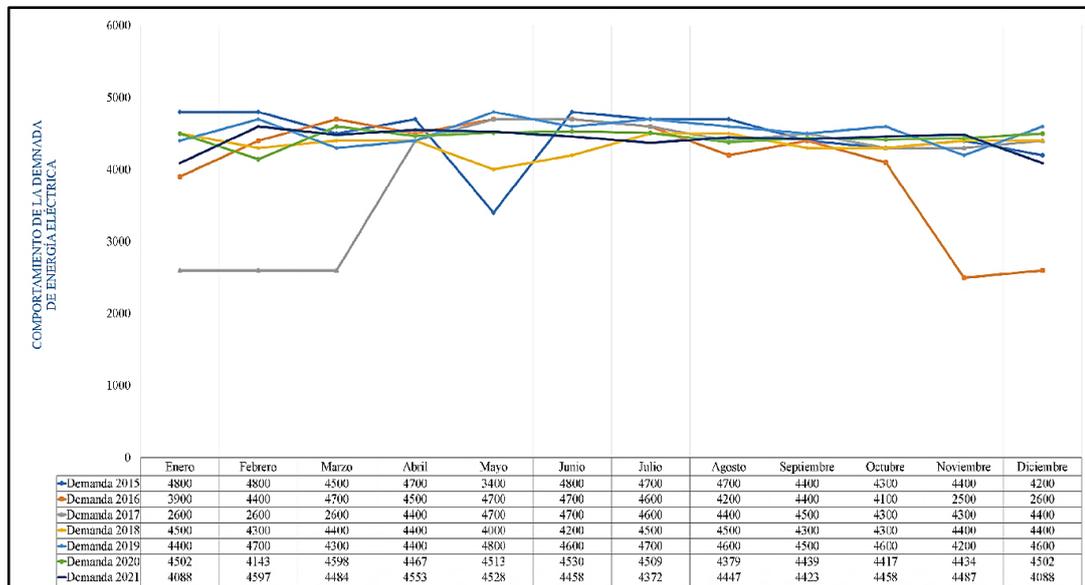


Figura 5.55: Comportamiento de la demanda de energía eléctrica desde el año 2 015 hasta el año 2 021

Fuente: Los autores

El propósito de mostrar la figura anterior es verificar el comportamiento de la demanda pronosticada en los años 2 020 y 2 021 y revisar si nuestra red neuronal recurrente predice la demanda de energía eléctrica correctamente.

En la tabla 5.11, se detalla los valores de los datos reales y los que se pronosticaron, los cuales pertenecen al año 2 020 y 2 021, de esta forma se obtiene datos de valor máximo de la demanda eléctrica y el valor mínimo donde se presenta un rango de 2 300 kWh, del mismo modo no se puede realizar el cálculo de la frecuencia debido que los datos no se repiten.

Tabla 5.11: Análisis descriptivo de la demanda de energía eléctrica real y pronosticada desde el año 2 015 hasta el año 2 021

ANÁLISIS DESCRIPTIVO	
Máximo	4800,000 kWh
Mínimo	2500,000 kWh
Rango	2300 kWh
Media	4334,71 kWh
Mediana	4442,636 kWh
Varianza	244159,57 kWh
Desviación estándar	494,13
Coefficiente de variación	11 %
Límite superior	4828,84 kWh
Límite inferior	3840,59 kWh

Fuente: Los autores

Para el análisis de las medidas de tendencia central, el cálculo de la media o el promedio es de 4 334,71 kWh es decir que representa el promedio de la energía que se consume en el intervalo de los datos analizados, la mediana representa el valor que ocupa la parte central del conjunto de datos, donde se representa el 50 % de datos por debajo y 50 % por encima de 4 442,63 kWh. En datos de medidas de dispersión, el cálculo de la desviación estándar se obtiene un valor de 494,13 con un coeficiente de variación de 11 %, comprobando la no homogeneidad en los datos de análisis.

5.12. DESARROLLO DE LA INTERFAZ GRÁFICA

En el desarrollo de una interfaz gráfica fue necesario la creación de los respectivos módulos con la ayuda de Python y Visual Studio Code, de esta forma crear un correcto funcionamiento del programa computacional propuesto para la predicción de la demanda eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2, cada módulo tiene asociado a una interfaz

gráfica de usuario o denominado (GUI) de fácil acceso y amigables para cualquier usuario incluso para ser usado por los operarios de ELEPCO S.A., también se requirió de una GUI principal para entrelazar los distintos módulos.

La interfaz gráfica que se planteó realizar para mostrar los resultados del trabajo de investigación que está compuesta por tres módulos:

- Módulo de datos históricos
- Módulo de entrenamiento de red neuronal
- Módulo de predicción de la demanda

Cada uno de los módulos tienen características únicas que permiten un correcto funcionamiento de la interfaz.

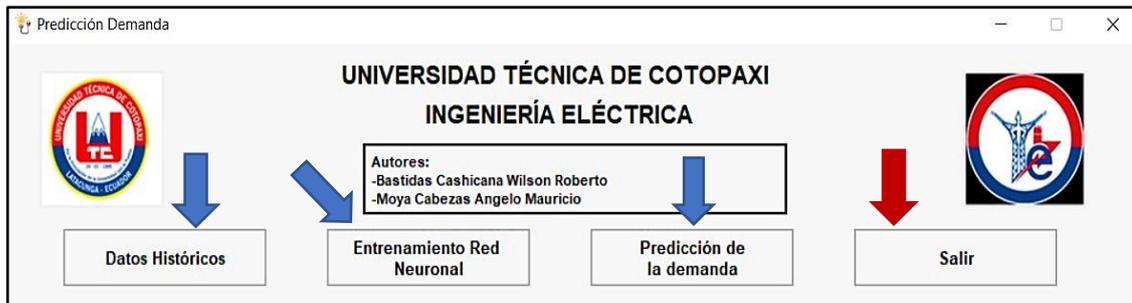


Figura 5.56: Visualización del menú principal de la interfaz gráfica diseñada

Fuente: Los autores

Tal como se observa en la figura 5.56, contiene un menú que ayuda a la selección de los diferentes módulos, adicionalmente se agregó un menú denominado “SALIR” y sirve para salir de la interfaz creada.

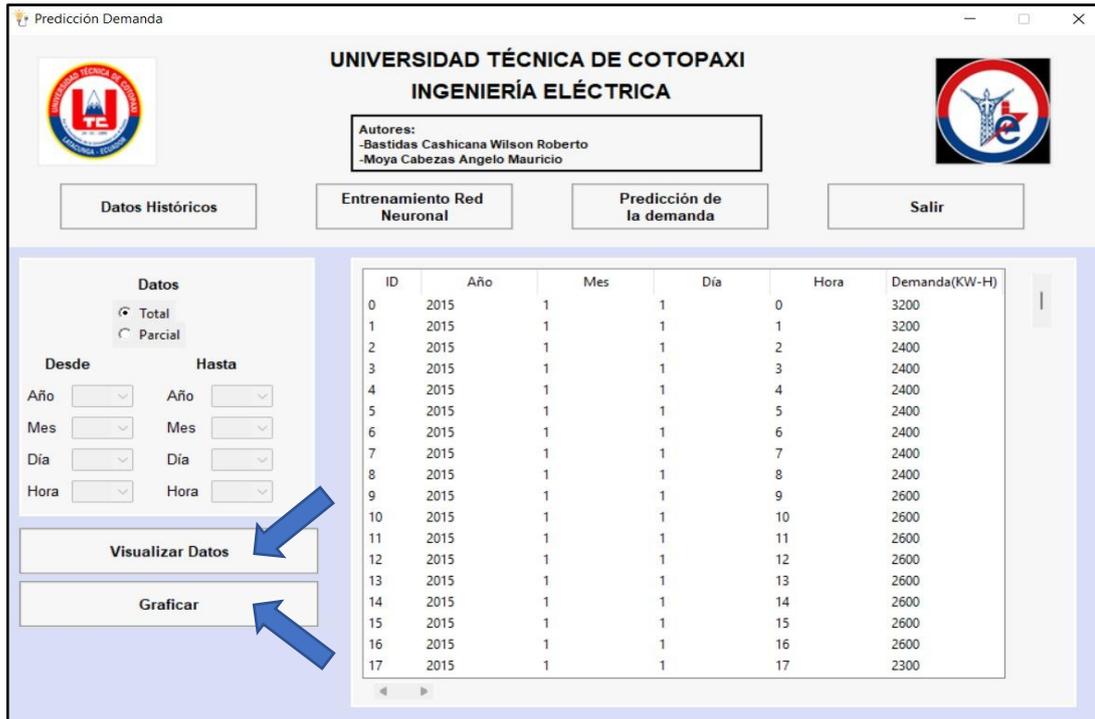


Figura 5.57: Visualización de la interfaz completa

Fuente: Los autores

Como se puede observar en la figura 5.57, se muestra la interfaz completa, en la parte inferior izquierda se muestra tres menús denominados: visualizar datos numéricos y realizar gráficas con respecto al comportamiento de la demanda.

5.12.1. Módulo de datos históricos

La función principal de este módulo es analizar los datos históricos en función de la base de datos utilizados en análisis anteriores con la diferencia que la información que se presenta debe estar automatizada. La primera sección de la interfaz permite configurar el intervalo de tiempo que se desee analizar y mostrar la información numéricamente, la siguiente sección permite graficar la curva de la demanda de energía eléctrica.

En la figura 5.58, se puede apreciar el funcionamiento del módulo, que para este caso se ocupa toda la base de datos, seleccionando la opción “Total” para formar la curva de la demanda de todos los datos históricos en conjunto.

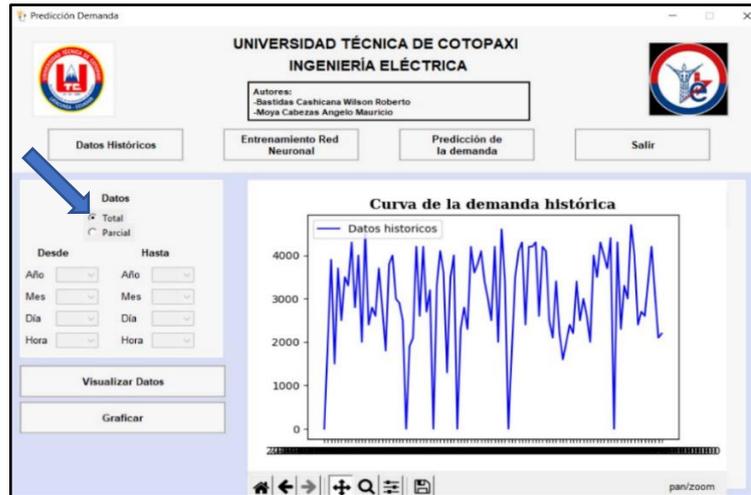


Figura 5.58: Interfaz para el análisis de la predicción de la demanda de energía eléctrica

Fuente: Los autores

En la figura 5.59, se utiliza otro tipo de análisis reduciendo el intervalo de tiempo, para este caso se selecciona la opción denominada “Parcial” y de esta forma se habilita el menú de la fecha de inicio y fin en intervalos de año, mes, día, hora, brindando al usuario la libertad de proponer un periodo de análisis. Es necesario mencionar que los datos deben tener concordancia, es decir, los datos que se agreguen en la fecha de inicio deben ser menores o antiguas a los datos ingresados en la fecha de finalización, caso contrario la interfaz presentará errores de cálculos. Para informar de este error, se ha agregado un mensaje que le indicará al usuario que las fechas ingresadas con incorrectas o no existe información en la base de datos.

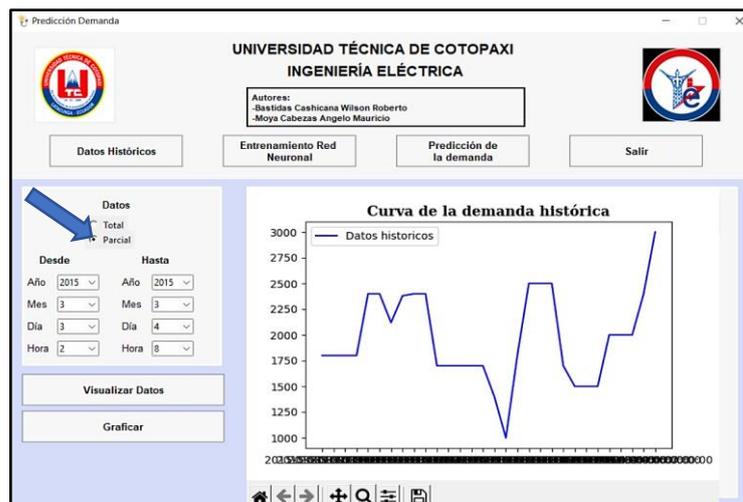


Figura 5.59: Módulo de datos históricos representando la curva de la demanda

Fuente: Los autores

5.12.2. Módulo de entrenamiento de la red

El propósito de este módulo es que el usuario pueda configurar, crear y entrenar una red neuronal artificial que sea útil en la predicción de la demanda de energía eléctrica. Este módulo cuenta con una sección que permite crear y modificar la red neuronal artificial.

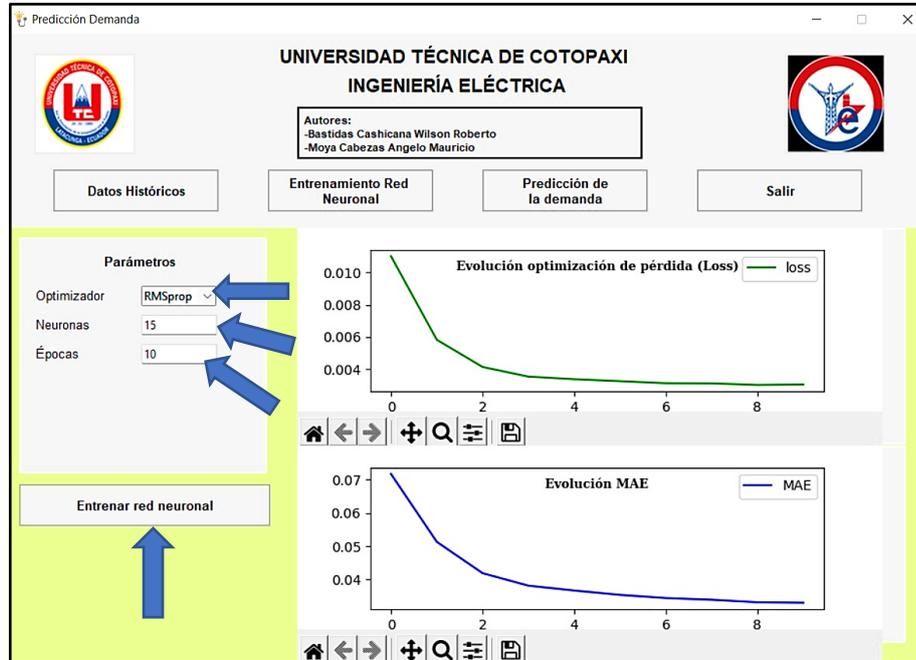


Figura 5.60: Interfaz para el entrenamiento de la predicción de la demanda de energía eléctrica

Fuente: Los autores

En la figura 5.60, se puede observar nuevas opciones que permiten modificar la estructura de la red neuronal implementada de acuerdo a las necesidades y criterios del usuario. La primera opción es el “Optimizador” esto permite elegir el algoritmo para realizar la predicción, luego está la opción de “Neuronas” que permite modificar el número de neuronas que se desea entrenar, para luego pasar a la opción “Épocas” es decir el número de entrenamiento que se desea que la red neuronal logre predecir la demanda.

Luego de ingresar la información requerida en cada una de las opciones anteriores se procede a seleccionar la opción “Entrenar red neuronal” esta función permite visualizar al usuario el comportamiento de la función de pérdida y el error medio absoluto tal como se muestra en la figura 5.61, cabe recalcar que estos valores deben ser pequeños debido a que estos errores comparan los datos reales con los datos pronosticados.

