



**UNIVERSIDAD TÉCNICA DE COTOPAXI**

**FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS**

**INGENIERÍA ELÉCTRICA EN SISTEMAS ELÉCTRICOS DE POTENCIA**

**PROYECTO DE INVESTIGACIÓN**

**PREDICCIÓN DE LA DEMANDA ELÉCTRICA DEL EDIFICIO DE UNA  
INSTITUCIÓN DE EDUCACIÓN SUPERIOR BASADO EN REDES  
NEURONALES ARTIFICIALES**

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

**Autor/es:**

Unapucha Quintuña Byron Mauricio

**Tutor:**

Ing. MSc. Castillo Fiallos Jessica Nataly

**LATACUNGA – ECUADOR**

**Marzo - 2023**

## DECLARACIÓN DE AUTORÍA

Yo, **Unapucha Quintuña Byron Mauricio** con C.I. N°: **1722194360** declaro ser autor del presente proyecto de investigación: **“PREDICCIÓN DE LA DEMANDA ELÉCTRICA DEL EDIFICIO DE UNA INSTITUCIÓN DE EDUCACIÓN SUPERIOR BASADO EN REDES NEURONALES ARTIFICIALES”**, siendo la **Ing. MSc. Jessica Nataly Castillo Fiallos** tutora del presente trabajo; y eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

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

.....

Unapucha Quintuña Byron Mauricio

C.C. 1722194360

## **AVAL DEL TUTOR DE PROYECTO DE INVESTIGACIÓN**

En calidad de Tutor del Trabajo de Investigación sobre el título: **“PREDICCIÓN DE LA DEMANDA ELÉCTRICA DEL EDIFICIO DE UNA INSTITUCIÓN DE EDUCACIÓN SUPERIOR BASADO EN REDES NEURONALES ARTIFICIALES”**, **Unapucha Quintuña Byron 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 2023

.....  
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, el postulante: **Unapucha Quintuña Byron Mauricio** con el título de Proyecto de titulación: **“PREDICCIÓN DE LA DEMANDA ELÉCTRICA DEL EDIFICIO DE UNA INSTITUCIÓN DE EDUCACIÓN SUPERIOR BASADO EN REDES NEURONALES ARTIFICIALES”**, 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 2023

Para constancia firman:

.....

**Lector 1 (Presidente)**

**Nombre:** Diego Leonardo Jimenez Jimenez

**CC:** 0503493702

.....

**Lector 2**

**Nombre:** Edgar Roberto Salazar Achig

**CC:** 0502847619

.....

**Lector 3**

**Nombre:** Carlos Iván Quinatoa Caiza

**CC:** 0503287864

## **AGRADECIMIENTO**

*Agradezco a Dios – Jehová por el regalo de la vida, luego por el tiempo otorgado siendo este el más valioso, las oportunidades que me ha generado a lo largo de mi vida.*

*A mis padres porque ellos son el motivo de crecer día a día, su generosidad su apoyo incondicional, sus sabios consejos, el sueño de ver uno más de sus hijos siendo un profesional, luego a mi familia Fernanda y Mauro por ser una persona afortunada de formar parte de ustedes los pilares fundamentales en mi vida, también agradezco a la provincia de Cotopaxi por abrirme las puertas estudiantil y laboralmente siendo la Corporación Nacional de Telecomunicaciones CNT EP. Por el tiempo que se me asigno para asistir a las aulas demostrar mi capacidad.*

*Por último a mis colegas, amigos por compartirme compañía, amistad, sus consejos, alentarme durante mi carrera.*

## DEDICATORIA

*La presente tesis, está dedicada e inspirada a nuestro Creador que es “Dios - Jehová” por su infinito amor, sabiduría, bondad, y demás regalos que nos da a lo largo de nuestras vidas, a mi querido padre Angel mi amada madre Olga por sus consejos, su generosidad apoyo incondicional; luego a Fernanda mi pareja por todos los años que hemos estado en convivencia apoyándonos uno del otro somos un gran equipo, Mauro mi hijo por ser la principal fuente de inspiración en toda mi carrera universitaria.*

*A mis docentes y compañeros por su tiempo, paciencia, sabiduría otorgada a lo largo de toda nuestra etapa estudiantil, por momentos únicos que quedan plasmados en nuestras memorias, de tiempo compartido en las aulas de una prestigiosa Universidad que nos abrió las puertas para ser mejores personas en beneficio de la sociedad.*

*A mi empresa donde trabajo CNT por confiar en mí y darme la oportunidad de especializarme técnicamente, también a las demás personas a lo largo de estos años estuvieron a mi lado apoyándome moralmente para que no decaiga en el camino, sus palabras de ánimo me reconfortaban siempre.*

## INDICE GENERAL

DECLARACIÓN DE AUTORÍA.....	ii
AVAL DEL TUTOR DE PROYECTO DE INVESTIGACIÓN.....	iii
APROBACIÓN DEL TRIBUNAL DE TITULACIÓN.....	iv
AGRADECIMIENTO .....	v
DEDICATORIA .....	vi
INDICE GENERAL .....	vii
INDICE DE FIGURAS.....	xv
INDICE DE TABLAS .....	xix
RESUMEN.....	xx
ABSTRACT.....	xxi
<i>AVAL DE TRADUCCIÓN</i> .....	xxii
1. INFORMACIÓN GENERAL.....	1
2. INTRODUCCIÓN .....	3
2.1. EL PROBLEMA.....	3
2.1.1. Situación Problémica.....	3
2.1.2. Formulación del problema .....	3
2.2. BENEFICIARIOS.....	4
2.2.1. Directos .....	4
2.2.2. Indirectos.....	4
2.3. OBJETO Y CAMPO DE ACCIÓN .....	4
2.4. JUSTIFICACIÓN .....	4
2.5. HIPOTESIS.....	5
2.6. OBJETIVOS .....	5
2.6.1. General .....	5

2.6.2. Específicos .....	5
2.7. SISTEMA DE TAREAS.....	5
3. FUNDAMENTACIÓN TEÓRICA.....	7
3.1. ANTECEDENTES DE LA INVESTIGACIÓN.....	7
3.2. MARCO TEÓRICO.....	8
3.2.1. Conceptos de electricidad.....	8
3.2.1.1. Sistema eléctrico.....	8
3.2.1.2. Concepto de carga en un sistema eléctrico.....	9
3.2.1.3. Concepto de la demanda de energía eléctrica.....	9
3.2.1.4. Tipos de demanda eléctrica .....	9
3.2.1.5. Demanda eléctrica a largo plazo (Anual) .....	10
3.2.2. Consumo de Energía Eléctrica .....	11
3.2.2.1. Pliego Tarifario.....	11
3.2.2.2. Tipos de consumidores de Energía Eléctrica.....	11
3.2.2.3. Categorías tarifarias según el Pliego Tarifario .....	12
3.2.3. Relación entre consumo eléctrico y demanda eléctrica .....	13
3.2.4. Factor de Carga .....	14
3.2.5. Analizador de calidad eléctrica y energía (Fluke 435).....	15
3.2.6. Predicción del consumo de energía eléctrica .....	16
3.2.7. Horizontes temporales para la predicción de consumo de energía eléctrica. ....	18
3.2.7.1. Corto plazo .....	18
3.2.7.2. Mediano plazo .....	18
3.2.7.3. Largo plazo .....	18
3.2.8. Perceptron multicapa.....	19
3.2.9. Clasificación de los métodos del pronóstico de consumo de energía eléctrica.....	19



3.2.10. Técnicas para la predicción de consumo de energía eléctrica.....	20
3.2.11. Técnicas de regresión .....	20
3.2.11.1. Regresión lineal.....	21
3.2.12. Categorización de las variables para la predicción de consumo de energía eléctrica .....	21
3.2.12.1. Inteligencia Artificial.....	22
3.2.12.2. Machine Learning.....	23
3.2.12.3. Deep Learning .....	23
3.2.12.4. Aprendizaje automático.....	24
3.2.13. Métodos de inteligencia artificial para la predicción de consumo de energía eléctrica .....	24
3.2.14. Redes neuronales artificiales .....	25
3.2.14.1. Funcionamiento de las neuronas .....	25
3.2.14.2. Características principales de una neurona biológica.....	25
3.2.14.3. Características principales de una red neuronal artificial.....	26
3.2.14.4. Modelo matemático de la red neuronal artificial.....	27
3.2.15. Arquitectura de redes neuronales .....	30
3.2.15.1. Unidad de proceso .....	30
3.2.15.2. Según la estructura de capas.....	30
3.2.15.3. Según el tipo de respuesta .....	31
3.2.15.4. Según el flujo de los datos.....	31
3.2.16. Funciones de activación para la aplicación de redes neuronales artificiales.....	33
3.2.16.1. Función tangente sigmoidea .....	34
3.2.16.2. Función logarítmica sigmoidea .....	34
3.2.17. Mecanismo de aprendizaje para el uso de redes neuronales artificiales. ....	35
3.2.17.1. Aprendizaje supervisado .....	35
3.2.17.2. Aprendizaje no supervisado .....	36
3.2.17.3. Aprendizaje por refuerzo .....	36

3.2.18. Algoritmos de aprendizaje para el uso de redes neuronales artificiales.....	36
3.2.19. Optimizadores de redes neuronales artificiales.....	37
3.2.20. Problemas derivados del entrenamiento en el uso de RNA.....	37
3.2.20.1. Overfitting .....	38
3.2.20.2. Underfitting .....	38
3.2.20.3. Normal fitting .....	38
3.2.21. Criterios para la validación de los resultados aplicando un método de análisis.....	39
3.2.21.1. Error medio cuadrático (MSE – mean square error) .....	39
3.2.21.2. Raíz del Error Medio Cuadrático (Root Mean Squared Error – RMSE) .....	39
3.2.21.3. Error Medio Absoluto (Mean Absolute Error MAE).....	39
3.2.21.4. Error Medio Absoluto Porcentual (Mean Absolute Percentage Error - MAPE).....	39
3.2.21.5. Error residual.....	40
3.2.21.6. Error estándar múltiple .....	40
3.2.22. Distribución de probabilidad.....	40
3.2.23. Matriz de confusión.....	40
3.2.24. Power Log .....	42
3.2.24.1. Instalación de Power Log .....	43
3.2.24.2. Descarga de datos del analizador de red hacia un PC .....	43
3.2.25. MATLAB .....	44
3.2.25.1. Aplicaciones de Matlab .....	45
4. METODOLOGÍA .....	48
4.1. TIPO DE INVESTIGACIÓN .....	48
4.1.1. Investigación exploratoria .....	48
4.1.2. Investigación de campo.....	48
4.1.3. Investigación aplicada.....	48

4.2. MÉTODO DE INVESTIGACIÓN .....	48
4.2.1. Metodología de la investigación bibliográfica .....	48
4.2.2. Inductivo – deductivo.....	49
4.3. TÉCNICAS E INSTRUMENTOS.....	49
4.3.1. Técnica de la observación .....	49
4.4. Etapas de la Metodología:.....	50
4.5. Caso practico.....	50
4.6. Adquisición de datos.....	55
4.6.1. Conexión y configuración de analizador de red FLUKE 435 .....	55
4.6.2. Obtención de datos del analizador de red Fluke 435 .....	57
4.6.2.1. Transferencia de información del equipo fluke al software POWER LOG .....	57
4.7. Análisis e interpretación de datos obtenidos en el software Power Log.....	59
4.7.1. Visualización de datos en Power Log .....	59
4.7.2. Transferencia de datos desde Power log a Microsoft Excel.....	61
4.7.3. Clasificación y validación de datos en Excel .....	64
4.8. Selección de variables de entrada para el algoritmo .....	65
4.9. Validación de datos para el desarrollo del algoritmo.....	65
4.10. Programación en Matlab .....	66
4.11. Librerías utilizadas en el código de programación.....	66
4.11.1. Librería Datos=xlsread.....	66
4.11.2. Librería Objetivo=xlsread .....	66
4.11.3. Librería tansig, logsig.....	66
4.11.4. Librería trainparam. Epoch, max fail, min grade, mu (dec, inc).....	66
4.11.5. Librería divideparam. Trainratio, valratio, test ratio .....	67
4.11.6. Definición de librerías de la red neuroartificiales. ....	67

4.11.7. Librería hardlim y tansig .....	67
4.11.8. Purelin-Satlin.....	69
4.11.9. Librería tansig – logsig.....	70
4.12. Diagrama de flujo.....	74
5.1. Resultados obtenidos .....	76
5.1.1. Análisis de la demanda eléctrica diaria para el día lunes de cada mes .....	76
5.1.2. Análisis de la demanda eléctrica en la semana de validación .....	80
5.1.2.1. Lunes .....	80
5.1.2.2. Martes .....	81
5.1.2.3. Miércoles .....	82
5.1.2.4. Jueves .....	82
5.1.2.5. Viernes.....	83
5.1.2.6. Sábado .....	84
5.1.2.7. Domingo .....	84
5.2. Resultados obtenidos .....	85
5.2.1. Lunes .....	85
5.2.1.1. Perfil de carga curva objetivo vs curva predicha lunes .....	85
5.2.1.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho lunes.....	86
5.2.1.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho lunes .....	87
5.2.1.4. Predicción de demanda lunes .....	88
5.2.1.5. Error medio cuadrático RMSE lunes.....	89
5.2.1.6. Error de histograma lunes.....	90
5.2.1.7. Avance del entrenamiento de red lunes .....	90
5.2.1.8. Matriz de confusión lunes .....	91
5.2.2. Datos obtenidos martes. ....	92
5.2.2.1. Perfil de carga curva objetivo vs curva predicha martes .....	92

5.2.2.2.	Error porcentual entre perfil de carga objetivo vs perfil de carga predicho martes .....	93
5.2.2.3.	Diferencia entre perfil de carga objetivo vs perfil de carga predicho martes .....	94
5.2.2.4.	Predicción de demanda martes .....	95
5.2.2.5.	Matriz de confusión martes .....	95
5.2.3.	Datos obtenidos miércoles .....	97
5.2.3.1.	Perfil de carga curva objetivo vs curva predicha miércoles .....	97
5.2.3.2.	Error porcentual entre perfil de carga objetivo vs perfil de carga predicho miércoles ...	98
5.2.3.3.	Diferencia entre perfil de carga objetivo vs perfil de carga predicho miércoles .....	99
5.2.3.4.	Predicción de demanda miércoles .....	100
5.2.3.5.	Matriz de confusión miércoles .....	100
5.2.4.	Datos obtenidos jueves .....	102
5.2.4.1.	Perfil de carga curva objetivo vs curva predicha jueves .....	102
5.2.4.2.	Error porcentual entre perfil de carga objetivo vs perfil de carga predicho jueves .....	103
5.2.4.3.	Diferencia entre perfil de carga objetivo vs perfil de carga predicho jueves .....	104
5.2.4.4.	Predicción de demanda jueves .....	105
5.2.4.5.	Matriz de confusión jueves .....	105
5.2.5.	Datos obtenidos viernes .....	107
5.2.5.1.	Perfil de carga curva objetivo vs curva predicha viernes .....	107
5.2.5.2.	Error porcentual entre perfil de carga objetivo vs perfil de carga predicho viernes .....	108
5.2.5.3.	Diferencia entre perfil de carga objetivo vs perfil de carga predicho viernes .....	108
5.2.5.4.	Predicción de demanda viernes .....	109
5.2.5.5.	Matriz de confusión viernes .....	110
5.2.6.	Datos obtenidos sábado .....	112
5.2.6.1.	Perfil de carga curva objetivo vs curva predicha sábado .....	112
5.2.6.2.	Error porcentual entre perfil de carga objetivo vs perfil de carga predicho sábado .....	113
5.2.6.3.	Diferencia entre perfil de carga objetivo vs perfil de carga predicho sábado .....	113

5.2.6.4. Predicción de demanda sábado.....	114
5.2.6.5. Matriz de confusión sábado.....	115
5.2.7. Datos obtenidos domingo.....	117
5.2.7.1. Perfil de carga curva objetivo vs curva predicha domingo .....	117
5.2.7.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho domingo ...	118
5.2.7.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho domingo .....	118
5.2.7.4. Predicción de demanda domingo.....	119
5.2.7.5. Matriz de confusión domingo.....	120
6.1. Conclusiones .....	123
6.2. Recomendaciones .....	124
7. BIBLIOGRAFÍA.....	125

## INDICE DE FIGURAS

<b>Figura 3. 1:</b> Tipos de demanda eléctrica [3]. .....	10
<b>Figura 3. 2:</b> Incremento del consumo de energía eléctrica en Ecuador a largo plazo. ....	11
<b>Figura 3. 3:</b> Analizador de calidad eléctrica y energía. ....	16
<b>Figura 3. 4:</b> Modelo de red perceptron Multicapa. ....	19
<b>Figura 3. 5:</b> Parámetros que indican en la predicción de consumo [24]......	20
<b>Figura 3. 6:</b> Categorización de la variable de estudio para la predicción de consumo de energía eléctrica [25]. ....	22
<b>Figura 3. 7:</b> Clasificación relacionado a los métodos de inteligencia artificial empleados en la predicción de consumo de energía eléctrica [24]......	25
<b>Figura 3. 8:</b> Estructura general de una neurona biológica [27]......	26
<b>Figura 3. 9:</b> Estructura general de una red neuronal artificial [30]......	27
<b>Figura 3. 10:</b> Esquema de una red neuronal artificial [30]. ....	29
<b>Figura 3. 11:</b> Red multicapa aplicando la propagación hacia adelante [24]......	32
<b>Figura 3. 12:</b> Red multicapa aplicando la propagación hacia atrás [24]......	32
<b>Figura 3. 13:</b> Clasificación de algoritmos para el uso de redes neuronales artificiales [34]. ....	37
<b>Figura 3. 14:</b> Matriz de confusión Binaria.....	41
<b>Figura 3. 15:</b> Icono de Power Log [9]......	42
<b>Figura 3. 16:</b> Visualización de datos en Power log. ....	44
<b>Figura 3. 17:</b> Icono de Matlab.....	44
<b>Figura 3. 18:</b> Grafica de la función peaks.....	46
<b>Figura 3. 19:</b> Grafica de la función pseudocolor (Peaks). ....	46
<b>Figura 3. 20:</b> Interfaz gráfica en Guide para conversión de unidades. ....	47
<b>Figura 5. 1:</b> Curva de consumo del día lunes para los meses de análisis.....	76
<b>Figura 5. 2:</b> Curva de consumo del día martes para los meses de análisis. ....	77