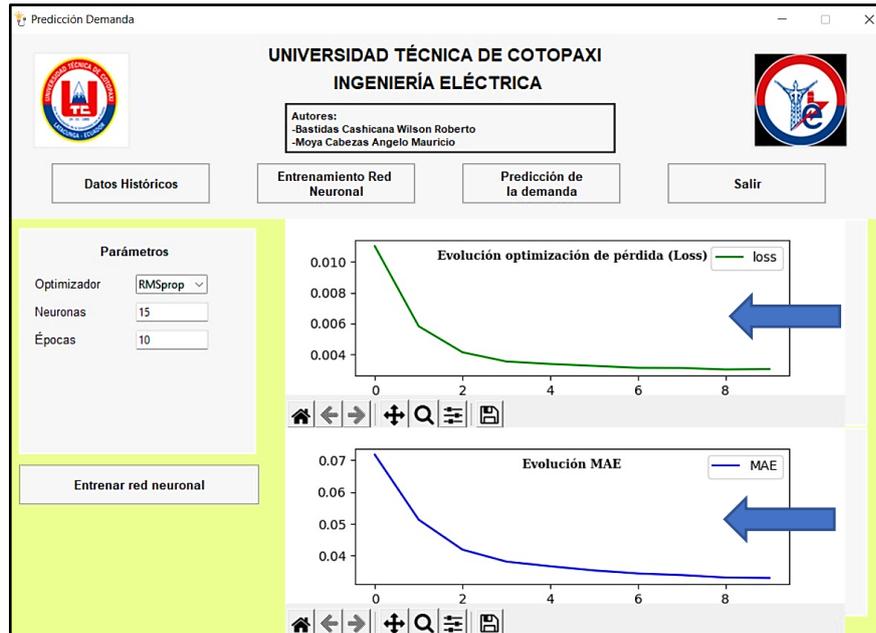


Figura 5.61: Interfaz para el entrenamiento de la predicción de la demanda de energía eléctrica

Fuente: Los autores

5.12.3. Módulo de la predicción de la demanda

El siguiente modulo tiene como propósito presentar las predicciones de la demanda de energía eléctrica en base a los datos ingresados. Este módulo cuenta con nuevos menús adicionales, el primero es “Calcular” esta opción permite conocer la predicción de la demanda de energía eléctrica. La opción “Predecir demanda” presenta los valores numéricos realizados en la predicción. Para visualizar el comportamiento de la demanda pronosticada se selecciona la opción “Gráfica”. Y como última opción denominada “Tabla” permite al usuario exportar esta información hacia el programa computacional Excel en formato “csv”.

La información que el usuario se plantea ingresar debe considerar el año, mes, día, hora, esta información es importante debido a las razones ya antes mencionadas, de este modo se puede predecir la demanda de energía eléctrica futura en función a los datos de tiempo y de esta forma visualizar dicha demanda a lo largo del tiempo.

En la figura 5.62, se puede apreciar el funcionamiento de la interfaz, en este caso los valores numéricos de la predicción de la demanda de energía eléctrica.

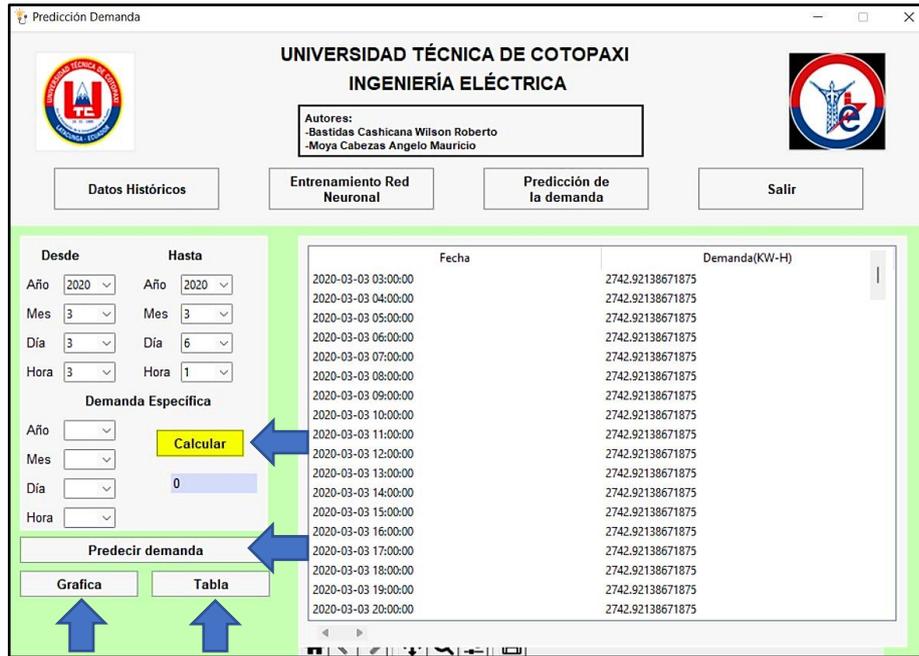


Figura 5.62: Módulo para la predicción de la demanda de energía eléctrica

Fuente: Los autores

En la figura 5.63, se muestra el funcionamiento de la interfaz, en este caso se presenta el comportamiento de la curva para la demanda de energía eléctrica.

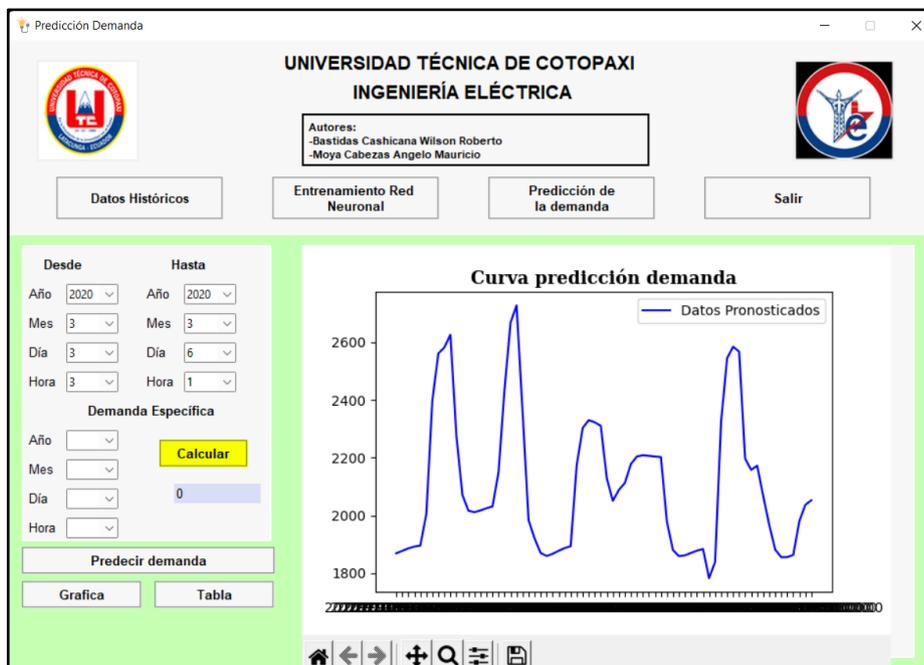


Figura 5.63: Módulo para la predicción de la demanda de energía eléctrica

Fuente: Los autores

6. IMPACTOS

Tras el desarrollo de un sistema de predicción con redes neuronales artificiales para determinar la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2, fue necesario considerar los impactos importantes. Cada uno de ellos que se encuentran descritos a continuación:

6.1. Impactos técnicos

Este impacto se centra en que tan precisos son los resultados en la predicción de la demanda de energía eléctrica, pero sin que el recurso computacional sea demasiado grande, cabe recalcar que estos puntos afectan el tiempo que transcurre al obtener los resultados de la predicción en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

6.2. Impactos sociales

Al mencionar que se desarrolla un sistema de predicción de la demanda de energía eléctrica y contar con una interfaz amigable con el usuario, permite tanto a estudiantes de la carrera de Ingeniería Eléctrica o carreras a fines como para los operarios encargados del funcionamiento de la CENTRAL HIDROELÉCTRICA ILLUCHI 2 a fortalecer sus conocimientos en el área de redes neuronales artificiales fusionando la parte práctica con la parte teórica.

6.3. Impactos ambientales

El desarrollo de un sistema de predicción con redes neuronales artificiales para determinar la demanda de energía eléctrica aporta al cuidado del medio ambiente, brindando un apoyo en la programación de la energía a producirse en la CENTRAL HIDROELÉCTRICA ILLUCHI 2 en un tiempo determinado por los operadores encargados, aprovechando de manera eficiente el recurso hídrico que se encuentra disponible en el tanque de captación.

6.4. Impactos económicos

El proyecto está basado en la aplicación de redes neuronales artificiales de tal manera que tiene un bajo costo, debido al programa computacional Python que mantiene sus licencias bajo ningún costo, una vez que ELEPCO S.A. opte por utilizar el sistema desarrollado, el gasto económico se centrará en la capacitación necesaria hacia los operadores de la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

7. CONCLUSIONES Y RECOMENDACIONES

7.1. CONCLUSIONES

- Al realizar el estudio investigativo con la ayuda de varias referencias bibliográficas relacionadas con la predicción de la demanda eléctrica, se desarrolló completamente un programa computacional en base al lenguaje de programación Python que ayudaron en la predicción de la demanda de energía eléctrica basado en las redes neuronales recurrentes.
- Al desarrollar un análisis completo de toda la base de datos de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, se identificó las variables de entradas mediante la formación de un mapa de calor verificando la correlación que existe entre estas, con esta idea se define la aplicación e implementación de la red neuronal artificial aplicando diferentes librerías que proporciona Python.
- El diseño del algoritmo para la predicción de la demanda eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2 se ha aplicado series de tiempo con Tensorflow para le conexión de los datos de entrada y Keras en el entrenamiento del algoritmo, se ha creado una red secuencial con la LSTM, la estructura de la RNA está formado por 10 neuronas de entrada, dos capas ocultas las cuales están compuestas por 2 capas dropout para evitar la memorización de datos y una salida para la predicción de la demanda de energía eléctrica.
- Para el entrenamiento es necesario que los datos sean escalados para que no se alteren los diferentes valores. Utilizando la red neuronal artificial, mediante el manejo del optimizador de entrenamiento RMSprop, con 10 números de retrasos, 10 neuronas, el 80 % de datos de entrenamiento, 20 % datos de validación, para obtener resultados pronosticados, de esta forma proporcionando un acercamiento a los datos reales. Con este modelo se logró confirmar la hipótesis planteada en el trabajo de investigación.
- La precisión y exactitud del modelo de red neuronal artificial recurrente está ligado a la configuración de la red y el tiempo de entrenamiento, en la actualidad no existen algoritmos exactos para lograr encontrar la mejor configuración, reducir el tiempo de entrenamiento, además del recurso computacional limitado que se posee, esto trae como consecuencia, realizar varias iteraciones para conseguir el menor error posible. Es

necesario considerar que no siempre el error disminuye a un mayor tiempo de entrenamiento. Con el acceso de una supercomputadora que permita desarrollar varios modelos, es indudable que los resultados serían óptimos de esta forma se podrá lograr una disminución considerable en el error entre los datos reales y los pronosticados.

7.2. RECOMENDACIONES

- Para este trabajo de investigación se realizó un estudio de forma global, es decir la información de toda la CENTRAL HIDROELÉCTRICA ILLUCHI 2, para futuros trabajos se puede implementar la aplicación de redes neuronales artificiales para el análisis de cada uno de los grupos generadores.
- El algoritmo planteado fue desarrollado con la ayuda del programa computacional Python al ser un software sofisticado y gratuito que está a disposición de cualquier persona, se recomienda realizar predicciones con otros programas computacionales utilizados para el análisis de datos entre ellos se puede encontrar: Matlab, Julia o R y comparar los resultados obtenidos con los desarrollados en este trabajo de investigación.
- Las redes neuronales artificiales recurrentes LSTM es una pequeña área que presenta la inteligencia artificial, al tratarse de un pronóstico de la demanda de energía eléctrica a través de la variación del tiempo este tipo de redes neuronales fueron la mejor opción para desarrollar un modelo de predicción se recomienda la aplicación de otro método empleado en la predicción de la demanda.
- Utilizar el método de red neuronal artificial planteado utilizando un mayor número de variables de entrada, cambiando la estructura de la red para obtener mejores resultados reduciendo el error medio absoluto y el error medio porcentual.
- Para futuros trabajos se recomienda realizar un estudio de la demanda de energía eléctrica considerando el antes y después de la pandemia del COVID-19. Es necesario mencionar que las cargas presentan una variedad de factores como: el tamaño de la carga y el periodo de funcionamiento, con esta idea se profundiza el análisis en cada uno de los grupos funcionales: residencial, comercial e industrial, de manera que se verificará que grupo funcional fue el que consumió mayor o menor energía eléctrica hacia los sectores que abastece la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

8. BIBLIOGRAFÍA

- [1] C. Veliz, «Notas libres sobre la naturaleza del saber histórico», *Anales de la Universidad de Chile*, n.º 124, p. ág. 74-88, ene. 1961, doi: 10.5354/anuc.v0i124.19069.
- [2] J. Colorado Mejía, «Modelo de pronóstico de caudal del río Otún y su impacto en la generación de energía hidráulica», jul. 2020, Accedido: 5 de diciembre de 2021. [En línea]. Disponible en: <https://repository.ean.edu.co/handle/10882/9733>
- [3] Y. García López, «Predicción de la demanda eléctrica empleando redes neuronales artificiales», Thesis, Universidad Central «Marta Abreu» de Las Villas. Facultad de Ingeniería Eléctrica. Departamento de Electroenergética, 2009. Accedido: 5 de diciembre de 2021. [En línea]. Disponible en: <http://dspace.uclv.edu.cu:8089/xmlui/handle/123456789/6906>
- [4] M. A. Aguilar Paredes, «“Incidencia de los proyectos emblemáticos de generación eléctrica ejecutados en el periodo 2007-2016 en la oferta eléctrica del país y su prospectiva al año 2030”», 2018, Accedido: 12 de diciembre de 2021. [En línea]. Disponible en: <http://repositorio.puce.edu.ec:80/xmlui/handle/22000/15074>
- [5] Z. Ti, X. W. Deng, y M. Zhang, «Artificial Neural Networks based wake model for power prediction of wind farm», *Renewable Energy*, vol. 172, pp. 618-631, jul. 2021, doi: 10.1016/j.renene.2021.03.030.
- [6] P. Bunnoon, «Mid-Term Load Forecasting Based on Neural Network Algorithm: a Comparison of Models», *IJCEE*, pp. 600-605, 2011, doi: 10.7763/IJCEE.2011.V3.388.
- [7] A. T. Eseye, M. Lehtonen, T. Tukia, S. Uimonen, y R. John Millar, «Machine Learning Based Integrated Feature Selection Approach for Improved Electricity Demand Forecasting in Decentralized Energy Systems», *IEEE Access*, vol. 7, pp. 91463-91475, 2019, doi: 10.1109/ACCESS.2019.2924685.
- [8] H. Mubarok y M. D. Sapanta, «Electrical Load Forecasting Study Using Artificial Neural Network Method for Minimizing Blackout», en *2018 5th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)*, Semarang, sep. 2018, pp. 256-259. doi: 10.1109/ICITACEE.2018.8576973.