<b>Figura 5. 3:</b> Curva de consumo del día miércoles para los meses de análisis. ....	77
<b>Figura 5. 4:</b> Curva de consumo del día jueves para los meses de análisis.....	78
<b>Figura 5. 5:</b> Curva de consumo del día viernes para los meses de análisis. ....	79
<b>Figura 5. 6:</b> Curva de consumo del día sábado para los meses de análisis.....	79
<b>Figura 5. 7:</b> Curva de consumo del día domingo para los meses de análisis.....	80
<b>Figura 5. 8:</b> Consumo de energía eléctrica lunes en el bloque "B" de la UTC.....	81
<b>Figura 5. 9:</b> Consumo de energía eléctrica martes en el bloque "B" de la UTC.....	81
<b>Figura 5. 10:</b> Consumo de energía eléctrica miércoles en el bloque "B" de la UTC.....	82
<b>Figura 5. 11:</b> Consumo de energía eléctrica jueves en el bloque "B" de la UTC. ....	83
<b>Figura 5. 12:</b> Consumo de energía eléctrica viernes en el bloque "B" de la UTC.....	83
<b>Figura 5. 13:</b> Consumo de energía eléctrica sábado en el bloque "B" de la UTC. ....	84
<b>Figura 5. 14:</b> Consumo de energía eléctrica domingo en el bloque "B" de la UTC. ....	85
<b>Figura 5. 15:</b> Comparación de demanda entre perfil de carga actual vs predicha lunes.....	86
<b>Figura 5. 16:</b> Error porcentual existente entre demanda actual y demanda predicha lunes.....	87
<b>Figura 5. 17:</b> Diferencia existente entre demanda actual y demanda predicha lunes .....	88
<b>Figura 5. 18:</b> Predicción de demanda para el día lunes .....	89
<b>Figura 5. 19:</b> Error medio cuadrático para el día lunes.....	89
<b>Figura 5. 20:</b> Histograma de error para el día jueves.....	90
<b>Figura 5. 21:</b> Entrenamiento de la herramienta tecnológica. ....	90
<b>Figura 5. 22:</b> Matriz de confusión del día lunes. ....	91
<b>Figura 5. 23:</b> Métrica obtenida día lunes .....	92
<b>Figura 5. 24:</b> Comparación de demanda entre perfil de carga actual vs predicha martes .....	93
<b>Figura 5. 25:</b> Error porcentual existente entre demanda actual y demanda predicha martes .....	94
<b>Figura 5. 26:</b> Diferencia existente entre demanda actual y demanda predicha martes .....	94
<b>Figura 5. 27:</b> Predicción de demanda para el día martes .....	95



<b>Figura 5. 28:</b> Matriz de confusión del día martes. ....	96
<b>Figura 5. 29:</b> Métricas obtenidas día martes. ....	97
<b>Figura 5. 30:</b> Comparación de demanda entre perfil de carga actual vs predicha miércoles.....	98
<b>Figura 5. 31:</b> Error porcentual existente entre demanda actual y demanda predicha miércoles.....	99
<b>Figura 5. 32:</b> Diferencia existente entre demanda actual y demanda predicha miércoles .....	99
<b>Figura 5. 33:</b> Predicción de demanda para el día miércoles .....	100
<b>Figura 5. 34:</b> Matriz de confusión del día miércoles. ....	101
<b>Figura 5. 35:</b> Métricas obtenidas día miércoles. ....	102
<b>Figura 5. 36:</b> Comparación de demanda entre perfil de carga actual vs predicha jueves .....	103
<b>Figura 5. 37:</b> Error porcentual existente entre demanda actual y demanda predicha jueves.....	104
<b>Figura 5. 38:</b> Diferencia existente entre demanda actual y demanda predicha jueves .....	104
<b>Figura 5. 39:</b> Predicción de demanda para el día jueves.....	105
<b>Figura 5. 40:</b> Matriz de confusión del día jueves.....	106
<b>Figura 5. 41:</b> Métricas obtenidas día jueves. ....	106
<b>Figura 5. 42:</b> Comparación de demanda entre perfil de carga actual vs predicha viernes.....	107
<b>Figura 5. 43:</b> Error porcentual existente entre demanda actual y demanda predicha viernes.....	108
<b>Figura 5. 44:</b> Diferencia existente entre demanda actual y demanda predicha viernes .....	109
<b>Figura 5. 45:</b> Predicción de demanda para el día viernes .....	110
<b>Figura 5. 46:</b> Matriz de confusión del día viernes .....	111
<b>Figura 5. 47:</b> Métricas obtenidas para el día viernes .....	111
<b>Figura 5. 48:</b> Comparación de demanda entre perfil de carga actual vs predicha sábado .....	112
<b>Figura 5. 49:</b> Error porcentual existente entre demanda actual y demanda predicha sábado .....	113
<b>Figura 5. 50:</b> Diferencia existente entre demanda actual y demanda predicha sábado .....	114
<b>Figura 5. 51:</b> Predicción de demanda para el día sábado.....	115
<b>Figura 5. 52:</b> Matriz de confusión del día sábado.....	116

<b>Figura 5. 53:</b> Métricas obtenidas día sábado. ....	116
<b>Figura 5. 54:</b> Comparación de demanda entre perfil de carga actual vs predicha día domingo .....	117
<b>Figura 5. 55:</b> Error porcentual existente entre demanda actual y demanda predicha día domingo	118
<b>Figura 5. 56:</b> Diferencia existente entre demanda actual y demanda predicha día domingo .....	119
<b>Figura 5. 57:</b> Predicción de demanda para el día domingo.....	120
<b>Figura 5. 58:</b> Matriz de confusión del día domingo.....	121
<b>Figura 5. 59:</b> Métrica obtenida del día sábado.....	122

## INDICE DE TABLAS

<b>Tabla 2.1:</b> Sistema de tareas en relación a los objetivos planteados.....	5
<b>Tabla 3. 1:</b> Consumidores según el pliego tarifario [17]. .....	12
<b>Tabla 3. 2:</b> Categorías Tarifarias según el Pliego Tarifario [17]. .....	13
<b>Tabla 3. 3:</b> Factor de carga según el porcentaje [19]. .....	15
<b>Tabla 3. 4:</b> Técnicas de inteligencia artificial [3]. .....	23
<b>Tabla 3. 5:</b> Funciones de activación para la aplicación de redes neuronales artificiales [23]. .....	33
<b>Tabla 4. 1:</b> Consumo Eléctrico del mes de mayo de los 3 campus de la UTC. ....	51
<b>Tabla 4. 2:</b> Coordenadas de la Universidad Técnica de Cotopaxi – La Matriz. ....	51
<b>Tabla 4. 3:</b> Variables seleccionadas para el proyecto. ....	65
<b>Tabla 4. 4:</b> Tabla de comparación de errores para diferentes funciones.....	73

# UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

**TITULO: “PREDICCIÓN DE LA DEMANDA ELÉCTRICA DEL EDIFICIO DE UNA INSTITUCIÓN DE EDUCACIÓN SUPERIOR BASADO EN REDES NEURONALES ARTIFICIALES”**

**Autor/es:** Unapucha Quintuña Byron Mauricio

## **RESUMEN**

En el presente trabajo de tesis brinda una solución a la predicción de la demanda eléctrica a corto plazo para el bloque “B” de la Universidad Técnica de Cotopaxi basado en el uso de redes neuronales artificiales, teniendo en cuenta que dicha predicción ha sido 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 algoritmo de programación, con esta idea y en base a esta premisa el objetivo principal de la investigación fue desarrollar una herramienta computación capaz de realizar esta actividad a partir de una base de datos, los cuales fueron recopilados mediante un analizador de red Fluke 435 conectados al tablero de distribución principal encargado de alimentar a las cargas del bloque “B” dicho equipo se mantuvo conectado durante un periodo de tiempo considerable que comprende los meses de junio, julio, agosto, septiembre, octubre, noviembre y diciembre del año 2022, se procedió a realizar un filtrado de los datos obtenidos para utilizar únicamente los que contienen valores de consumo eléctrico, se plantearon las variables de entrada que son: días, energía eléctrica (Wh), para elaborar los diferentes casos de estudio con diversas condiciones con el propósito de alcanzar un acertado modelo de red neuronal. Una vez comprendidas las variables del modelo, los datos se dividieron en tres grupos: entrenamiento, prueba y validación, para que el algoritmo desarrolle los entrenamientos necesarios se utilizó las librerías que ofrece Matlab. A partir de los datos del consumo de energía eléctrica en estos siete meses del año 2022, el análisis diario y semanal realizados para predecir la demanda de energía necesaria del día a la siguiente semana, se concluye que el modelo planteado, presenta el mayor ajuste al comportamiento de la serie de datos con un error porcentual inferior al 5% de esta forma se obtuvo una predecir la demanda de energía eléctrica acertada.