- [9] J. P. Aimacaña Chuquimarca y A. R. Columba Guanoluisa, «Análisis comparativo de algoritmos de Machine Learning para la detección de plagas en los cultivos representativos de la sierra ecuatoriana», 2021, Accedido: 5 de diciembre de 2021. [En línea]. Disponible en: <http://www.dspace.uce.edu.ec/handle/25000/24228>
- [10] I. Challenger-Pérez, Y. Díaz-Ricardo, y R. A. Becerra-García, «El lenguaje de programación Python», *Ciencias Holguín*, vol. XX, n.º 2, pp. 1-13, 2014.
- [11] D. A. Alvarez Chiriboga, «Modelo de predicción de la producción de energía de la Central Hidroeléctrica Coca Codo Sinclair, basado en técnicas de aprendizaje computacional», 2020, Accedido: 5 de diciembre de 2021. [En línea]. Disponible en: <http://repositorio.espe.edu.ec/jspui/handle/21000/23038>
- [12] J. Chen y P.-A. Zhong, «A multi-time-scale power prediction model of hydropower station considering multiple uncertainties», *Science of The Total Environment*, vol. 677, pp. 612-625, ago. 2019, doi: 10.1016/j.scitotenv.2019.04.430.
- [13] F. Zhou *et al.*, «Forecasting the Evolution of Hydropower Generation», en *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Virtual Event CA USA, ago. 2020, pp. 2861-2870. doi: 10.1145/3394486.3403337.
- [14] G. E. Barragán Montalvo y C. E. Parra Almeida, «Optimización de la geometría de un rodete tipo Pelton para flujo particulado utilizando simulación numérica.», ago. 2020, Accedido: 5 de diciembre de 2021. [En línea]. Disponible en: <http://bibdigital.epn.edu.ec/handle/15000/21058>
- [15] F. M. Calero Freire, «Estudio técnico-económico de la implementación del centro de control de las centrales hidroeléctricas Illuchi 1 e Illuchi 2 de ELEPCO S.A.», oct. 2007, Accedido: 5 de diciembre de 2021. [En línea]. Disponible en: <http://bibdigital.epn.edu.ec/handle/15000/524>
- [16] J. C. Calvopiña Valle y S. J. Maite Sánchez, «Adquisición de datos e implementación de una interfaz gráfica para la evaluación del estado de operación de la central Illuchi 2 a través de estándar de perturbación COMTRADE», jun. 2016, Accedido: 5 de diciembre de 2021. [En línea]. Disponible en: <http://bibdigital.epn.edu.ec/handle/15000/17181>
- [17] T. Gönen, *Electric Power Distribution Engineering*, Third Edition. New York: CRC Press, 2014.

- [18]V. Palomeque, I. Valdez, N. Jara, y F. Reinoso, «Diseño de una mini central hidroeléctrica», *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, vol. 30, pp. 30-43, jun. 2020.
- [19]V. M. Palomeque Jimbo y I. A. Valdez Cajamarca, «Diseño de una central hidroeléctrica para abastecer la demanda del consumo eléctrico de Plantaciones Malima Cía. Ltda.», may 2019, Accedido: 12 de diciembre de 2021. [En línea]. Disponible en: <http://dspace.ups.edu.ec/handle/123456789/17404>
- [20]Á. L. O. Fernández y L. H. Coderch, *Centrales Eléctricas I: Introducción Al Sector Eléctrico y Al Sistema de Energía Eléctrica. Centrales Hidroeléctricas. Centrales Térmicas*. UPC, S.L., Edicions, 1996.
- [21]P. K. Nag, *Power Plant Engineering*. Tata McGraw-Hill Education, 2008.
- [22]N. Arriazu Ramos, «Análisis de la producción eléctrica generada en la minicentral hidroeléctrica de Anguiano», 2019, Accedido: 13 de diciembre de 2021. [En línea]. Disponible en: <https://academica-e.unavarra.es/xmlui/handle/2454/33695>
- [23]B. Z. Parra y A. V. Robles, *Máquinas hidráulicas: teoría y problemas*. Universidad Politécnica de Cartagena, 2016. Accedido: 13 de diciembre de 2021. [En línea]. Disponible en: <https://dialnet.unirioja.es/servlet/libro?codigo=660965>
- [24]J. M. Illidge-Araujo, J. L. Chacon-Velasco, A. J. Chacon-Velasco, y C. Romero-Piehadraita, «Diseño y simulación de un sistema pico-hydro para la generación de energía eléctrica en zonas rurales, mediante un software de mecánica de fluidos computacional», *Revista UIS Ingenierías*, vol. 19, n.º 1, Art. n.º 1, ene. 2020, doi: 10.18273/revuin.v19n1-2020015.
- [25]R. S. Gómez-Zurdo, D. G. Martín, B. González-Rodrigo, M. M. Sacristán, y R. M. Marín, «Aplicación de la fotogrametría con drones al control deformacional de estructuras y terreno», *Informes de la Construcción*, vol. 73, n.º 561, Art. n.º 561, abr. 2021, doi: 10.3989/ic.77867.
- [26]A. S. Woodget, R. Austrums, I. P. Maddock, y E. Habit, «Drones and digital photogrammetry: from classifications to continuums for monitoring river habitat and hydromorphology», *WIREs Water*, vol. 4, n.º 4, jul. 2017, doi: 10.1002/wat2.1222.

- [27]A. C. Peña, A. E. S. Ávila, R. M. Zúñiga, G. E. C. Posada, y J. E. M. Castro, «Implementación de las técnicas de predicción en la generación de energía eléctrica en el sector industrial», *Revista de Investigación en Tecnologías de la Información: RITI*, vol. 8, n.º 15, pp. 16-26, 2020.
- [28]A. F. Manobanda Vega, «Predicción de la demanda de energía eléctrica en la producción de petróleo de los campos de Petroamazonas Ep utilizando redes neuronales artificiales», jun. 2020, Accedido: 6 de diciembre de 2021. [En línea]. Disponible en: <http://bibdigital.epn.edu.ec/handle/15000/20936>
- [29]A. M. Ariza Ramírez, «Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución», 2013, Accedido: 6 de diciembre de 2021. [En línea]. Disponible en: <http://repositorio.utp.edu.co/dspace/handle/11059/3862>
- [30]D. Julian y B. Baka, *Python Data Structures and Algorithm*. Birmingham: Packt Publishing, Limited, 2017. Accedido: 14 de diciembre de 2021. [En línea]. Disponible en: <https://proquest.safaribooksonline.com/9781786467355>
- [31]M. C. Soberanis, «Inspiración biológica de las redes neuronales artificiales», *SoldAI*, 15 de mayo de 2020. <https://medium.com/soldai/inspiraci%C3%B3n-biol%C3%B3gica-de-las-redes-neuronales-artificiales-9af7d7b906a> (accedido 6 de diciembre de 2021).
- [32]P. Isasi y I. Galván, *Redes neuronales artificiales un enfoque práctico*. Madrid: Pearson Educación S.A., 2004.
- [33]L. G. Rodríguez y A. P. Salgueiro, «Comparación de frameworks de aprendizaje profundo», p. 11.
- [34]G. E. Asqui Santillán, «Predicción del nivel de agua del embalse, basado en redes neuronales, para la mejora de la planificación de producción de energía en la Central Hidroeléctrica Agoyán.», mar. 2017, Accedido: 6 de diciembre de 2021. [En línea]. Disponible en: <http://dspace.esPOCH.edu.ec/handle/123456789/6159>
- [35]E. X. Chafla Yambay, «Análisis del rendimiento de algoritmos de entrenamiento de redes neuronales artificiales, aplicadas al modelamiento dinámico de represas hidroeléctricas, mediante el error de predicción del nivel de embalse de agua.», feb. 2019, Accedido: 6 de diciembre de 2021. [En línea]. Disponible en: <http://dspace.esPOCH.edu.ec/handle/123456789/9697>

- [36]M. Cabezón, «Predicción demanda eléctrica española. Implementación de redes neuronales recurrentes en Python», info:eu-repo/semantics/masterThesis, 2018. Accedido: 25 de enero de 2022. [En línea]. Disponible en: <https://eprints.ucm.es/id/eprint/49444/>
- [37]A. Géron, *Hands-on Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, 2017.
- [38]J. R. Hilera González y V. J. Martínez Hernando, *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Madrid: RA-MA Editorial, 1995.
- [39]D. Murti Baer, «Modelo de predicción a corto plazo de la generación eléctrica en parques eólicos, utilizando técnicas de Machine-Learning», nov. 2020, Accedido: 14 de diciembre de 2021. [En línea]. Disponible en: <http://dspace.uib.es/xmlui/handle/11201/154431>
- [40]D. Quesada y J. María, «Aprendizaje supervisado para la detección de amenazas web mediante clasificación basada en árboles de decisión: Aplicación de técnicas de machine learning a la ciberseguridad», p. 61, jun. 2020.
- [41]J. M. Alvarado Carrera, «Clasificación de sílabos académicos en base a redes neuronales de aprendizaje profundo», Universidad del Azuay, 2018. Accedido: 18 de enero de 2022. [En línea]. Disponible en: <http://dspace.uazuay.edu.ec/handle/datos/8568>
- [42]A. E. Repetur, «Redes neuronales artificiales», p. 89, ago. 2019.
- [43]J. C. Colás Herrera, «Aplicación de modelos de redes neuronales a la predicción de la fiebre», febrero de 2019. <https://oa.upm.es/54125/> (accedido 6 de diciembre de 2021).
- [44]J. Heizer, B. Render, y J. E. Murrieta Murrieta, *Principios de Administración de Operaciones*. México: Pearson Educación de México, S. A. de C. V., 2009.
- [45]L. D. Quisimalín Villacís, «Predicción de la Demanda Eléctrica en Barra de 69 kV del Sistema Eléctrico de Subtransmisión de la Empresa Eléctrica Riobamba S.A.», may 2017, Accedido: 15 de diciembre de 2021. [En línea]. Disponible en: <http://bibdigital.epn.edu.ec/handle/15000/17367>
- [46]J. J. Martín Miralles, «Librería de Python para el trazamiento y la animación de trayectorias de GPS almacenadas en ficheros con formato GPX», mar. 2020, Accedido: 16 de diciembre de 2021. [En línea]. Disponible en: <http://dspace.uib.es/xmlui/handle/11201/151783>

- [47]S. J. García y I. María, «Diseño e implementación de un módulo Python para representar datos geográficos en Dataframes», jun. 2019, Accedido: 16 de diciembre de 2021. [En línea]. Disponible en: <https://e-archivo.uc3m.es/handle/10016/31974>
- [48]O. Caja García, «Librería Python para el aprendizaje y la implementación de redes neuronales», Proyecto/Trabajo fin de carrera/grado, Universitat Politècnica de València, 2020. Accedido: 16 de diciembre de 2021. [En línea]. Disponible en: <https://riunet.upv.es/handle/10251/152226>
- [49]«Conceptos básicos sobre redes neuronales», *Vicente Rodríguez blog*. <https://vincentblog.xyz/posts/conceptos-basicos-sobre-redes-neuronales> (accedido 29 de enero de 2022).
- [50]«scikit-learn - 6.3. Preprocesamiento de datos - El paquete sklearn.preprocessing proporciona varias funciones de utilidad comune - Español». https://runebook.dev/es/docs/scikit_learn/modules/preprocessing (accedido 31 de enero de 2022).
- [51]G. Cabrera, «Criterios de aceptación - ¿Qué son?», *Somos PNT - Desarrollamos Software*. <https://sospnt.com/blog/171-criterios-de-aceptacion-que-son> (accedido 25 de febrero de 2022).
- [52]ekuatio, «Error absoluto y error relativo: Qué son y cómo se calculan», *Clases de Matemáticas Online*, 25 de octubre de 2018. <https://ekuatio.com/error-absolutos-y-error-relativos-que-son-y-como-se-calculan/> (accedido 25 de febrero de 2022).

ANEXOS

INDICE DE ANEXOS

ANEXO A. Glosario

ANEXO B. Información depurada de la base de datos desde el año 2 015 hasta el año 2 019

ANEXO C. Estructura implementada en Python para la predicción de la demanda eléctrica

ANEXO D. Datos pronosticados para el año 2 020 y 2 021

ANEXO E. Manual de usuario

ANEXO A. Glosario

DBN:	Redes bayesianas dinámicas
KW-H:	Kilowatt-hora
MDE:	Modelos digitales de elevación
SFM:	Source Filmmaker
IA:	Inteligencia Artificial
DL:	Deep learning
FEEDFORWARD:	Propagación hacia adelante
FEEDBACK:	Propagación hacia atrás
SGD:	Descenso de Gradiente Estocástico
RMSPROP:	Root Mean Square Propagation
ADAGRAD:	Adaptive Gradient Algorithm
ADAM:	Adaptive Moment Estimation
OVERFITTING:	Sobre entrenamiento
UNDERFITTING:	Bajo entrenamiento
NORMAL FITTING:	Normal entrenamiento
RNA:	Red neuronal artificial
LSTM:	Long short-term memory
MAE:	Error medio absoluto
MAPE:	Error porcentual medio absoluto

ANEXO B. Información depurada de la base de datos desde el año 2 015 hasta el año 2 019**Figura B.1.** Datos depurados desde el año 2 015 hasta el año 2 019

AÑO	MES	DIA	FECHA	HORA	KW-H
2015	1	jueves	1	0:00:00	3200
2015	1	jueves	1	1:00:00	3200
2015	1	jueves	1	2:00:00	2400
2015	1	jueves	1	3:00:00	2400
2015	1	jueves	1	4:00:00	2400
2015	1	jueves	1	5:00:00	2400
2015	1	jueves	1	6:00:00	2400
2015	1	jueves	1	7:00:00	2400
2015	1	jueves	1	8:00:00	2400
2015	1	jueves	1	9:00:00	2600
2015	1	jueves	1	10:00:00	2600
2015	1	jueves	1	11:00:00	2600
2015	1	jueves	1	12:00:00	2600
2015	1	jueves	1	13:00:00	2600
2015	1	jueves	1	14:00:00	2600
2015	1	jueves	1	15:00:00	2600
2015	1	jueves	1	16:00:00	2600
2015	1	jueves	1	17:00:00	2300
2015	1	jueves	1	18:00:00	2300
2015	1	jueves	1	19:00:00	2300
2015	1	jueves	1	20:00:00	2300
2015	1	jueves	1	21:00:00	2400
2015	1	jueves	1	22:00:00	2400
2015	1	jueves	1	23:00:00	2400
2015	1	viernes	2	0:00:00	2400
2015	1	viernes	2	1:00:00	2400
2015	1	viernes	2	2:00:00	2400
2015	1	viernes	2	3:00:00	2400
2015	1	viernes	2	4:00:00	2200
2015	1	viernes	2	5:00:00	2200
2015	1	viernes	2	6:00:00	2200
2015	1	viernes	2	7:00:00	2200
2015	1	viernes	2	8:00:00	2200
2015	1	viernes	2	9:00:00	2200
2015	1	viernes	2	10:00:00	2200

Figura B.2. Datos depurados desde el año 2 015 hasta el año 2 019

AÑO	MES	DIA	FECHA	HORA	KW-H
2019	12	Lunes	30	13:00:00	1900
2019	12	Lunes	30	14:00:00	2000
2019	12	Lunes	30	15:00:00	2100
2019	12	lunes	30	16:00:00	2200
2019	12	lunes	30	17:00:00	2100
2019	12	lunes	30	18:00:00	2000
2019	12	lunes	30	19:00:00	2500
2019	12	lunes	30	20:00:00	2500
2019	12	lunes	30	21:00:00	2500
2019	12	lunes	30	22:00:00	2500
2019	12	lunes	30	23:00:00	2400
2019	12	martes	31	0:00:00	2400
2019	12	martes	31	1:00:00	2400
2019	12	martes	31	2:00:00	2600
2019	12	martes	31	3:00:00	2600
2019	12	martes	31	4:00:00	2800
2019	12	martes	31	5:00:00	2700
2019	12	martes	31	6:00:00	2600
2019	12	martes	31	7:00:00	3000
2019	12	martes	31	8:00:00	3100
2019	12	martes	31	9:00:00	3600
2019	12	martes	31	10:00:00	4000
2019	12	martes	31	11:00:00	4100
2019	12	martes	31	12:00:00	4100
2019	12	martes	31	13:00:00	4100
2019	12	martes	31	14:00:00	3900
2019	12	martes	31	15:00:00	3900
2019	12	martes	31	16:00:00	3600
2019	12	martes	31	17:00:00	3400
2019	12	martes	31	18:00:00	3400
2019	12	martes	31	19:00:00	3400
2019	12	martes	31	20:00:00	3600
2019	12	martes	31	21:00:00	3800
2019	12	martes	31	22:00:00	4000
2019	12	martes	31	23:00:00	4000