**Palabras clave:** *Demanda de energía eléctrica, red neuronal, Blackpropagation, log-sig tan-sig.*

# COTOPAXI TECHNICAL UNIVERSITY

ENGINEERING AND APPLIED SCIENCES FACULTY

**TOPIC: "PREDICTION OF THE ELECTRICAL DEMAND OF A HIGHER EDUCATION INSTITUTION BUILDING BASED ON ARTIFICIAL NEURAL NETWORKS".**

**Author/s:** Unapucha Quintuña Byron Mauricio

## **ABSTRACT**

In the present thesis, a solution is provided for the short-term prediction of electric demand for Block "B" at the Technical University of Cotopaxi, based on the use of artificial neural networks. It is worth noting that demand prediction has been a phenomenon that has generated curiosity in humans. However, to achieve a projection of a future event, a detailed data analysis is required to predict subsequent events using a programming algorithm. With this idea and based on this premise, the main objective of the research was to develop a computer tool capable of performing this activity based on a database. The data were collected using a Fluke 435 power quality analyzer connected to the main distribution board responsible for powering the loads of Block "B". This equipment was connected for a considerable period of time, covering the months of June, July, August, September, October, November, and December of 2022. The obtained data were filtered to use only those containing electrical consumption values. The input variables, which were date and energy consumed, were proposed to develop different case studies with various conditions in order to achieve an accurate neural network model. Once the model variables were understood, the data were divided into three groups: training, testing, and validation. Matlab libraries were used to develop the necessary training for the algorithm. Based on the data of the electric energy consumption in these seven months of 2022, the daily and weekly analyses performed to predict the necessary energy demand of the following week, it is concluded that the proposed model presents the best fit to the behavior of the data series with a percentage error of less than 5%, thus obtaining an accurate prediction of electric energy demand.

**Keywords:** *Electric power demand, neural network, Blackpropagation, log-sig tan-sig.*

## *AVAL DE TRADUCCIÓN*

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

La traducción del resumen al idioma inglés del proyecto de investigación cuyo título versa: **“PREDICCIÓN DE LA DEMANDA ELÉCTRICA DEL EDIFICIO DE UNA INSTITUCIÓN DE EDUCACIÓN SUPERIOR BASADO EN REDES NEURONALES ARTIFICIALES”** presentado por: **Unapucha Quintuña Byron Mauricio**, egresado de la Carrera de: **Ingeniería Eléctrica**, perteneciente a la **Facultad De Ciencias De La Ingeniería Y Aplicadas**, lo realizó 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, marzo del 2023

Atentamente,

.....

Nombre del docente

**DOCENTE UTC**

**C.C**

## 1. INFORMACIÓN GENERAL

**Título:** Predicción de la demanda eléctrica del edificio de una institución de educación superior basado en redes neuronales artificiales

**Fecha de inicio:** abril de 2022

**Fecha de finalización:** marzo de 2023

**Lugar de ejecución:** Provincia de Cotopaxi, cantón Latacunga, Universidad Técnica de Cotopaxi

**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**

Nombres: Byron Mauricio

Apellidos: Unapucha Quintuña

Cédula de Ciudadanía: 1722194360

E-mail: byron.unapucha0@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**

La predicción de la demanda eléctrica es muy importante a la hora de la planificación para generar energía eléctrica, además que contribuye un factor importante para la toma de decisiones en empresas, comercios y entidades publico privadas, algunas de las aplicaciones en las que puede contribuir dicha predicción son: la mejora de la eficiencia energética; la elaboración de estrategias que permitan utilizar el suministro eléctrico de manera prudente.

En el presente trabajo de investigación se propone realizar la predicción de la demanda eléctrica para la Universidad Técnica de Cotopaxi, bloque “B” mediante el uso de redes neuronales artificiales, mediante el uso de datos de consumo eléctrico obtenidos a través de un analizador de red FLUKE 435.

Se inicia con una investigación bibliográfica para determinar conceptos básicos y definiciones de una red neuronal artificial, distribución probabilística, curva de probabilidad, tipos de modelos matemáticos etc.

Una vez determinado dichas definiciones, con el uso del software Matlab se simplifica ecuaciones diferenciales mediante un código de programación que toma datos obtenidos de consumo de un analizador de red Fluke 435, lo cual permita planear y tomar decisiones a corto y mediano plazo.

Finalmente se presentan los resultados obtenidos tras el desarrollo integral de cada fase comprendida, para evidenciar el cumplimiento de los objetivos planteados, además que se presentan las respectivas conclusiones y recomendaciones que surgieron durante la ejecución del proyecto.

### **2.1.EL PROBLEMA**

#### **2.1.1. Situación Problémica**

Actualmente el bloque B de la Universidad Técnica de Cotopaxi no cuenta con un análisis de la demanda actual existente ni la variación de la misma con respecto al tiempo, debido a la complejidad que resulta la obtención de estos datos, la única manera de poder obtenerlos es mediante de una red neuronal artificial, la cual tiene la capacidad de resolver ecuaciones algebraicas diferenciales no lineales, que son complejas y lleva mucho tiempo calcularlas, siendo así difícil cumplir con los requisitos del cálculo.

#### **2.1.2. Formulación del problema**

¿Es posible que una red neuronal artificial permita predecir el consumo de energía eléctrica de la Universidad Técnica De Cotopaxi Bloque B?

## 2.2. BENEFICIARIOS

### 2.2.1. Directos

Los beneficiarios directos de la investigación son todos los miembros que conforman la comunidad Universitaria debido a que el desarrollo de dicha investigación ayudará a determinar del consumo de energía eléctrica.

### 2.2.2. Indirectos

Estudiantes e investigadores que enfocan su estudio en el estudio de redes neuronales artificiales, usados la predicción del consumo de energía eléctrica.

## 2.3. OBJETO Y CAMPO DE ACCIÓN

- **Objeto:** Redes neuro-artificiales enfocadas a la predicción de energía eléctrica.
- **Campo de acción:** 330000 ciencias Tecnológicas / 3306 Ingeniería y Tecnología Eléctricas / 330602 Aplicaciones Eléctricas.

## 2.4. JUSTIFICACIÓN

La predicción del consumo energético es una de las funciones más relevantes para realizar la planificación en los sistemas eléctricos de potencia, debido a que gracias a estos se puede determinar los intervalos de tiempo en los cuales se necesita generar mayor cantidad de energía, además de realizar la expansión de redes eléctricas de distribución.

En la actualidad, las empresas distribuidoras se encargan de realizar el análisis de la predicción de la demanda eléctrica, siendo de gran importancia para los sistemas existentes como para el diseño de nuevos sistemas, garantizando un estado de operación adecuado. Dentro de dicho estudio se analiza el comportamiento de los sistemas de distribución, de igual manera para las empresas y entidades de gran consumo energético el poder predecir la demanda de consumo es muy importante pues gracias a esto pueden planificar el uso mesurado y una disminución de la factura de consumo eléctrico.

Tomando en cuenta a estas razones se ve la necesidad de realizar una predicción de la demanda eléctrica del bloque B en la Universidad técnica de Cotopaxi basándose en redes neuronales artificiales, así como la utilización de una herramienta de programación accesible como lo es el software MATLAB, a partir del cual se obtendrá un algoritmo, para la resolución de la predicción de la demanda eléctrica a corto plazo en sistemas de distribución, utilizando datos a partir de la demanda que nos proporcionará un analizador de red FLUKE 435 conectado al sistema real de la institución.

## 2.5.HIPOTESIS

¿El desarrollo de una red neuronal artificial, permitirá predecir el consumo de energía eléctrica en el Bloque “B” de la Universidad Técnica De Cotopaxi?

## 2.6. OBJETIVOS

### 2.6.1. General

Desarrollar una herramienta computacional basada en redes neuronales artificiales mediante la medición de parámetros eléctricos dando como resultado la predicción del consumo de energía eléctrica en el bloque “B” de la Universidad Técnica de Cotopaxi.

### 2.6.2. Específicos

- Recopilar información sobre la predicción de demanda eléctrica utilizando redes neuronales a corto plazo.
- Determinar el perfil de consumo energético del bloque “B” de la Universidad Técnica de Cotopaxi.
- Entrenar la herramienta computacional, para predecir el consumo energético.
- Analizar los resultados obtenidos de la herramienta computacional para el pronóstico de demanda.

## 2.7.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
Recopilar información sobre la predicción de demanda eléctrica utilizando redes neuronales a corto plazo.	<ul style="list-style-type: none"> <li>• Buscar definiciones de los principales temas y subtemas referentes al consumo de energía eléctrica.</li> <li>• Revisión de fuentes bibliográficas, artículos científicos que aporten contenido importante al estudio de la predicción de consumo de energía eléctrica utilizando redes neuronales artificiales.</li> </ul>	<ul style="list-style-type: none"> <li>• Comprensión teórica, sobre parámetros en el consumo de energía eléctrica.</li> <li>• Fundamentación científica, teórica técnica para sustentar el desarrollo del presente proyecto.</li> <li>• Comprender la aplicación de redes neuronales en el</li> </ul>	<ul style="list-style-type: none"> <li>• Libros</li> <li>• Tesis</li> <li>• Artículos científicos.</li> <li>• Trabajos</li> <li>• Académicos</li> <li>• Revistas Científicas</li> <li>• Normativas</li> <li>• Informes técnicos</li> </ul>

		correcto diseño de la herramienta computacional de predicción del consumo de energía eléctrica.	
Determinar el perfil de consumo energético del bloque “B” de la Universidad Técnica de Cotopaxi.	<ul style="list-style-type: none"> <li>• Recopilación de datos referentes al consumo eléctrico en la UNIVERSIDAD TECNICA DE COTOPAXI BLOQUE “B” mediante el analizador de red.</li> <li>• Análisis y comprensión de la base de datos.</li> <li>• Reprocesamiento de la base de datos.</li> </ul>	<ul style="list-style-type: none"> <li>• Obtención de datos de campo, actual sobre el consumo eléctrico del bloque “B”.</li> <li>• Graficas del consumo actual en Excel.</li> <li>• Tablas de resultados de las predicciones del consumo futuro en formato Excel.</li> </ul>	<ul style="list-style-type: none"> <li>• Analizador de redes</li> <li>• Históricos obtenidos</li> <li>• Micros Office</li> </ul>
Entrenar la herramienta computacional, para predecir el consumo energético.	<ul style="list-style-type: none"> <li>• Programación de la red neuronal en lenguaje de programación Matlab.</li> <li>• Validación de los valores de potencia obtenidos en del analizador de red, con los obtenidos con la herramienta computacional.</li> </ul>	<ul style="list-style-type: none"> <li>• Código de programación capaz de predecir el consumo de energía eléctrica en corto plazo a partir de datos obtenidos.</li> </ul>	<ul style="list-style-type: none"> <li>• Software de ingeniería Matlab.</li> </ul>
Analizar los resultados obtenidos de la herramienta computacional para el pronóstico de demanda.	<ul style="list-style-type: none"> <li>• Pruebas y correcciones a la herramienta computacional</li> </ul>	<ul style="list-style-type: none"> <li>• Herramienta computacional capaz de predecir el consumo energético con un valor de error mínimo.</li> </ul>	<ul style="list-style-type: none"> <li>• Computador.</li> <li>• Tratamiento de datos.</li> </ul>

### 3. FUNDAMENTACIÓN TEÓRICA

#### 3.1. ANTECEDENTES DE LA INVESTIGACIÓN

Existen diferentes algoritmos para la predicción del consumo de energía eléctrica, mediante una búsqueda bibliográfica se identificaron varios, entre los más destacables están proyectos de investigación como:

El desarrollado en la universidad Cienfuegos en dónde.

Según el autor [1] La investigación desarrollada, tuvo como objetivo general conocer el comportamiento matemático que existe entre el consumo energético y las variables que lo afectan, para poder escoger un modelo matemático que permita predecir futuros consumos de la energía eléctrica en la Universidad de Cienfuegos, sede “Carlos Rafael Rodríguez”. A partir del diagnóstico efectuado se obtienen las principales debilidades en cuanto a la gestión energética por lo que se realizó un estudio estadístico mediante el análisis de componentes principales, la regresión lineal y el diseño de experimentos a una serie de variables que afectan el consumo energético en la Universidad de Cienfuegos. Entre los principales resultados de este estudio se encuentra conocer el comportamiento de dichas variables y el consumo energético, además de finalmente poder escoger un modelo que permita predecir futuros consumos.

En el documento de tesis presentado en el año 2021 con título “desarrollo de un modelo matemático de optimización para el despacho económico mediante penetración de energía renovable no convencional”, según los autores [2] mencionan que hoy en día en los sistemas de potencia se está implementado el uso de Energías Renovables no Convencionales (ERNC) tales como la solar y la eólica con el propósito de reducir las emisiones de CO<sub>2</sub> producidas al generar energía eléctrica a través de plantas a base de combustibles fósiles, en donde se evidencia que una de las desventajas principales al usar este tipo de energía, es la inestabilidad de fuentes de energía tanto como viento o radiación solar, lo que hace difícil pronosticar anticipadamente un despacho económico óptimo, los autores realizan el desarrollo de un modelo matemático para la generación óptima de potencia, con el fin de minimizar costos operativos y el consumo de combustible fósil (diésel) en una Microred aislada.

Según [3] en su investigación titulada “Predicción de la demanda de energía eléctrica que se produce en la central hidroeléctrica Illuchi 2”, modelan matemáticamente mediante el software de ingeniería PYTHON un programa que permite determinar la predicción de la demanda de energía eléctrica utilizando redes neuronales artificiales en ELEPCO S.A. la cual fue realizada mediante regresión

lineal simple, esto para evidenciar la bondad de la RNA para la aplicación, obteniendo como resultados luego de utilizar el 50% de la 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, 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.

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.

Finalmente; [1] en su investigación realizan el diseño de una red neuronal capaz de predecir el consumo eléctrico para la universidad de Piura mediante redes Neuronales LSTM Y TCN, partiendo desde la caracterización de la demanda eléctrica en dos edificios el primero perteneciente a la facultad de derecho y el edificio E de dicha institución, además para el estudio se plantearon cuatro casos distintos por cada modelo, comparando el desempeño entre casos y, posteriormente, se eligió el modelo más preciso para ser implementado en la interfaz gráfica. En este caso, fue el modelo TCN el que tuvo un mejor desempeño, con un MAPE de 8.35%.

Además, desarrollan una interfaz gráfica que permite al usuario obtener la predicción de la demanda eléctrica de un día entero, en una resolución treinta minutos, a partir de un archivo con datos del día anterior. De esta investigación se evidencia la importancia de la implementación de la inteligencia artificial en la industria eléctrica y sus grandes beneficios.

## **3.2.MARCO TEÓRICO**

Para desarrollar el trabajo de investigación y brindar una solución al problema de inexistencia de una red neuronal artificial que permita determinar el consumo de energía eléctrica, es indispensable recopilar información necesaria para conocer diferentes conceptos del consumo de energía eléctrica, redes neuronales artificiales, machine learning, deep learning, tipos de aprendizajes.

### **3.2.1. Conceptos de electricidad**

#### **3.2.1.1. Sistema eléctrico**

Es una serie de elementos o componentes eléctricos o electrónicos, tales como resistencias, inductancias, condensadores, fuentes, y/o dispositivos electrónicos semiconductores, conectados eléctricamente entre sí con el propósito de generar, transportar o modificar señales electrónicas o

eléctricas, generalmente dichos elementos son cables, apliques, tomacorrientes, etc. Que se los encuentra en el diario vivir [1].

### **3.2.1.2. Concepto de carga en un sistema eléctrico**

La carga de un sistema eléctrico es la parte terminal del sistema que convierte la energía eléctrica a otra forma de energía, ejemplo: un motor eléctrico convierte la energía eléctrica en mecánica, además se incluye a todos los artefactos que requieren de energía eléctrica para funcionar o realizar un trabajo.

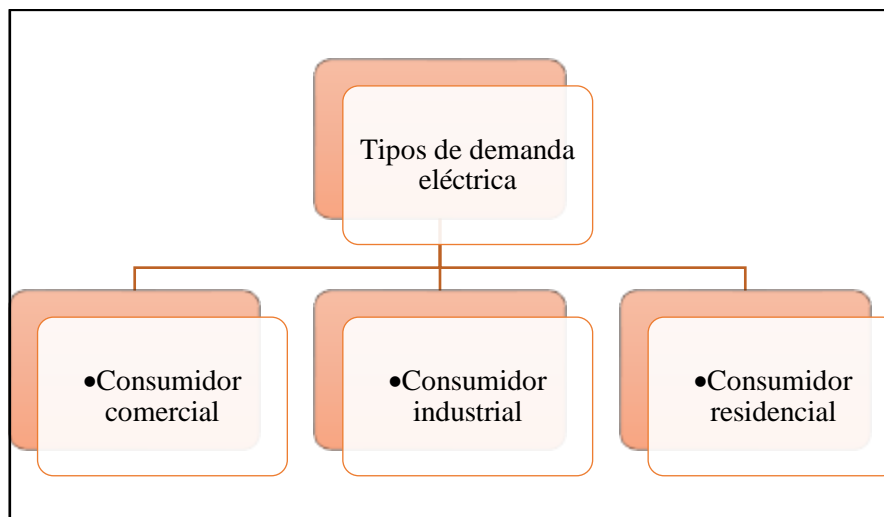
La suma de las intensidades o potencias de placa de todos los artefactos de consumo dependientes del sistema, o de una parte de él, constituyen su carga conectada y representa la máxima demanda posible de una instalación [2].