ANEXO C. Estructura implementada en Python para la predicción de la demanda eléctrica

Figura C.1. Algoritmo desarrollado

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import LabelEncoder
from sklearn.model_selection import train_test_split
import keras
from keras.models import Sequential
from keras.layers import Dense, Activation, Dropout
from sklearn.metrics import mean_squared_error
```

```
#Lectura de datos
data = pd.read_csv('DEPURACION_FINAL.csv', sep=',')
data
```

	AÑO	MES	DIA	FECHA	HORA	KW-H
0	2015	1	jueves	1	0	3200
1	2015	1	jueves	1	1	3200
2	2015	1	jueves	1	2	2400
3	2015	1	jueves	1	3	2400
4	2015	1	jueves	1	4	2400
...
43819	2019	12	martes	31	19	3400
43820	2019	12	martes	31	20	3600
43821	2019	12	martes	31	21	3800
43822	2019	12	martes	31	22	4000
43823	2019	12	martes	31	23	4000

43824 rows x 6 columns

```
#Verificacion de nans
data.isnull().values.any()
data.isnull().sum().sum()

data.isnull().sum()
```

```
AÑO      0
MES      0
DIA      0
FECHA    0
HORA     0
KW-H     0
dtype: int64
```

```
#Variable categorica DIA a numérica
#TODO Borrar al final de cuentas no se usa este dato
data['DIA'] = data['DIA'].map({'lunes': 1,
                              'martes': 2,
                              'miercoles': 3,
                              'miércoles': 3,
                              'jueves': 4,
                              'viernes': 5,
                              'sábado': 6,
                              'sabado': 6, #inconsistencia en la data por las tildes
                              'domingo': 7})
```

```
data.tail(50)
# data.to_csv('data_total.csv')
```

	AÑO	MES	DIA	FECHA	HORA	KW-H
43774	2019	12	7	29	22	3200
43775	2019	12	7	29	23	2800
43776	2019	12	1	30	0	2400
43777	2019	12	1	30	1	2400
43778	2019	12	1	30	2	2000
43779	2019	12	1	30	3	2000
43780	2019	12	1	30	4	2000
43781	2019	12	1	30	5	2000
43782	2019	12	1	30	6	2000
43783	2019	12	1	30	7	1800
43784	2019	12	1	30	8	1800
43785	2019	12	1	30	9	1800
43786	2019	12	1	30	10	1900
43787	2019	12	1	30	11	1900
43788	2019	12	1	30	12	1900
43789	2019	12	1	30	13	1900
43790	2019	12	1	30	14	2000
43791	2019	12	1	30	15	2100
43792	2019	12	1	30	16	2200
43793	2019	12	1	30	17	2100
43794	2019	12	1	30	18	2000
43795	2019	12	1	30	19	2500

```
#Llevamos la hora y la fecha para los indices porque lo que nos interesa es KW-H
from datetime import datetime
data_final = pd.DataFrame()
fechas_dt = []
kwh_dt = []
for registro in data.values:
    fecha = "{}-{}-{} {}".format(registro[0], registro[1], registro[3], registro[4])
    fecha_dt = datetime.strptime(fecha, '%Y-%m-%d %H')
    fechas_dt.append(fecha_dt)
    kwh_dt.append(registro[5])
#Creamos un nuevo dataframe con el formato de fecha correcto y el valor de KW-H
data_final['FECHA'] = fechas_dt
data_final['KW-H'] = kwh_dt
data_final
```

	FECHA	KW-H
0	2015-01-01 00:00:00	3200
1	2015-01-01 01:00:00	3200
2	2015-01-01 02:00:00	2400
3	2015-01-01 03:00:00	2400
4	2015-01-01 04:00:00	2400
...
43819	2019-12-31 19:00:00	3400
43820	2019-12-31 20:00:00	3600
43821	2019-12-31 21:00:00	3800
43822	2019-12-31 22:00:00	4000
43823	2019-12-31 23:00:00	4000

43824 rows x 2 columns

```
# data_final.to_csv('data_total_datetime.csv')
```

```
#Llevamos la FECHA al índice de nuestro df, ahora solo tenemos una columna de datos
data_final.set_index('FECHA', drop=True, inplace = True)
data_final
```

KW-H	
FECHA	
2015-01-01 00:00:00	3200
2015-01-01 01:00:00	3200
2015-01-01 02:00:00	2400
2015-01-01 03:00:00	2400
2015-01-01 04:00:00	2400
...	...
2019-12-31 19:00:00	3400
2019-12-31 20:00:00	3600
2019-12-31 21:00:00	3800
2019-12-31 22:00:00	4000
2019-12-31 23:00:00	4000

43824 rows × 1 columns

```
#Dividir los datos de entrenamiento y de test
# No se puede utilizar train test split, debemos dividir en el último segmento
#Tomamos los datos para validación el 18%, pero del final de los datos (todo 2019 menos enero)
size = int(0.18292*data_final.shape[0])
data_test = data_final[-size:]
data_train = data_final[:-size]
data_train
```

KW-H	
FECHA	
2015-01-01 00:00:00	3200
2015-01-01 01:00:00	3200
2015-01-01 02:00:00	2400
2015-01-01 03:00:00	2400
2015-01-01 04:00:00	2400
...	...
2019-01-31 19:00:00	3300
2019-01-31 20:00:00	3300
2019-01-31 21:00:00	3400
2019-01-31 22:00:00	3600
2019-01-31 23:00:00	2600

35808 rows × 1 columns

```
#Transformacion de datos a numerica
```

```
data_train['KW-H'] = [valor.replace(",",".") for valor in data_train['KW-H'] ]
data_train['KW-H'] = [float(valor) for valor in data_train['KW-H'] ]
```

```
data_test['KW-H'] = [valor.replace(",",".") for valor in data_test['KW-H'] ]
data_test['KW-H'] = [float(valor) for valor in data_test['KW-H'] ]
```

```
data_train
```

```
/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:3: SettingWithCopyWarning:
A value is trying to be set on a copy of a slice from a DataFrame.
Try using .loc[row_indexer,col_indexer] = value instead
```

See the caveats in the documentation: https://pandas.pydata.org/pandas-docs/stable/user_guide/indexing.html#returning-a-view-versus-a-copy
This is separate from the ipykernel package so we can avoid doing imports until

```
/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:4: SettingWithCopyWarning:
A value is trying to be set on a copy of a slice from a DataFrame.
Try using .loc[row_indexer,col_indexer] = value instead
```

See the caveats in the documentation: https://pandas.pydata.org/pandas-docs/stable/user_guide/indexing.html#returning-a-view-versus-a-copy
after removing the cwd from sys.path.

```
/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:6: SettingWithCopyWarning:
A value is trying to be set on a copy of a slice from a DataFrame.
Try using .loc[row_indexer,col_indexer] = value instead
```

See the caveats in the documentation: https://pandas.pydata.org/pandas-docs/stable/user_guide/indexing.html#returning-a-view-versus-a-copy

```
/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:7: SettingWithCopyWarning:
A value is trying to be set on a copy of a slice from a DataFrame.
Try using .loc[row_indexer,col_indexer] = value instead
```

See the caveats in the documentation: https://pandas.pydata.org/pandas-docs/stable/user_guide/indexing.html#returning-a-view-versus-a-copy
import sys

```
.....
```

	KW-H
FECHA	
2015-01-01 00:00:00	3200.0
2015-01-01 01:00:00	3200.0
2015-01-01 02:00:00	2400.0
2015-01-01 03:00:00	2400.0
2015-01-01 04:00:00	2400.0
...	...
2019-01-31 19:00:00	3300.0
2019-01-31 20:00:00	3300.0
2019-01-31 21:00:00	3400.0
2019-01-31 22:00:00	3600.0
2019-01-31 23:00:00	2600.0

35808 rows × 1 columns

```
#Normalizacion de Los datos
#Para LSTM es obligatoria la normalización, en este caso lo hacemos de 0 a 1
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0,1))
data_train_scaled = sc.fit_transform(data_train)
print(data_train_scaled.shape)
data_train_scaled
```

```
(35808, 1)
array([[0.66666667],
       [0.66666667],
       [0.5       ],
       ...,
       [0.70833333],
       [0.75       ],
       [0.54166667]])
```

```

#Tenemos que entrenar la red por bloques de datos
#Time_step es el tamaño del bloque
#Cada n datos genera una salida
#Tomamos bloques de 60 datos consecutivos
time_step = 60
X_train = [] #Lista de conjuntos de 60 datos
Y_train = []
m = len(data_train_scaled)
for i in range(time_step, m):
    X_train.append(data_train_scaled[i-time_step:i, 0]) #Guardamos 60 valores
    Y_train.append(data_train_scaled[i, 0]) #Buscamos predecir el dato time_step + 1, no la var KW
X_train, Y_train = np.array(X_train), np.array(Y_train) #Usamos np por reshape y optimizacion

```

```
X_train.shape, Y_train.shape
```

```
((35748, 60), (35748,))
```

```

# pd.DataFrame(X_train).to_csv('x_train.csv')
# pd.DataFrame(Y_train).to_csv('y_train.csv')

```

```

#Obligatorio el reshape de los datos, es obligatorio por Keras, nos pide ingresar un array de 3 dim
#Levamos de dos a 3 dimensiones nuestro arreglo
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1)) #Agregamos una nueva dimension
X_train.shape, Y_train.shape

```

```
((35748, 60, 1), (35748,))
```

```

#MODELO
from keras.layers import LSTM
from sklearn.metrics import mean_squared_error

```

```

def NN_LSTM(optimizador, neuronas, epocas):
    dim_entrada = (X_train.shape[1], X_train.shape[2])
    dim_salida = 1
    num_neuronas = neuronas

    modelo = Sequential()

    modelo.add(LSTM(units=num_neuronas, return_sequences = True, input_shape=dim_entrada))
    modelo.add(Dropout(0.4))
    modelo.add(LSTM(units=num_neuronas))
    modelo.add(Dropout(0.2))
    modelo.add(Dense(units = dim_salida))
    # modelo.add(activation = 'Linear')
    modelo.compile(optimizer= optimizador, loss='mse', metrics = ['mean_absolute_error']) #mean_squared_error

```

```

#Entrenamiento
history = modelo.fit(X_train, Y_train, epochs = epocas, batch_size = 128)
return modelo, history

```

```

def predDataTest(modelo):
    x_test = data_test.values
    x_test = sc.transform(x_test)
    ## x_test
    X_test = []
    for i in range(time_step, len(x_test)):
        X_test.append(x_test[i-time_step: i, 0])
    X_test = np.array(X_test)
    X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
    X_test.shape
    prediccion = modelo.predict(X_test)
    prediccion = sc.inverse_transform(prediccion)
    return prediccion

```

```

#rmsprop LOS MEJORES RESULTADOS
modelo, history = NN_LSTM(optimizador = 'rmsprop', neuronas = 10, epocas = 10)
#Guardamos el modelo para no tener que entrenar otra vez para probar
modelo.save('modelos/model.h5')

```

```

Epoch 1/10
280/280 [=====] - 18s 50ms/step - loss: 0.0375 - mean_absolute_error: 0.1386
Epoch 2/10
280/280 [=====] - 22s 80ms/step - loss: 0.0137 - mean_absolute_error: 0.0862
Epoch 3/10
280/280 [=====] - 14s 50ms/step - loss: 0.0101 - mean_absolute_error: 0.0727
Epoch 4/10
280/280 [=====] - 14s 50ms/step - loss: 0.0080 - mean_absolute_error: 0.0640
Epoch 5/10
280/280 [=====] - 19s 67ms/step - loss: 0.0069 - mean_absolute_error: 0.0584
Epoch 6/10
280/280 [=====] - 14s 49ms/step - loss: 0.0062 - mean_absolute_error: 0.0545
Epoch 7/10
280/280 [=====] - 14s 49ms/step - loss: 0.0057 - mean_absolute_error: 0.0521
Epoch 8/10
280/280 [=====] - 14s 49ms/step - loss: 0.0055 - mean_absolute_error: 0.0507
Epoch 9/10
280/280 [=====] - 14s 52ms/step - loss: 0.0052 - mean_absolute_error: 0.0496
Epoch 10/10
280/280 [=====] - 14s 50ms/step - loss: 0.0051 - mean_absolute_error: 0.0485

```

```
#Ver la arquitectura del modelo
print(model.summary())
print('El valor de la pérdida obtenido es: {}'.format(history.history['loss'][-1]))
print('El valor del error medio absoluto es: {}'.format(history.history['mean_absolute_error'][-1]))
```

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 60, 10)	480
dropout (Dropout)	(None, 60, 10)	0
lstm_1 (LSTM)	(None, 10)	840
dropout_1 (Dropout)	(None, 10)	0
dense (Dense)	(None, 1)	11

=====
 Total params: 1,331
 Trainable params: 1,331
 Non-trainable params: 0

None
 El valor de la pérdida obtenido es: 0.005072229541838169
 El valor del error medio absoluto es: 0.048485200852155685

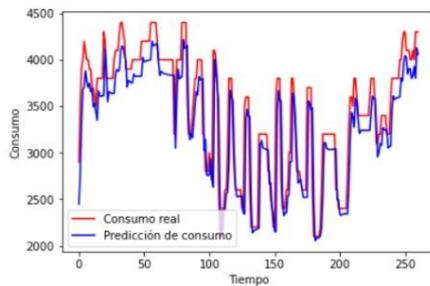
```
model = keras.models.load_model('modelos/model.h5')
prediccion = predDataTest(model) ##Arreglar porque salta error al correr de nuevo
```

```
x_test = data_test.values
x_test = sc.transform(x_test)
## x_test
X_test = []
for i in range(time_step, len(x_test)):
    X_test.append(x_test[i-time_step: i, 0])
X_test = np.array(X_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
X_test.shape
prediccion = model.predict(X_test)
prediccion = sc.inverse_transform(prediccion)
```

```
len(prediccion)
```

7956

```
#Grafica de valores
# Y_test #Aun no defnido
plt.plot(data_test.values[60:321], color='red', label='Consumo real')
plt.plot(prediccion[:261], color='blue', label='Predicción de consumo')
plt.xlabel('Tiempo')
plt.ylabel('Consumo')
plt.legend()
plt.show()
```



```
#Union de datos
#LSTM nos predice el dato time_step + 1 por tanto debemos unir a partir del dato 61 de nuestro data_test
data_test_slic = data_test[60:].copy()
data_test_pred = pd.concat([data_test_slic,
                             pd.DataFrame(prediccion,
                                           columns=['KW-H_PRED'],
                                           index = data_test_slic.index)],
                             axis =1)
# print(data_test_slic.shape)
# print(prediccion.shape)
# print(data_test_slic)
# print(prediccion)
data_test_pred.head(20)
```

	KW-H	KW-H_PRED
2019-02-03 12:00:00	2900.0	2447.286377
2019-02-03 13:00:00	3500.0	2769.744385
2019-02-03 14:00:00	3900.0	3327.097900
2019-02-03 15:00:00	4000.0	3675.702637
2019-02-03 16:00:00	4200.0	3706.161865
2019-02-03 17:00:00	4100.0	3882.923096
2019-02-03 18:00:00	4000.0	3773.962891
2019-02-03 19:00:00	4000.0	3704.181885
2019-02-03 20:00:00	3900.0	3746.572754
2019-02-03 21:00:00	3900.0	3657.266113
2019-02-03 22:00:00	3700.0	3683.607666
2019-02-03 23:00:00	3700.0	3495.078369
2019-02-04 00:00:00	3600.0	3531.615723
2019-02-04 01:00:00	3500.0	3436.601807
2019-02-04 02:00:00	3800.0	3347.583740

```
# Figura 5.8: Curva de La demanda eléctrica pronosticada
#Los primeros 7 dias(completos) de La prediccion (4 de febrero)
semana_estudio_test_pred = data_test_pred[
    data_test_pred.index.get_loc('2019-02-04 00:00:00'):
    data_test_pred.index.get_loc('2019-02-11 00:00:00')]

semana_estudio_test = semana_estudio_test_pred['KW-H']
semana_estudio_pred = semana_estudio_test_pred['KW-H_PRED']
# semana_estudio_pred
plt.figure(figsize=(10,6))
plt.plot(semana_estudio_pred,
         color='blue',
         label='Datos Pronosticados')
plt.suptitle('CURVA DE LA DEMANDA PRONOSTICADA',
             fontsize = 18,
             fontweight = 'bold',
             fontfamily='serif')
plt.legend()
plt.show()
```

CURVA DE LA DEMANDA PRONOSTICADA

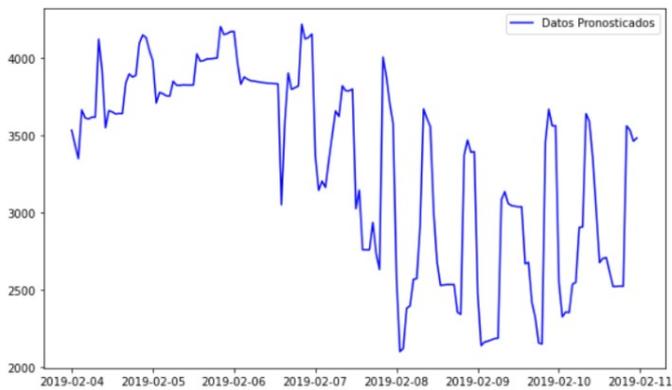


Figura C.2. Compilación de los diferentes optimizadores**ADAM**

```

model_adam, history_adam = NN_LSTM(optimizador = 'adam', neuronas = 10, epocas = 10)
model_adam.save('modelos/model_adam.h5')

Epoch 1/10
35748/35748 [=====] - 260s 7ms/step - loss: 0.0199 - mean_absolute_error: 0.0929
Epoch 2/10
35748/35748 [=====] - 108s 3ms/step - loss: 0.0082 - mean_absolute_error: 0.0622
Epoch 3/10
35748/35748 [=====] - 147s 4ms/step - loss: 0.0065 - mean_absolute_error: 0.0537
Epoch 4/10
35748/35748 [=====] - 165s 5ms/step - loss: 0.0052 - mean_absolute_error: 0.0469
Epoch 5/10
35748/35748 [=====] - 111s 3ms/step - loss: 0.0043 - mean_absolute_error: 0.0416
Epoch 6/10
35748/35748 [=====] - 161s 5ms/step - loss: 0.0039 - mean_absolute_error: 0.0390
Epoch 7/10
35748/35748 [=====] - 176s 5ms/step - loss: 0.0036 - mean_absolute_error: 0.0377
Epoch 8/10
35748/35748 [=====] - 172s 5ms/step - loss: 0.0035 - mean_absolute_error: 0.0369
Epoch 9/10
35748/35748 [=====] - 145s 4ms/step - loss: 0.0035 - mean_absolute_error: 0.0366
Epoch 10/10
35748/35748 [=====] - 161s 5ms/step - loss: 0.0034 - mean_absolute_error: 0.0359

prediccion_adam = predDataTest(model_adam)

```

ADADELTA

```

model_adadelta, history_adadelta = NN_LSTM(optimizador = 'adadelta', neuronas = 10, epocas = 10)
model_adadelta.save('modelos/model_adadelta.h5')

Epoch 1/10
35748/35748 [=====] - 150s 4ms/step - loss: 0.0214 - mean_absolute_error: 0.0948
Epoch 2/10
35748/35748 [=====] - 122s 3ms/step - loss: 0.0082 - mean_absolute_error: 0.0624
Epoch 3/10
35748/35748 [=====] - 136s 4ms/step - loss: 0.0066 - mean_absolute_error: 0.0548
Epoch 4/10
35748/35748 [=====] - 161s 5ms/step - loss: 0.0055 - mean_absolute_error: 0.0491
Epoch 5/10
35748/35748 [=====] - 142s 4ms/step - loss: 0.0048 - mean_absolute_error: 0.0452
Epoch 6/10
35748/35748 [=====] - 159s 4ms/step - loss: 0.0044 - mean_absolute_error: 0.0427
Epoch 7/10
35748/35748 [=====] - 121s 3ms/step - loss: 0.0040 - mean_absolute_error: 0.0405
Epoch 8/10
35748/35748 [=====] - 156s 4ms/step - loss: 0.0038 - mean_absolute_error: 0.0389
Epoch 9/10
35748/35748 [=====] - 153s 4ms/step - loss: 0.0036 - mean_absolute_error: 0.0378
Epoch 10/10
35748/35748 [=====] - 153s 4ms/step - loss: 0.0035 - mean_absolute_error: 0.0370

prediccion_adadelta = predDataTest(model_adadelta)

```

RMSPROP

```

model_rmsprop, history_rmsprop = NN_LSTM(optimizador = 'rmsprop', neuronas = 10, epocas = 10)
model_rmsprop.save('modelos/model_rmsprop.h5')

Epoch 1/10
35748/35748 [=====] - 110s 3ms/step - loss: 0.0099 - mean_absolute_error: 0.0689
Epoch 2/10
35748/35748 [=====] - 162s 5ms/step - loss: 0.0061 - mean_absolute_error: 0.0528
Epoch 3/10
35748/35748 [=====] - 153s 4ms/step - loss: 0.0044 - mean_absolute_error: 0.0437
Epoch 4/10
35748/35748 [=====] - 159s 4ms/step - loss: 0.0039 - mean_absolute_error: 0.0404
Epoch 5/10
35748/35748 [=====] - 139s 4ms/step - loss: 0.0036 - mean_absolute_error: 0.0384
Epoch 6/10
35748/35748 [=====] - 137s 4ms/step - loss: 0.0034 - mean_absolute_error: 0.0371
Epoch 7/10
35748/35748 [=====] - 160s 4ms/step - loss: 0.0034 - mean_absolute_error: 0.0363
Epoch 8/10
35748/35748 [=====] - 129s 4ms/step - loss: 0.0033 - mean_absolute_error: 0.0353
Epoch 9/10
35748/35748 [=====] - 126s 4ms/step - loss: 0.0032 - mean_absolute_error: 0.0349
Epoch 10/10
35748/35748 [=====] - 147s 4ms/step - loss: 0.0032 - mean_absolute_error: 0.0348