### **3.2.1.3. Concepto de la demanda de energía eléctrica**

Se entiende por demanda eléctrica a la cantidad de electricidad en KWH que una serie de consumidores necesitan para abastecer sus necesidades. Por tanto, la demanda eléctrica nacional es el resultado de la suma de todas las cargas de electricidad necesarias para dar suministro a todos los consumidores del territorio nacional: industrias, empresas, oficinas, comercios, hogares, centros públicos, alumbrado [14].

### **3.2.1.4. 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. 1:** Tipos de demanda eléctrica [3].

### **3.2.1.5.Demanda eléctrica a largo plazo (Anual)**

La demanda eléctrica anual está íntimamente relacionada con el desarrollo de la actividad económica del país y con la producción de bienes y servicios. Obviando los efectos de la temperatura y la laboralidad, la serie de la demanda es un indicador de la marcha de la economía y de su tendencia a largo plazo.

En el periodo 2008-2018, el Producto Interno Bruto Nacional experimentó un crecimiento de 3.4% (a valores constantes del 2007). En la Figura 3-5, se observa que en el periodo de análisis hay variabilidad con dos picos marcados en los años 2008 y 2011 con tasas de crecimiento del PIB de 6,4% y 7,9% respectivamente; así también se presentaron crecimientos menores en los años 2009, 2015, y 2016 con valores de 0,6%, 0,25% y -1.6% respectivamente; el resultado negativo obtenido en el 2016 fue atribuido a la crisis económica generada por la caída de los precios internacionales del petróleo [3].





**Figura 3. 2:** Incremento del consumo de energía eléctrica en Ecuador a largo plazo.

### 3.2.2. Consumo de Energía Eléctrica

El consumo de energía eléctrica es la cantidad de energía utilizada. El término hace referencia al conjunto de la energía eléctrica empleada para distintos usos, como por ejemplo la fabricación industrial, mover un vehículo eléctrico, o el uso de dispositivos electrónicos. La electricidad consumida se mide en el punto de acceso en las instalaciones del usuario final a través de los contadores eléctricos inteligentes. Consumir energía es necesario para el desarrollo económico y social actual. Gracias a la electricidad, se permite la producción industrial, el desarrollo de edificios funcionales, mantener el sector servicios, recargar vehículos eléctricos, y disfrutar de las funciones de todos los electrodomésticos y dispositivos electrónicos que nos rodean [16].

#### 3.2.2.1. Pliego Tarifario

Documento emitido por la ARCONEL, que contiene la estructura, nivel y régimen tarifario para el servicio público de energía eléctrica para la aplicación de la distribuidora y cumple con los principios tarifarios establecidos en la normativa vigente [17].

#### 3.2.2.2. Tipos de consumidores de Energía Eléctrica

Dentro del sistema eléctrico ecuatoriano se encuentra el pliego tarifario en el cual se han clasificado a los usuarios en varios tipos de consumidores, actualmente existen cuatro tipos los mismos están ligados a diferentes sistemas de tarifas dependiendo del grupo al que pertenezcan, como se observa en la tabla 3.3.

**Tabla 3. 1:** Consumidores según el pliego tarifario [17].

<b>Tipos de consumidores según el pliego tarifario</b>	
<b>Consumidor regulado</b>	Persona natural o jurídica que mantiene un contrato de suministro con la empresa eléctrica distribuidora y que se beneficia con la prestación del servicio público de energía eléctrica.
<b>Consumidor regulado comercial</b>	Persona natural o jurídica, pública o privada, que utiliza los servicios de energía eléctrica para fines de negocio, actividades profesionales o cualquier otra actividad con fines de lucro.
<b>Consumidor regulado industrial</b>	Persona natural o jurídica, pública o privada, que utiliza los servicios de energía eléctrica para la elaboración o transformación de productos. También se debe considerar dentro de esta definición a los agroindustriales, en los cuales existe una transformación de productos de la agricultura, ganadería, riqueza forestal y pesca.
<b>Consumidor regulado residencial</b>	Persona natural o jurídica, pública o privada, que utiliza los servicios de energía eléctrica exclusivamente, al uso doméstico, es decir, en la residencia de la unidad familiar independientemente del tamaño de la carga conectada. Se incluye a los consumidores de escasos recursos económicos y bajos consumos que tiene integrada a su residencia una pequeña actividad comercial o artesanal; para lo cual, es responsabilidad de la distribuidora evaluar las características de consumo de energía eléctrica, y de ser el caso, recomendar la separación de los respectivos circuitos con su sistema de medición independiente y a la tarifa correspondiente.

### 3.2.2.3. Categorías tarifarias según el Pliego Tarifario

El servicio de energía eléctrica tiene dos categorías tarifarias las cuales dependen del consumidor: residencial y general; La determinación de la categoría tarifaria de los consumidores es responsabilidad de la distribuidora. La misma que evalúa las características de la carga y el uso de energía declarada por el consumidor regulado [17].

**Tabla 3. 2:** Categorías Tarifarias según el Pliego Tarifario [17].

<b>Categorías Tarifarias según el pliego Tarifario</b>	
<b>Categoría Residencial</b>	<b>Categoría General</b>
<p><b>Corresponde al servicio público de energía eléctrica destinado exclusivamente al uso doméstico de los consumidores; es decir, en la residencia de la unidad familiar independientemente del tamaño de la carga conectada.</b></p> <p><b>En esta categoría se incluyen a los consumidores de bajos consumos y de escasos recursos económicos, que tienen integrada a su residencia una pequeña actividad comercial o artesanal. Es responsabilidad de la distribuidora evaluar las características del consumo de energía eléctrica; y de ser el caso, recomendar la separación de los consumos en circuitos independientes con su propio sistema de medición y a la tarifa correspondiente.</b></p>	<p>Se establece que el servicio público de energía eléctrica es destinado por los consumidores en actividades diferentes a la categoría residencial y básicamente comprende el comercio, la industria y la prestación de servicios públicos y privados. Se consideran dentro de esta categoría, entre otros, los siguientes:</p> <ol style="list-style-type: none"> <li>a) Locales y establecimientos comerciales públicos o privados: tiendas, almacenes, salas de cine o teatro, restaurantes, hoteles y afines, plantas de radio, televisión y cualquier otro servicio de telecomunicaciones; Clínicas y hospitales privados; Instituciones educativas privadas; Vallas publicitarias. Organismos internacionales, embajadas, legaciones y consulados; Asociaciones civiles y entidades con o sin fines de lucro; Cámaras de comercio e industria tanto nacionales como extranjeras.</li> <li>b) Locales y establecimientos industriales públicos o privados, destinados a la elaboración o transformación de productos por medio de cualquier proceso industrial y sus oficinas administrativas.</li> <li>c) Instalaciones de Bombeo de Agua (incluye oficinas administrativas y guardiana).</li> <li>d) Entidades de Asistencia Social.</li> <li>e) Entidades de Beneficio Público.</li> <li>f) Entidades Oficiales (del sector público).</li> <li>g) Entidades Oficiales (del sector público).</li> <li>h) Culto Religioso.</li> <li>i) Servicio Comunitario (Servicio General).</li> <li>j) Abonado Especial.</li> <li>k) Y los demás que no estén considerados en la Categoría Residencial.</li> </ol>

### 3.2.3. Relación entre consumo eléctrico y demanda eléctrica

Las tarifas que se cobran por el consumo de electricidad se conforman por varios elementos, siendo los dos principales la energía eléctrica y la demanda. Por lo tanto, la reducción del monto a pagar en

el recibo de luz implica más que solamente una disminución en el consumo de energía eléctrica. El concepto del cobro por la demanda juega un papel fundamental en la facturación, por lo que es importante comprenderlo para poder así reducir efectivamente los costos por el uso de la electricidad. La razón entre el Consumo y Demanda es conocida como factor de carga y su valor nos indica el porcentaje de energía utilizada respecto a la demanda máxima de energía del centro de carga en el periodo de facturación. [18].

#### **3.2.4. Factor de Carga**

El factor de carga es la relación entre el consumo durante un periodo de tiempo determinado y el consumo que habría resultado de la utilización continua de la potencia máxima contratada durante ese período. Fuera del plano técnico, el Factor de Carga es un número que nos indica el porcentaje de utilización de la potencia contratada durante un mes o un año.

Un Factor de Carga muy bajo, por ejemplo, indica que es posible que tengamos contratada una potencia excesivamente alta para nuestro consumo, y que es posible que consigamos ahorrar en la factura si bajamos la potencia contratada. Antes de hacer ningún cambio hay que analizar con mucho detenimiento los hábitos de consumo ya que quizás la potencia sobredimensionada sea necesaria si solemos enchufar a la vez la nevera, lavadora, el termo eléctrico, el televisor, el aire acondicionado y muchas luces. En este caso y aunque sea por periodos cortos sí que se necesita sobredimensionar la potencia, aunque su uso sea esporádico.

Por el contrario, un Factor de Carga muy alto nos puede indicar que es posible que sobrepasemos la potencia contratada en repetidos momentos puntuales, lo que en algunos casos puede ser penalizado si carecemos de ICP (Interruptor de Control de Potencia). En este caso, sería necesario aumentar la potencia contratada, y es posible que nuestra factura eléctrica disminuya si cambiamos nuestra tarifa de acceso [19]

**Tabla 3. 3:** Factor de carga según el porcentaje [19].

Factor de carga	Uso de la Potencia concentrada	Recomendaciones
0 – 5%	Muy baja	<ul style="list-style-type: none"> <li>• Posiblemente exista demasiada potencia contratada.</li> <li>• Es posible que se obtenga un ahorro si disminuimos la potencia concentrada</li> </ul>
5 – 20%	Baja	-
20 – 40%	Normal	<ul style="list-style-type: none"> <li>• Uso normal.</li> <li>• Es posible que se obtenga un ahorro si se modifica el contrato a uno con discriminación horaria.</li> </ul>
40 – 66%	Alta	<ul style="list-style-type: none"> <li>• Se corre el peligro de sobrepasar la potencia contratada.</li> <li>• es posible que se obtenga un ahorro si se modifica el contrato a uno con discriminación horaria.</li> </ul>
Más del 66%	Muy alta	<ul style="list-style-type: none"> <li>• Es posible que en algún momento se sobrepase la potencia contratada.</li> <li>• Si no se dispone de ICP, esto puede suponer una penalización en la factura.</li> <li>• Es necesario subir la potencia contratada.</li> <li>• Es posible se pueda disminuir costes modificando la tarifa de acceso.</li> </ul>

### 3.2.5. Analizador de calidad eléctrica y energía (Fluke 435)

Dentro de la investigación uno de los puntos más importantes es la recopilación de datos los cuales fueron obtenidos mediante el analizador de red Fluke 435, tales como corriente por cada fase, voltajes de línea a fase, voltajes de línea a línea, potencias activa, reactiva y aparente consumidas por cada fase en un intervalo de tiempo, se observa en la figura 3.5.

Su sencillez de uso contribuye a realizar y registrar fácilmente las medidas, incluso conforme a las normas de calidad actuales [20].



**Figura 3. 3:** Analizador de calidad eléctrica y energía.

### 3.2.6. Predicción del consumo de energía eléctrica

Para asegurar un abastecimiento eléctrico constante y de calidad es necesaria una correcta planificación tanto de las centrales que entrarán a producir como de aquellas centrales de contingencia que deberán estar disponibles para poder asumir un pico de demanda imprevisto. De esto modo, la predicción de la demanda a muy corto plazo se convierte en un aspecto crucial pues estas estimaciones son los datos a partir de los cuales los algoritmos de planificación regulan la generación y distribución de la electricidad.

Una predicción precisa para la demanda de las siguientes horas no sólo es de importancia para el operador de la red eléctrica, sino que constituye un factor de gran interés tanto para las centrales eléctricas de generación como para las comercializadoras.

Teniendo en cuenta que, para el caso de los productores, el poder conocer la demanda que va ocurrir en el futuro inmediato les permite planificar de forma estratégica tanto la cantidad de energía eléctrica que están dispuestos a generar como el precio al que la ofertan.

Para las comercializadoras el disponer de una estimación precisa de la demanda que va a tener lugar en un futuro inmediato les permite calcular con mayor exactitud la cantidad de energía eléctrica que deben adquirir en el mercado mayorista [4].

Además 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 [5].

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 en donde las técnicas de predicción pueden ser muy útiles son:

- Ciencias
- Comercio
- Finanzas
- Gobierno
- Telecomunicaciones
- Industria
- Marketing
- Energías

Entre otros [6].

Es precisamente en el campo de energías en donde se desarrolla esta investigación, concretamente en el consumo de energía eléctrica en donde una empresa distribuidora comercia hacia los usuarios y abastecer sus procesos. Utilizando técnicas de predicción y datos históricos recolectados del tablero de distribución principal del bloque “B” de la UTC, mediante un analizador de redes.

No existe una sola forma de definir el consumo eléctrico, por lo tanto una primera clasificación en las predicciones de consumo eléctrico está dado por el tipo de caracterización, normalmente puede estar dado en energía (kWh) o en potencia (kW), comúnmente la predicción suele realizarse caracterizando el consumo eléctrico 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 el consumo como energía o potencia. La predicción de 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 causarán deficiencias en la prestación del servicio en el futuro [5].

### **3.2.7. Horizontes temporales para la predicción de consumo de energía eléctrica.**

Al realizar un modelo predictivo del consumo de energía eléctrica se debe tener en consideración los distintos factores. Uno de estos factores es el horizonte temporal, el cual está intrínsecamente relacionado con la variable que se va a predecir.

Esencialmente se pueden distinguir tres horizontes temporales en la previsión del consumo de energía eléctrica [4].

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:

#### **3.2.7.1. 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 consumo. Realmente se trata de realizar el seguimiento de la carga y de la predicción inmediata de esta basándose en los datos de consumo eléctrico obtenidos por el analizador de red Fluke 435 durante las 24 horas [4].

#### **3.2.7.2. 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. Los datos empleados para este tipo de previsiones son las medidas tomadas cada dos meses.

#### **3.2.7.3. Largo plazo**

Este es el horizonte temporal de previsión del consumo de energía eléctrica que engloba desde uno hasta diez años en el futuro. Dado que se necesita entre tres y diez años para planificar, construir, probar y poner en marcha nueva capacidad generadora, este tipo de predicciones resultan de gran utilidad para mantener el equilibrio entre producción y demanda en consonancia con el desarrollo económico y sociocultural del país. Por otro lado, una correcta estimación de la demanda a largo plazo permite programar un mix energético adecuado a las características de la demanda eléctrica a nivel nacional, por lo general este horizonte temporal es utilizado para predecir la demanda energética de un País [4].



### 3.2.8. Perceptron multicapa

El modelo de la estructura Perceptrón se basan en los principios de corrección de error planteado por el algoritmo de la regla delta el cual utiliza para entrenar un sistema, la cual se basa en el uso de varias capas de neuronas artificiales, además esta es la red neuronal más antigua que hoy en día se utiliza para aplicación como identificador de patrones, este modelo después de haber aprendido una serie de patrones puede reconocer otros similares, aunque no se le hubiesen presentado en el entrenamiento [8].


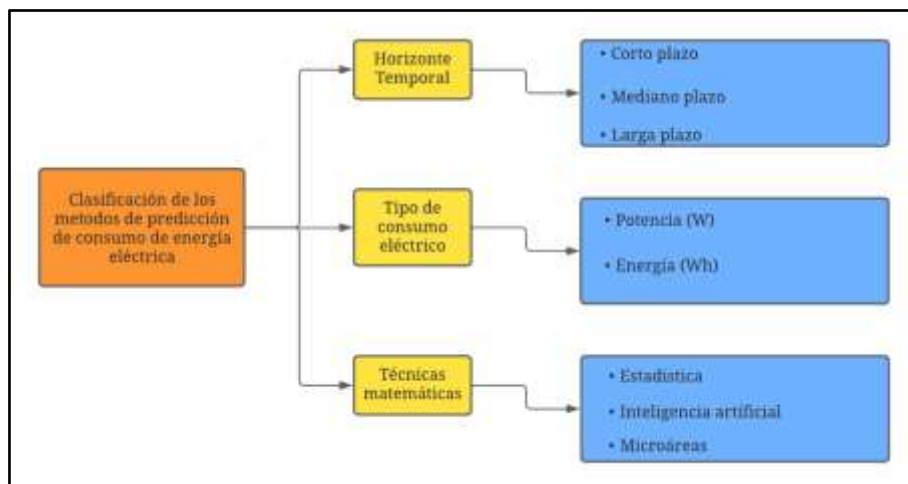


Figura 3. 4: Modelo de red perceptron Multicapa.

### 3.2.9. Clasificación de los métodos del pronóstico de consumo de energía eléctrica

En la actualidad los métodos para pronosticar el consumo eléctrico se lo realizan mediante parámetros que inciden, cada uno de los criterios son importantes para lograr plantear un método de eficaz, En la figura 3.7, se detalla la clasificación.



**Figura 3. 5:** Parámetros que indican en la predicción de consumo [24].

### 3.2.10. Técnicas para la predicción de consumo de energía eléctrica

Las técnicas que generalmente se utilizan para realizar una predicción de consumo eléctrico emplean datos históricos para predecir eventos futuros, normalmente, los datos históricos se utilizan para crear un modelo matemático que capture las tendencias importantes.

Estas técnicas de predicción se usan entonces con los datos actuales para predecir lo que pasará a continuación, o bien para sugerir acciones con el fin de obtener resultados óptimos [6].

Dentro de las principales técnicas de predicción más utilizadas actualmente para pronosticar los valores futuros sobre la demanda de energía se encuentran:

- El modelo de series temporales.
- El modelo de promedios móviles.
- El modelo de promedio autorregresivos integrado (ARIMA).
- Técnicas de inteligencia artificial.
- Modelos de regresión lineal y polinomio.