prediccion_rmsprop = predDataTest(model_rmsprop)

```

Figura C.3. Datos pronosticados aplicando la interfaz gráfica implementada

UNIVERSIDAD TÉCNICA DE COTOPAXI
INGENIERÍA ELÉCTRICA

Autores:
-Bastidas Cashicana Wilson Roberto
-Moya Cabezas Angelo Mauricio

Datos Históricos Entrenamiento Red Neuronal **Predicción de la demanda** Salir

Desde **Hasta**

Año 2019 Año 2019
Mes 4 Mes 4
Día 3 Día 6
Hora 1 Hora 2

Demanda Específica

Año 2019 **Calcular**
Mes 4 2834.6257
Día 4
Hora 1

Prededir demanda

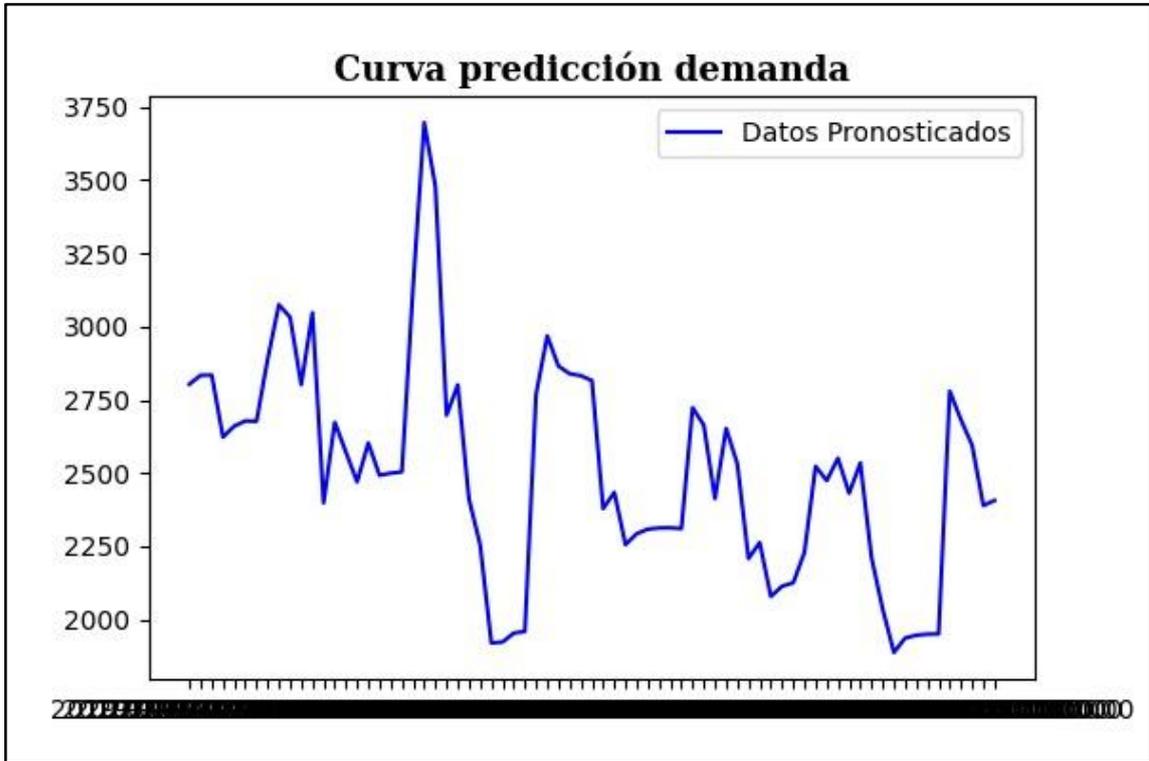
Grafica Tabla

Fecha	Demanda(KW-H)
2019-04-03 01:00:00	2803.36279296875
2019-04-03 02:00:00	2833.701904296875
2019-04-03 03:00:00	2834.625732421875
2019-04-03 04:00:00	2622.857666015625
2019-04-03 05:00:00	2660.114990234375
2019-04-03 06:00:00	2678.130859375
2019-04-03 07:00:00	2676.900634765625
2019-04-03 08:00:00	2888.81494140625
2019-04-03 09:00:00	3074.72314453125
2019-04-03 10:00:00	3032.123046875
2019-04-03 11:00:00	2802.10693359375
2019-04-03 12:00:00	3047.039794921875
2019-04-03 13:00:00	2398.87158203125
2019-04-03 14:00:00	2673.464599609375
2019-04-03 15:00:00	2571.17626953125
2019-04-03 16:00:00	2470.2744140625
2019-04-03 17:00:00	2603.156005859375
2019-04-03 18:00:00	2492.70068359375

Figura C.4. Datos numéricos pronosticados

FECHA	PREDICCIÓN
03/04/2019 1:00	2803,3628
03/04/2019 2:00	2833,7020
03/04/2019 3:00	2834,6257
03/04/2019 4:00	2622,8577
03/04/2019 5:00	2660,1150
03/04/2019 6:00	2678,1309
03/04/2019 7:00	2676,9006
03/04/2019 8:00	2888,8150
03/04/2019 9:00	3074,7231
03/04/2019 10:00	3032,1230
03/04/2019 11:00	2802,1070
03/04/2019 12:00	3047,0398
03/04/2019 13:00	2398,8716
03/04/2019 14:00	2673,4646
03/04/2019 15:00	2571,1763
03/04/2019 16:00	2470,2744
03/04/2019 17:00	2603,1560
03/04/2019 18:00	2492,7007
03/04/2019 19:00	2499,9128
03/04/2019 20:00	2504,1326
03/04/2019 21:00	3135,3830
03/04/2019 22:00	3696,1033
03/04/2019 23:00	3477,8066
04/04/2019 0:00	2697,3965
04/04/2019 1:00	2801,4924
04/04/2019 2:00	2411,7434
04/04/2019 3:00	2255,8313
04/04/2019 4:00	1920,9194
04/04/2019 5:00	1923,7250
04/04/2019 6:00	1954,0057
04/04/2019 7:00	1960,2737
04/04/2019 8:00	2768,2158
04/04/2019 9:00	2968,3657
04/04/2019 10:00	2865,4873
04/04/2019 11:00	2839,0955
04/04/2019 12:00	2832,5470
04/04/2019 13:00	2815,5227

Figura C.5. Curva de la demanda pronosticados



ANEXO D. Datos pronosticados para el año 2 020 y 2 021

Tabla D.1. Datos pronosticados desde Enero para el año 2 020

PREDICCIÓN AÑO 2020	
FECHA	PREDICCIÓN
01/01/2020 0:00	2789,71167
01/01/2020 1:00	2634,18213
01/01/2020 2:00	2631,58203
01/01/2020 3:00	2623,24658
01/01/2020 4:00	2618,39307
01/01/2020 5:00	2619,62622
01/01/2020 6:00	2432,49805
01/01/2020 7:00	2431,80444
01/01/2020 8:00	3540,2959
01/01/2020 9:00	3583,62769
01/01/2020 10:00	3508,37793
01/01/2020 11:00	3540,87842
01/01/2020 12:00	2561,91138
01/01/2020 13:00	2232,98682
01/01/2020 14:00	2268,01074
01/01/2020 15:00	2259,1897
01/01/2020 16:00	2248,04102
01/01/2020 17:00	2248,98096
01/01/2020 18:00	2251,42334
01/01/2020 19:00	3232,38867
01/01/2020 20:00	3212,32715
01/01/2020 21:00	3149,13623
01/01/2020 22:00	3167,13965
01/01/2020 23:00	3168,50293
02/01/2020 0:00	3158,95679
02/01/2020 1:00	3153,73706
02/01/2020 2:00	2754,29761
02/01/2020 3:00	2777,57398
02/01/2020 4:00	2506,28589
02/01/2020 5:00	2410,63989
02/01/2020 6:00	2238,31055
02/01/2020 7:00	2238,40674
02/01/2020 8:00	3643,39941
02/01/2020 9:00	3783,65625
02/01/2020 10:00	3680,3794

PREDICCIÓN AÑO 2020	
FECHA	PREDICCIÓN
02/01/2020 11:00	3722,92651
02/01/2020 12:00	2642,28149
02/01/2020 13:00	2420,79126
02/01/2020 14:00	2461,25488
02/01/2020 15:00	2441,56494
02/01/2020 16:00	2618,56934
02/01/2020 17:00	2619,12012
02/01/2020 18:00	3006,23584
02/01/2020 19:00	2996,32959
02/01/2020 20:00	3803,46338
02/01/2020 21:00	3736,25684
02/01/2020 22:00	3486,77588
02/01/2020 23:00	3134,75269
03/01/2020 0:00	2786,05737
03/01/2020 1:00	2811,90039
03/01/2020 2:00	2810,13648
03/01/2020 3:00	2701,31445
03/01/2020 4:00	2610,05054
03/01/2020 5:00	2619,56787
03/01/2020 6:00	2622,62573
03/01/2020 7:00	2619,80542
03/01/2020 8:00	3735,15308
03/01/2020 9:00	3656,76367
03/01/2020 10:00	3594,66382
03/01/2020 11:00	3638,54492
03/01/2020 12:00	2561,94116
03/01/2020 13:00	2154,27051
03/01/2020 14:00	2190,00464
03/01/2020 15:00	2180,40991
03/01/2020 16:00	2167,16626
03/01/2020 17:00	2167,1897
03/01/2020 18:00	2259,7041
03/01/2020 19:00	2639,4292
03/01/2020 20:00	3235,33838
03/01/2020 21:00	3193,96631
03/01/2020 22:00	3159,29199
03/01/2020 23:00	3169,58936

PREDICCIÓN AÑO 2020	
FECHA	PREDICCIÓN
04/01/2020 0:00	3165,24902
04/01/2020 1:00	3156,24707
04/01/2020 2:00	3151,67969
04/01/2020 3:00	3150,04321
04/01/2020 4:00	3149,98608
04/01/2020 5:00	3151,16919
04/01/2020 6:00	2569,26904
04/01/2020 7:00	2599,11865
04/01/2020 8:00	2435,16162
04/01/2020 9:00	2425,54932
04/01/2020 10:00	2431,66797
04/01/2020 11:00	2431,44263
04/01/2020 12:00	2431,3645
04/01/2020 13:00	2431,01587
04/01/2020 14:00	2429,42773
04/01/2020 15:00	2815,32495
04/01/2020 16:00	3313,99731
04/01/2020 17:00	3575,97315
04/01/2020 18:00	3527,0398
04/01/2020 19:00	3422,21582
04/01/2020 20:00	3756,64844
04/01/2020 21:00	3715,73584
04/01/2020 22:00	3489,0686
04/01/2020 23:00	3327,95215

Tabla D.2. Datos pronosticados hasta Diciembre para el año 2 020

PREDICCIÓN AÑO 2020	
FECHA	PREDICCIÓN
26/12/2020 1:00	2387,00122
26/12/2020 2:00	2035,55798
26/12/2020 3:00	2023,43701
26/12/2020 4:00	2039,52576
26/12/2020 5:00	1866,93567
26/12/2020 6:00	1857,3103
26/12/2020 7:00	1867,06177
26/12/2020 8:00	2418,72437
26/12/2020 9:00	2173,66773
26/12/2020 10:00	2603,67481
26/12/2020 11:00	2248,35181
26/12/2020 12:00	2303,25879
26/12/2020 13:00	2225,94385
26/12/2020 14:00	2124,38623
26/12/2020 15:00	2121,6062
26/12/2020 16:00	1946,35815
26/12/2020 17:00	1848,63391
26/12/2020 18:00	1850,61096
26/12/2020 19:00	1857,05676
26/12/2020 20:00	2603,60449
26/12/2020 21:00	2831,70996
26/12/2020 22:00	2788,93237
26/12/2020 23:00	2777,85352
27/12/2020 0:00	2115,35132
27/12/2020 1:00	2103,65698
27/12/2020 2:00	2128,01831
27/12/2020 3:00	2124,48926
27/12/2020 4:00	2123,71094
27/12/2020 5:00	2036,98084
27/12/2020 6:00	2035,58374
27/12/2020 7:00	2041,62048
27/12/2020 8:00	2414,44653
27/12/2020 9:00	2335,14063
27/12/2020 10:00	2502,41773
27/12/2020 11:00	2413,52026
27/12/2020 12:00	2213,61401

PREDICCIÓN AÑO 2020	
FECHA	PREDICCIÓN
27/12/2020 13:00	2211,31299
27/12/2020 14:00	2126,77173
27/12/2020 15:00	2403,2356
27/12/2020 16:00	2509,54663
27/12/2020 17:00	2790,93164
27/12/2020 18:00	2783,31909
27/12/2020 19:00	2768,65479
27/12/2020 20:00	3390,21899
27/12/2020 21:00	3347,93408
27/12/2020 22:00	3311,67163
27/12/2020 23:00	3330,49829
28/12/2020 0:00	2539,89038
28/12/2020 1:00	2582,46606
28/12/2020 2:00	2808,52783
28/12/2020 3:00	3182,65503
28/12/2020 4:00	3146,36816
28/12/2020 5:00	3139,4148
28/12/2020 6:00	3990,69727
28/12/2020 7:00	4209,3374
28/12/2020 8:00	4126,77441
28/12/2020 9:00	4163,30615
28/12/2020 10:00	4179,17676
28/12/2020 11:00	4169,13428
28/12/2020 12:00	3974,27368
28/12/2020 13:00	3817,03101
28/12/2020 14:00	3661,19702
28/12/2020 15:00	3678,5061
28/12/2020 16:00	3766,95923
28/12/2020 17:00	3749,05615
28/12/2020 18:00	3752,26123
28/12/2020 19:00	3762,85889
28/12/2020 20:00	4142,76172
28/12/2020 21:00	4093,36133
28/12/2020 22:00	3995,448
28/12/2020 23:00	3943,72925
29/12/2020 0:00	3957,68481
29/12/2020 1:00	3586,16455

PREDICCIÓN AÑO 2020	
FECHA	PREDICCIÓN
29/12/2020 2:00	3259,13965
29/12/2020 3:00	3295,77368
29/12/2020 4:00	3280,78955
29/12/2020 5:00	3257,83643
29/12/2020 6:00	2711,09253
29/12/2020 7:00	2721,20264
29/12/2020 8:00	3105,11084
29/12/2020 9:00	3070,38403
29/12/2020 10:00	3042,25537
29/12/2020 11:00	869,551575
29/12/2020 12:00	508,188995
29/12/2020 13:00	450,078461
29/12/2020 14:00	431,149139
29/12/2020 15:00	423,105957
29/12/2020 16:00	1315,85278
29/12/2020 17:00	3247,47241
29/12/2020 18:00	3230,9895
29/12/2020 19:00	2777,32422
29/12/2020 20:00	2749,3064
29/12/2020 21:00	2745,54614
29/12/2020 22:00	2811,47412
29/12/2020 23:00	2688,68213
30/12/2020 0:00	2674,60034
30/12/2020 1:00	2482,28711
30/12/2020 2:00	2385,68018
30/12/2020 3:00	2393,71729
30/12/2020 4:00	2397,60425
30/12/2020 5:00	2398,48315
30/12/2020 6:00	2401,45361
30/12/2020 7:00	3201,40649
30/12/2020 8:00	3279,58716
30/12/2020 9:00	3228,34985
30/12/2020 10:00	2740,50391
30/12/2020 11:00	2578,5332
30/12/2020 12:00	2411,77905
30/12/2020 13:00	2044,47009
30/12/2020 14:00	1863,90491

PREDICCIÓN AÑO 2020	
FECHA	PREDICCIÓN
30/12/2020 15:00	1869,22022
30/12/2020 16:00	1877,55286
30/12/2020 17:00	1879,96472
30/12/2020 18:00	1881,62268
30/12/2020 19:00	1881,93311
30/12/2020 20:00	2238,44165
30/12/2020 21:00	2261,46606
30/12/2020 22:00	2426,70898
30/12/2020 23:00	2333,29419
31/12/2020 0:00	2223,0481
31/12/2020 1:00	2218,79761
31/12/2020 2:00	2219,53687
31/12/2020 3:00	2216,4021
31/12/2020 4:00	2499,3667
31/12/2020 5:00	2504,59277
31/12/2020 6:00	2489,26221
31/12/2020 7:00	2887,0188
31/12/2020 8:00	2979,87549
31/12/2020 9:00	2951,68164
31/12/2020 10:00	2951,9397
31/12/2020 11:00	2955,45483
31/12/2020 12:00	2753,64014
31/12/2020 13:00	2566,61157
31/12/2020 14:00	2583,65039
31/12/2020 15:00	2590,34448
31/12/2020 16:00	2588,06323
31/12/2020 17:00	2590,22339
31/12/2020 18:00	2593,46777
31/12/2020 19:00	2595,54297
31/12/2020 20:00	2792,97583
31/12/2020 21:00	3192,00977
31/12/2020 22:00	3159,5603
31/12/2020 23:00	3142,14746

Tabla D.3. Datos pronosticados desde Enero para el año 2 021

PREDICCIÓN AÑO 2021	
FECHA	PREDICCIÓN
01/01/2021 0:00	2267,2908
01/01/2021 1:00	1893,9517
01/01/2021 2:00	1720,8625
01/01/2021 3:00	1703,7964
01/01/2021 4:00	1725,7168
01/01/2021 5:00	1736,7987
01/01/2021 6:00	1729,5092
01/01/2021 7:00	1878,5764
01/01/2021 8:00	1997,4083
01/01/2021 9:00	2024,4204
01/01/2021 10:00	2009,9462
01/01/2021 11:00	2047,6816
01/01/2021 12:00	2418,4158
01/01/2021 13:00	2588,9417
01/01/2021 14:00	2615,8384
01/01/2021 15:00	2602,1938
01/01/2021 16:00	2471,0552
01/01/2021 17:00	2363,91
01/01/2021 18:00	2467,6472
01/01/2021 19:00	2600,705
01/01/2021 20:00	2780,613
01/01/2021 21:00	2840,4067
01/01/2021 22:00	2840,9326
01/01/2021 23:00	2832,2183
02/01/2021 0:00	2387,5017
02/01/2021 1:00	2218,5493
02/01/2021 2:00	2205,4211
02/01/2021 3:00	2477,9514
02/01/2021 4:00	2602,635
02/01/2021 5:00	2616,9668
02/01/2021 6:00	2596,1772
02/01/2021 7:00	2513,965
02/01/2021 8:00	2860,9128
02/01/2021 9:00	3078,1694
02/01/2021 10:00	2984,111
02/01/2021 11:00	2787,0261

PREDICCIÓN AÑO 2021	
FECHA	PREDICCIÓN
02/01/2021 12:00	2595,7185
02/01/2021 13:00	2553,3523
02/01/2021 14:00	2444,8247
02/01/2021 15:00	2478,6787
02/01/2021 16:00	2509,8157
02/01/2021 17:00	2519,3894
02/01/2021 18:00	2515,671
02/01/2021 19:00	2507,4783
02/01/2021 20:00	2753,6162
02/01/2021 21:00	2851,0298
02/01/2021 22:00	2919,4424
02/01/2021 23:00	2926,7698
03/01/2021 0:00	2407,8037
03/01/2021 1:00	2089,138
03/01/2021 2:00	2020,5575
03/01/2021 3:00	2041,4447
03/01/2021 4:00	2067,7932
03/01/2021 5:00	2076,3164
03/01/2021 6:00	2069,7295
03/01/2021 7:00	2293,6545
03/01/2021 8:00	2698,1206
03/01/2021 9:00	3429,1626
03/01/2021 10:00	1396,0558
03/01/2021 11:00	528,5676
03/01/2021 12:00	257,75034
03/01/2021 13:00	230,78163
03/01/2021 14:00	269,28693
03/01/2021 15:00	298,41525
03/01/2021 16:00	300,9804
03/01/2021 17:00	283,09537
03/01/2021 18:00	255,33119
03/01/2021 19:00	225,70535
03/01/2021 20:00	198,6858
03/01/2021 21:00	176,04604
03/01/2021 22:00	157,97693
03/01/2021 23:00	143,90497
04/01/2021 0:00	536,3697

PREDICCIÓN AÑO 2021	
FECHA	PREDICCIÓN
04/01/2021 1:00	1793,1421
04/01/2021 2:00	2636,693
04/01/2021 3:00	2829,8435
04/01/2021 4:00	2772,32
04/01/2021 5:00	2527,9446
04/01/2021 6:00	2147,242
04/01/2021 7:00	2032,6573
04/01/2021 8:00	2062,1204
04/01/2021 9:00	1952,2449
04/01/2021 10:00	1917,3395
04/01/2021 11:00	1924,3038
04/01/2021 12:00	1937,1018
04/01/2021 13:00	1774,4369
04/01/2021 14:00	1688,6918
04/01/2021 15:00	1660,1615
04/01/2021 16:00	1762,7848
04/01/2021 17:00	1815,7493
04/01/2021 18:00	1824,1293
04/01/2021 19:00	1814,1979
04/01/2021 20:00	2259,0984
04/01/2021 21:00	2480,3984
04/01/2021 22:00	2459,921
04/01/2021 23:00	2414,0664

Tabla D.4. Datos pronosticados hasta Diciembre para el año 2 021

PREDICCIÓN AÑO 2021	
FECHA	PREDICCIÓN
26/12/2021 5:00	1837,8776
26/12/2021 6:00	1836,4241
26/12/2021 7:00	1830,4564
26/12/2021 8:00	1935,4447
26/12/2021 9:00	2334,8154
26/12/2021 10:00	2512,0627
26/12/2021 11:00	2534,4978
26/12/2021 12:00	2574,5305
26/12/2021 13:00	2224,323
26/12/2021 14:00	2014,687
26/12/2021 15:00	1970,032
26/12/2021 16:00	1989,2476
26/12/2021 17:00	2014,5392
26/12/2021 18:00	2027,76
26/12/2021 19:00	2029,3177
26/12/2021 20:00	2140,678
26/12/2021 21:00	2428,1248
26/12/2021 22:00	2665,6296
26/12/2021 23:00	2725,651
27/12/2021 0:00	2343,531
27/12/2021 1:00	1939,5354
27/12/2021 2:00	1865,3372
27/12/2021 3:00	1835,4834
27/12/2021 4:00	1843,4419
27/12/2021 5:00	1855,0916
27/12/2021 6:00	1857,9076
27/12/2021 7:00	1852,3472
27/12/2021 8:00	1842,541
27/12/2021 9:00	2117,312
27/12/2021 10:00	2249,2332
27/12/2021 11:00	2270,7195
27/12/2021 12:00	2255,8362
27/12/2021 13:00	2242,2798
27/12/2021 14:00	2063,5496
27/12/2021 15:00	1987,3083
27/12/2021 16:00	2036,8464

PREDICCIÓN AÑO 2021	
FECHA	PREDICCIÓN
27/12/2021 17:00	2077,7405
27/12/2021 18:00	2153,9385
27/12/2021 19:00	2184,9453
27/12/2021 20:00	2188,1865
27/12/2021 21:00	2183,2124
27/12/2021 22:00	2179,0176
27/12/2021 23:00	2177,508
28/12/2021 0:00	1946,2821
28/12/2021 1:00	1840,0146
28/12/2021 2:00	1818,3387
28/12/2021 3:00	1825,2021
28/12/2021 4:00	1832,9523
28/12/2021 5:00	1834,2092
28/12/2021 6:00	1830,1636
28/12/2021 7:00	1713,5565
28/12/2021 8:00	1760,9641
28/12/2021 9:00	2255,9858
28/12/2021 10:00	2497,8647
28/12/2021 11:00	2538,9998
28/12/2021 12:00	2515,1204
28/12/2021 13:00	2136,9155
28/12/2021 14:00	2093,1787
28/12/2021 15:00	2129,4705
28/12/2021 16:00	2049,7937
28/12/2021 17:00	1959,24
28/12/2021 18:00	1872,4895
28/12/2021 19:00	1843,5914
28/12/2021 20:00	1840,4242
28/12/2021 21:00	1841,0598
28/12/2021 22:00	1951,1704
28/12/2021 23:00	2001,0042
29/12/2021 0:00	2006,112
29/12/2021 1:00	1996,1561
29/12/2021 2:00	1929,8461
29/12/2021 3:00	1897,2549
29/12/2021 4:00	1833,8647
29/12/2021 5:00	1808,4576

PREDICCIÓN AÑO 2021	
FECHA	PREDICCIÓN
29/12/2021 6:00	1805,334
29/12/2021 7:00	1808,4106
29/12/2021 8:00	1810,4915
29/12/2021 9:00	2269,345
29/12/2021 10:00	2496,6782
29/12/2021 11:00	2536,995
29/12/2021 12:00	2159,5093
29/12/2021 13:00	1983,6421
29/12/2021 14:00	1952,2491
29/12/2021 15:00	1972,6036
29/12/2021 16:00	1882,7411
29/12/2021 17:00	1841,4001
29/12/2021 18:00	1832,5568
29/12/2021 19:00	1889,1688
29/12/2021 20:00	2087,9805
29/12/2021 21:00	2411,8987
29/12/2021 22:00	2532,818
29/12/2021 23:00	2536,3242
30/12/2021 0:00	2392,7776
30/12/2021 1:00	2209,4136
30/12/2021 2:00	1976,419
30/12/2021 3:00	1845,2142
30/12/2021 4:00	1821,5796
30/12/2021 5:00	1948,7291
30/12/2021 6:00	2017,3298
30/12/2021 7:00	2031,8663
30/12/2021 8:00	2022,9568
30/12/2021 9:00	2243,2998
30/12/2021 10:00	2587,7668
30/12/2021 11:00	2711,3901
30/12/2021 12:00	2712,9058
30/12/2021 13:00	2383,3193
30/12/2021 14:00	2247,2478
30/12/2021 15:00	2236,5693
30/12/2021 16:00	2263,463
30/12/2021 17:00	2108,6033
30/12/2021 18:00	1924,9185

PREDICCIÓN AÑO 2021	
FECHA	PREDICCIÓN
30/12/2021 19:00	1859,181
30/12/2021 20:00	1851,2146
30/12/2021 21:00	2204,2388
30/12/2021 22:00	2372,7312
30/12/2021 23:00	2518,657
31/12/2021 0:00	2548,5938
31/12/2021 1:00	2533,5598
31/12/2021 2:00	2157,5024
31/12/2021 3:00	1884,1422
31/12/2021 4:00	1809,739
31/12/2021 5:00	1819,5305
31/12/2021 6:00	1842,6294
31/12/2021 7:00	1854,4601
31/12/2021 8:00	1853,6565
31/12/2021 9:00	2309,7925
31/12/2021 10:00	2649,3257
31/12/2021 11:00	2733,8691
31/12/2021 12:00	2712,06
31/12/2021 13:00	2436,1428
31/12/2021 14:00	2265,3892
31/12/2021 15:00	1998,6248
31/12/2021 16:00	1914,9536
31/12/2021 17:00	1920,504
31/12/2021 18:00	1942,7664
31/12/2021 19:00	1954,6552
31/12/2021 20:00	1953,7783
31/12/2021 21:00	2236,7185
31/12/2021 22:00	2365,364
31/12/2021 23:00	2261,2427

ANEXO E

MANUAL DE USUARIO

1 de 6

UNIVERSIDAD TÉCNICA DE COTOPAXI



FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

TITULACIÓN:

GRADO EN INGENIERÍA ELÉCTRICA

MANUAL DE USUARIO

TÍTULO:

VISUAL ESTUDIO CODE-PREDICCIÓN DE ENERGIA ELECTRICA CON RNA
PARA LA CENTRAL HIDROELECTRICA ILLUCHI 2

AUTORES:

Bastidas Cashicana Wilson Roberto

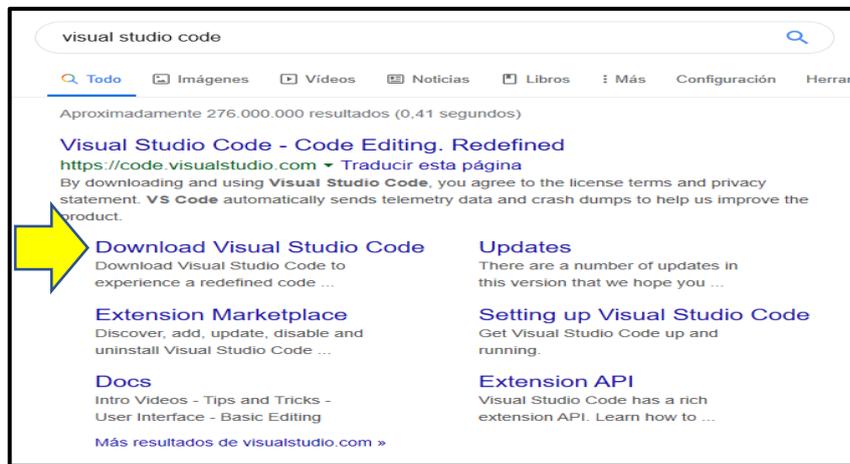
Moya Cabezas Angelo Mauricio

Visual Studio Code es un editor de código fuente desarrollado por Microsoft para Windows, Linux y macOS. Incluye soporte para depuración, control integrado de GIT, resaltado de sintaxis finalización inteligente de código, fragmentos y refactorización de código.

En este Manual se observa como instalar paso a paso Visual Studio Code y la manera correcta de iniciar el programa para la predicción de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

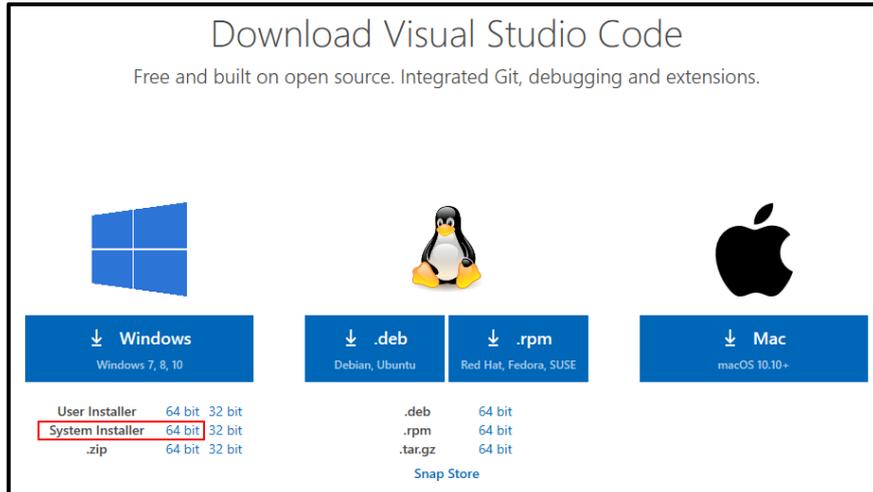
Se selecciona un navegador web de confianza y se escribe Visual Studio Code en la barra de búsqueda. En los resultados, se clickea en Download Visual Studio Code.

Figura E.1. Navegador web para descargar Visual Studio Code



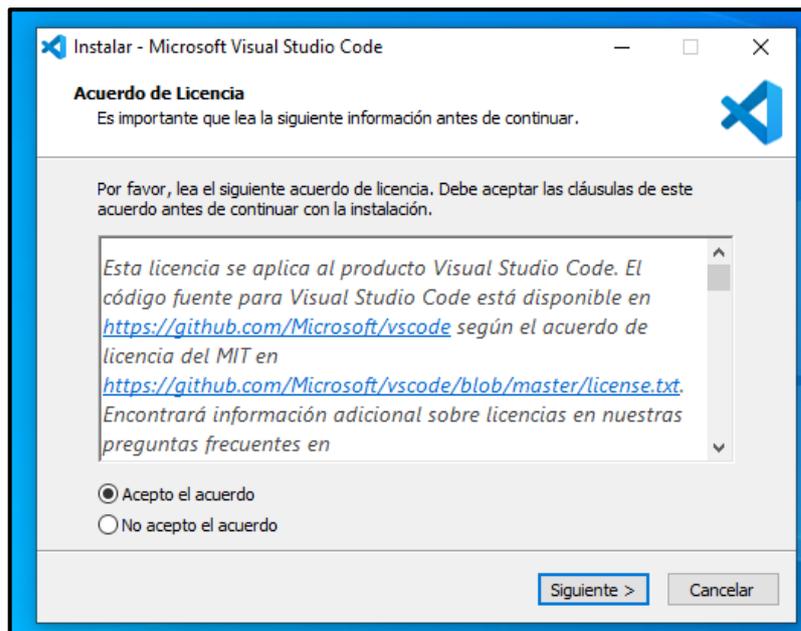
Nos cargará una pantalla como la de la siguiente captura. En el caso, que el sistema operativo es 64 bits, se selecciona lo marcado en el recuadro rojo. Si el sistema operativo donde se instale es 32 bits, habría que seleccionar la versión correspondiente.

Figura E.2. Ventana principal para descargar Visual Studio Code



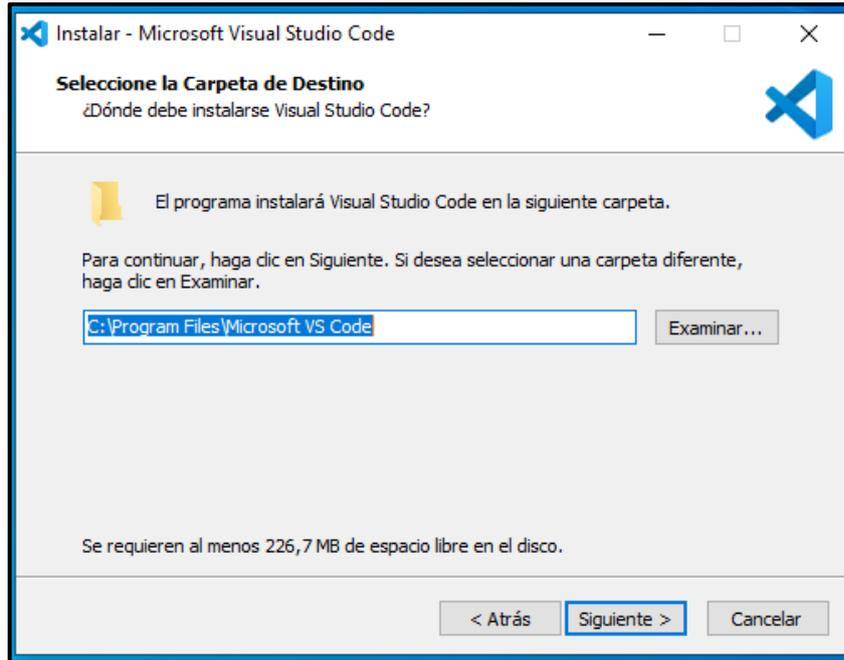
Una vez descargado el fichero de instalación, se ejecuta como administrador. Se abrirá un asistente para empezar a instalar. Aceptamos el acuerdo de licencia y Siguiente.

Figura E.3. Acuerdo de licencia para descargar Visual Studio Code



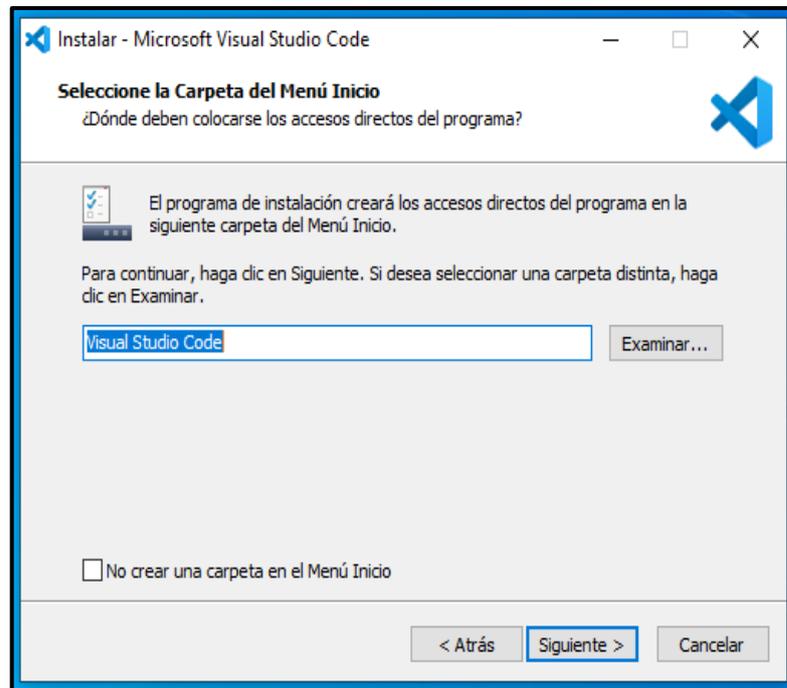
Se indica la ruta donde se desea instalar. Por defecto se puede instalar en Program Files. Después se clickea sobre Siguiente.

Figura E.4. Selección de la carpeta de destino para descargar Visual Studio Code



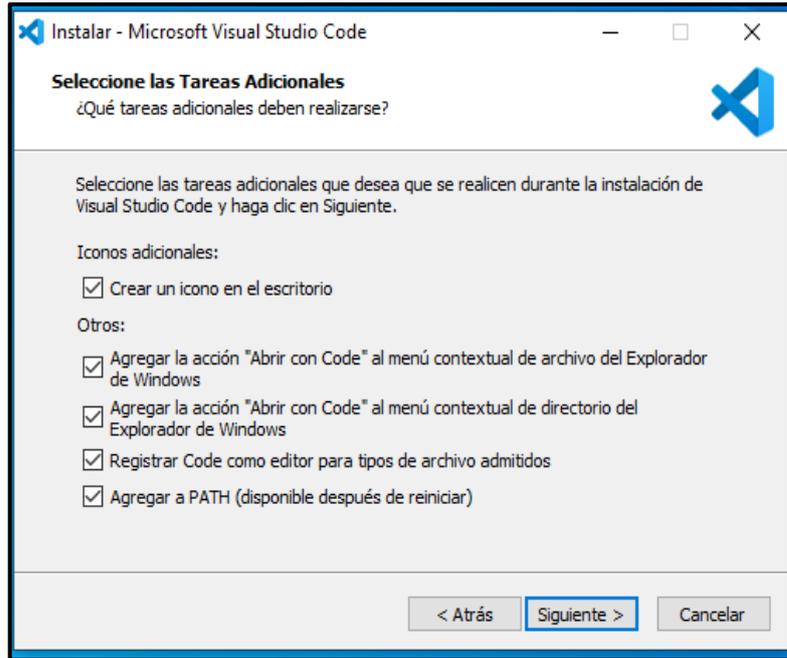
En la siguiente pantalla se mantiene todo por defecto y Siguiente.

Figura E.5. Selección de la carpeta del menú inicio para descargar Visual Studio Code



En la siguiente pantalla se marcan las opciones que se crean convenientes para el entorno de trabajo y se clickea sobre Siguiente.

Figura E.6. Selección de las tareas adicionales para descargar Visual Studio Code



Una vez realizado los pasos anteriores se procesa a la instalación del software clickeando sobre Instalar.

Figura E.7. Instalación del programa computacional Visual Studio Code

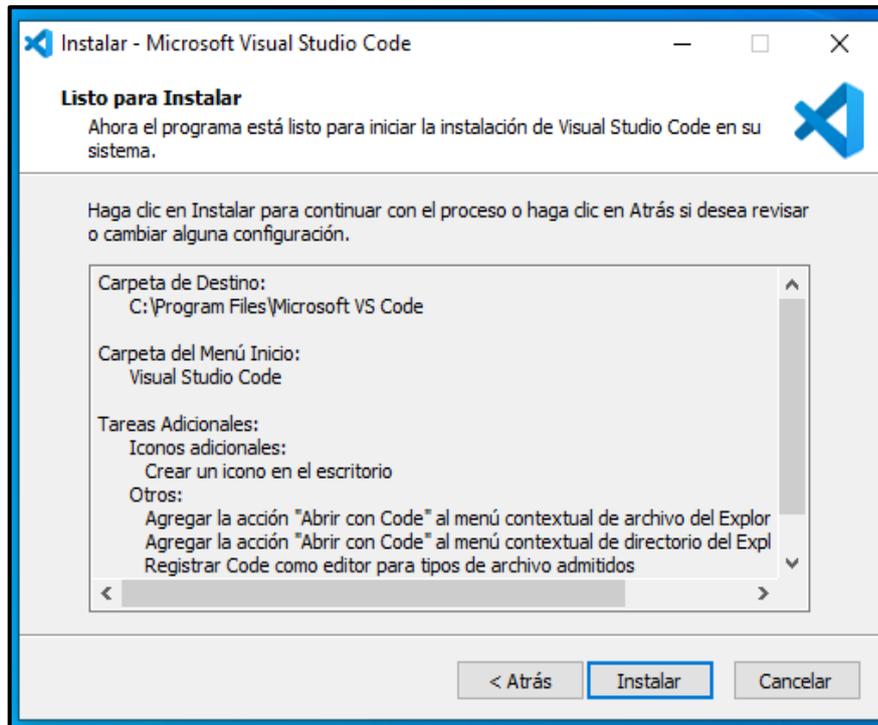
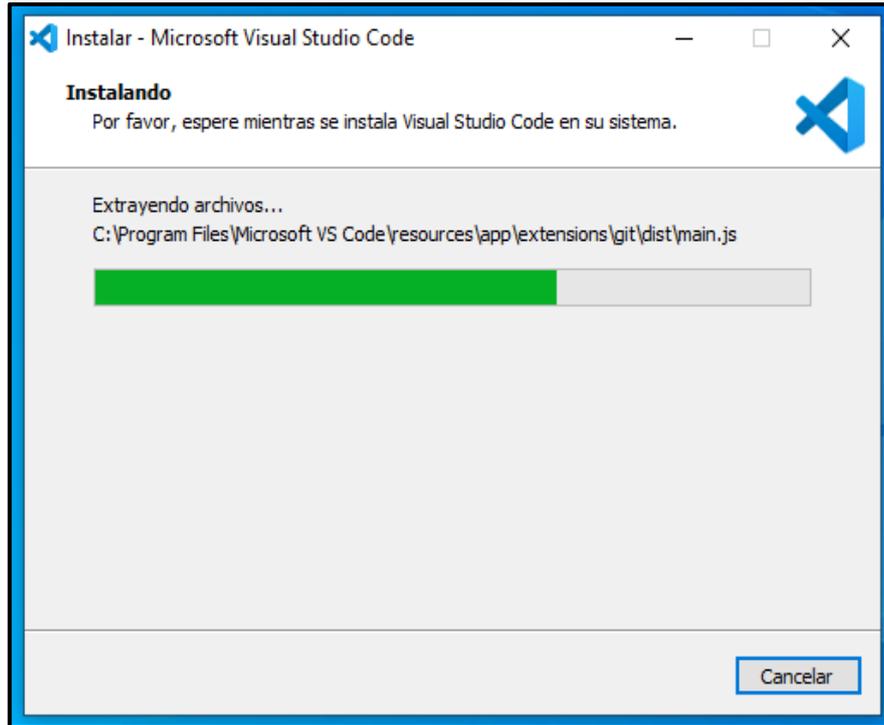


Figura E.8. Instalación en proceso del programa computacional Visual Studio Code



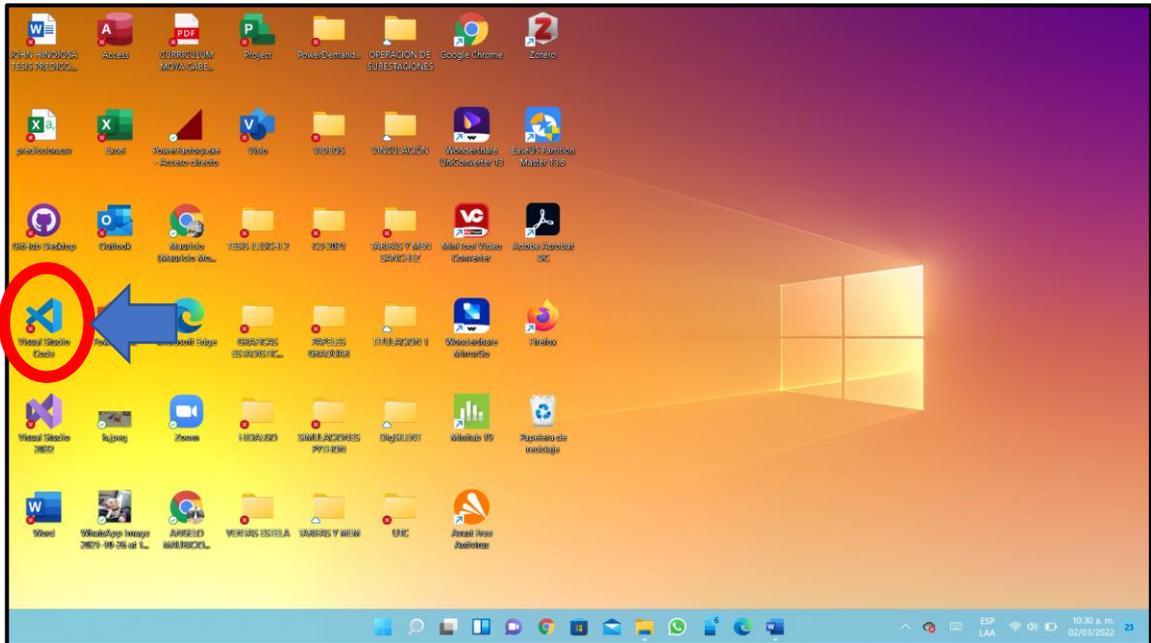
Una vez finalizada la instalación se clickea sobre el botón Finalizar.

Figura E.9. Instalación completa del programa computacional Visual Studio Code



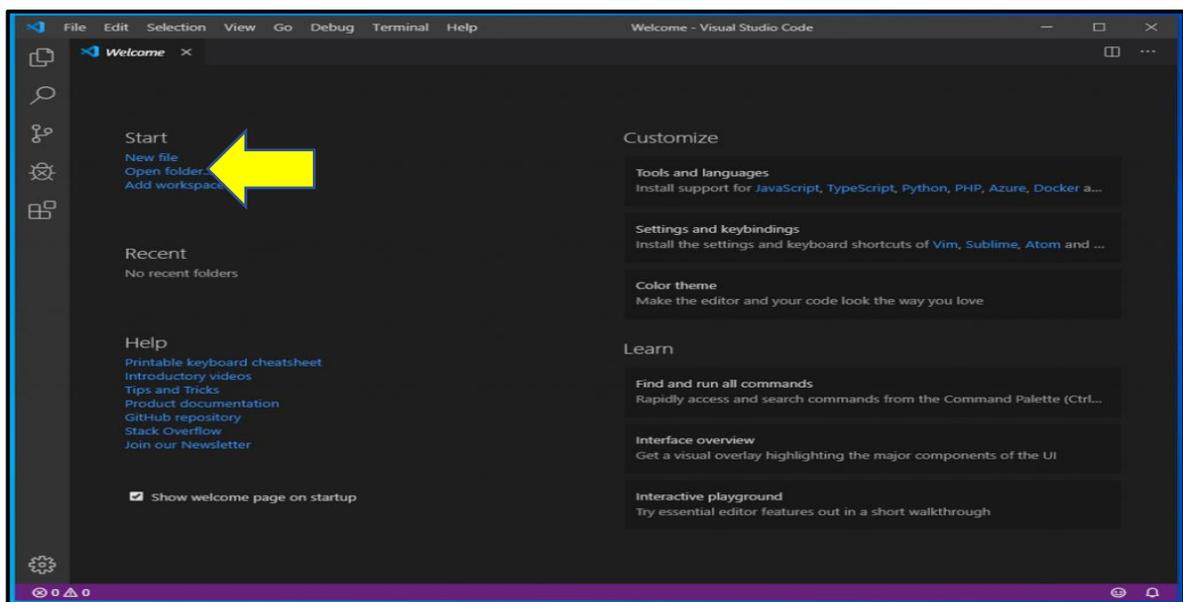
Después solo sé que clickea sobre el icono que ha creado Visual Studio Code para iniciar el Software.

Figura E.10. Icono del software instalado correspondiente al programa computacional Visual Studio Code



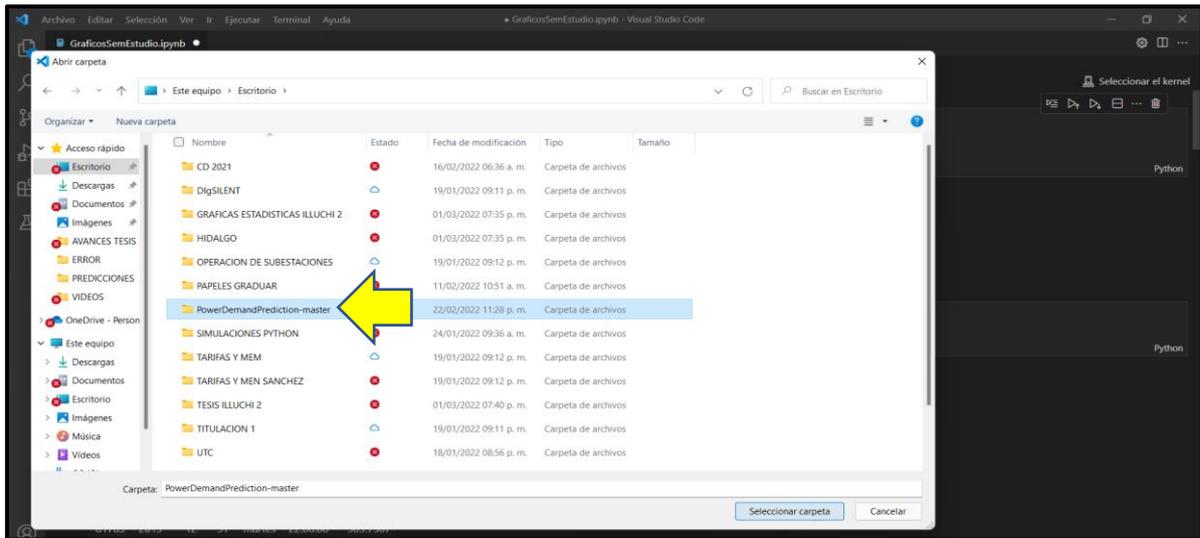
Una vez iniciado el Software procedemos abrir la carpeta en donde se encuentra la programación respectiva sobre la predicción de la demanda de energía eléctrica en la central Illuchi 2 dando click en la opción “open folder”

Figura E.11. Ventana principal del programa computacional Visual Studio Code



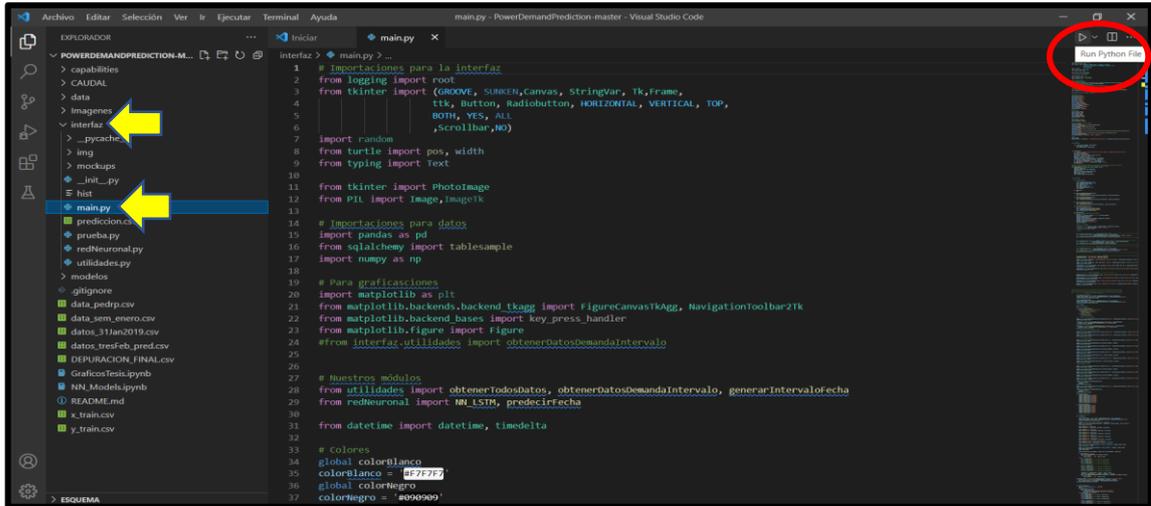
Realizado el paso anterior, el software procede a abrir una ventana adicional en la cual se escogerá la carpeta en donde se encuentra la simulación correspondiente la cual tiene como nombre “PowerDemandPrediction-master” misma que será entregada en un CD al encargado del laboratorio de la facultad de CIYA para su uso didáctico.

Figura E.12. Selección de la carpeta de la implementación de la interfaz gráfica para la predicción de la demanda de energía eléctrica



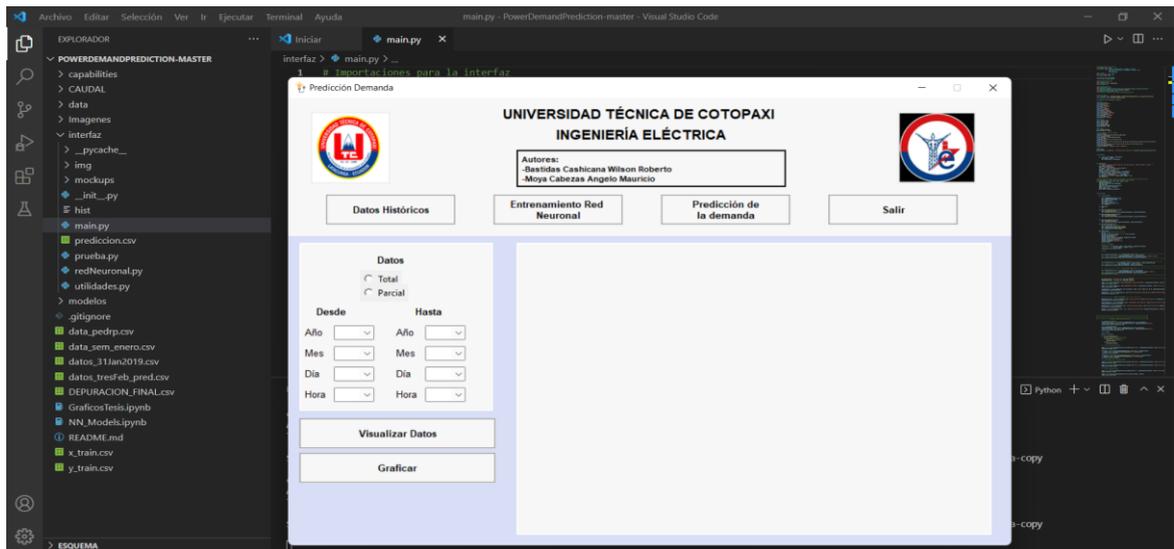
Una vez que se abre la carpeta seleccionada, el software procede a cargar todos los datos que se encuentran dentro, de tal manera que para su uso didáctico se creó una interfaz de usuario la cual debe ser ejecutada clickeando en la opción “interfaz”, después en la opción “main.py” y por último iniciamos la interfaz dando click en el icono que se encuentra señalado con color rojo el cual se denomina “Run Python File”

Figura E.13. Selección de los archivos correspondientes a la implementación de la interfaz gráfica para la predicción de la demanda de energía eléctrica



Por último, esperamos unos segundos hasta que nuestra interfaz cargue para luego proceder con su respectivo uso. Para la utilización de la interfaz se recomienda la revisión de la sección 5.12 del trabajo de titulación.

Figura E.14. Vista previa de la interfaz gráfica para la predicción de la demanda de energía eléctrica



OBSERVACIONES:

En caso de realizar predicciones de demanda de energía eléctrica con una base de datos distinta se deberá cargar un archivo en formato XLSX o CSV en la sección denominada “data” de la carpeta principal “PowerDemandPrediction-master”

Figura E.15. Cambio de la base de datos para la predicción de la demanda de energía eléctrica