### 3.2.11. Técnicas de regresión

En este tipo de técnicas se hace vital el uso de la regresión, que, en estadística, es un proceso para estimar las relaciones entre variables. Incluye muchas maneras para el modelado y análisis de diversas variables, cuando la atención se centra en la relación entre una variable dependiente y una o más variables independientes. Más específicamente, la regresión ayuda a entender cómo el valor de la

variable dependiente varía al cambiar el valor de una de las variables independientes, manteniendo el valor de las otras variables independientes fijas.

Convirtiéndose así en uno de los métodos estadísticos más utilizados para modelar un conjunto de datos de sección transversal.

### **3.2.11.1. Regresión lineal**

Existen muchas técnicas de regresión en función del tipo de variables y de la forma funcional supuesta entre ellas.

Las más elementales, aunque las más potentes en el sentido de que se puede obtener más información son las lineales, las cuales son una herramienta simple de aprendizaje automático para predecir un parámetro desconocido basadas en variables independientes determinadas. Asimismo, permite probar si existe influencia de las variables independientes a la variable dependiente.

El modelado de análisis de regresión que involucra una variable independiente y una variable dependiente para el cual la relación entre las variables se aproxima por medio de una recta se llama regresión lineal simple.

En la regresión simple se tiene una única variable predictora, mientras que, si se integran dos o más variables regresoras o predictoras, se debe recurrir al uso del modelo regresión múltiple. A partir de la regresión lineal es posible obtener predicciones sobre la variable dependiente con base a los valores de la variable dependiente, la ecuación de análisis de regresión lineal simple está dada por:

$$\hat{y} = b_0 + b_1x \quad (3.1)$$

Donde,

$\hat{y}$  = Valor estimado de la variable dependiente.

$b_0$  = Intercepto de la ecuación de regresión estimada.

$b_1$  = Pendiente de la ecuación de regresión estimada.

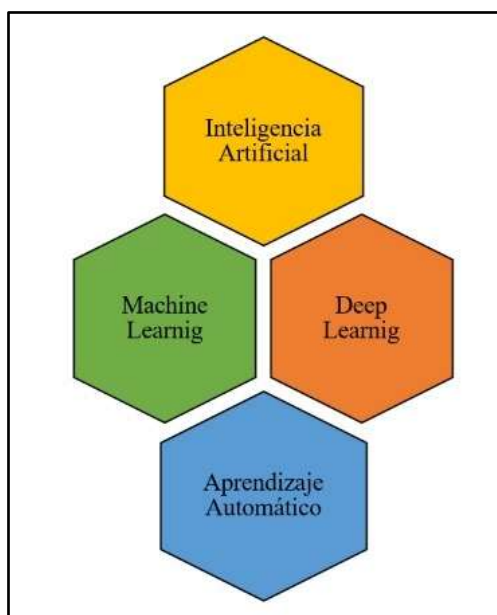
$x$  = Valor de la variable independiente.

### **3.2.12. Categorización de las variables para la predicción de consumo de energía eléctrica**

Se debe tomar en cuenta que para definir las variables que intervienen directamente en la predicción se debe establecer un grado de estudio.

El grado de estudio que se plantea en esta investigación tiene un orden según su categorización de tal manera que se deriva desde; Inteligencia artificial, machine learning Deep learning y aprendizaje automático.

Al plantear correctamente este grado, procedemos a desarrollar la categorización de las variables tal como se muestra en la figura 3.8.



**Figura 3. 6:** Categorización de la variable de estudio para la predicción de consumo de energía eléctrica [25].

### 3.2.12.1. Inteligencia Artificial

La inteligencia artificial (IA) hace referencia a la capacidad que tienen las máquinas de emular el comportamiento del ser humano a través de sus distintas ramas como lo son: lógica difusa, redes neuronales, árboles de decisión y algoritmos genéticos, entre otras, las cuales han permitido el desarrollo de nuevas tecnologías de tipo inteligente que sean capaces de resolver problemas complejos, así como automatizar y optimizar procesos o servicios empresariales de forma eficaz y eficiente sin la menor intervención del factor humano.

La IA implica estudiar el diseño de máquinas inteligentes, de tal manera que puedan dar soluciones reales relacionadas con la toma de decisiones en las organizaciones [6].

**Tabla 3. 4:** Técnicas de inteligencia artificial [3].

<b>Técnica</b>	<b>Definición</b>
Lógica difusa	Rama de la inteligencia artificial que permite manejar datos imprecisos y ambiguos para tomar decisiones como lo haría una persona.
Redes neuronales	Paradigmas computacionales basados en modelos matemáticos para extraer información útil y producir inferencias a partir de los datos disponibles gracias a su capacidad de aprendizaje.
Arboles de decisión	Técnica de predicción la cual consiste en la representación analítica de todos los eventos (sucesos) mediante nodos de un posible problema y que sirve para categorizar una serie de condiciones que ocurren en forma repetitiva para la solución de un problema.
Algoritmo genético	Los algoritmos genéticos (GA) son procedimientos de búsqueda probabilística que generan soluciones a problemas de optimización utilizando técnicas inspiradas en la evolución natural, como la herencia, la mutación, la selección y el cruce.

### 3.2.12.2. 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, además su principio fundamental se basa en permitir que las máquinas aprendan sin ser expresamente programadas para ello.

Una habilidad indispensable para hacer sistemas capaces de identificar patrones entre los datos para hacer predicciones [7].

Entonces el Machine learning es el aprendizaje a través de patrones que son realizados de manera repetitiva.

### 3.2.12.3. 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 [25].

También se compone de un número de niveles jerárquicos. En el nivel inicial de la jerarquía la red aprende algo simple y luego envía esta información al siguiente nivel. El siguiente nivel toma esta información sencilla, la combina, compone una información algo un poco más compleja, y se lo pasa al tercer nivel, y así sucesivamente [8].

Por ejemplo, el nivel inicial de una red de Deep Learning podría utilizar las diferencias entre las zonas claras y oscuras de una imagen para saber dónde están los bordes de la imagen, el nivel inicial pasa esta información al segundo nivel, que combina los bordes construyendo formas simples, como una línea diagonal o un ángulo recto, el tercer nivel combina las formas simples y obtiene objetos más complejos como óvalos o rectángulos, el siguiente nivel podría combinar los óvalos y rectángulos, formando barbas, patas o colas rudimentarias. El proceso continúa hasta que se alcanza el nivel superior en la jerarquía.

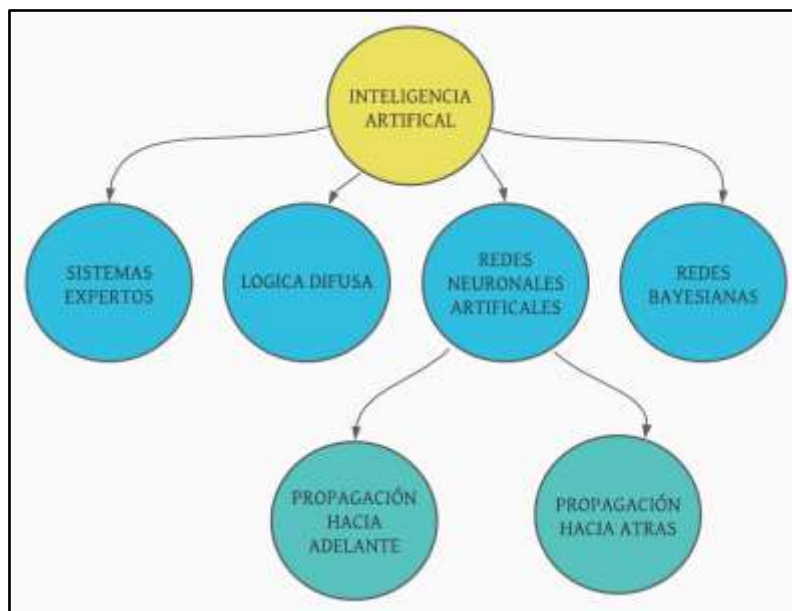
#### **3.2.12.4. Aprendizaje automático**

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 [26].

#### **3.2.13. Métodos de inteligencia artificial para la predicción de consumo de energía eléctrica**

La inteligencia artificial se define como el arte que ayuda a desarrollar máquinas con la capacidad necesaria para realizar tareas.

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 manera trabajan con sistemas complejos, los mismos que presentan comportamientos no lineales [23]. En la figura 3.8, se muestra la clasificación relacionada con la inteligencia artificial.



**Figura 3. 7:** Clasificación relacionado a los métodos de inteligencia artificial empleados en la predicción de consumo de energía eléctrica [24].

### 3.2.14. Redes neuronales artificiales


#### 3.2.14.1. 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 [25].

#### 3.2.14.2. 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, transmitirlas y elaborarlas, en parte también almacenadas y enviarlas de nuevo de forma elaborada.



**Figura 3. 8:** Estructura general de una neurona biológica [27].

En la figura 3.9, 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 [28].

### 3.2.14.3. 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, como se observa en la figura 3.10. Las conexiones entre neuronas tienen pesos asociados que regulan la acción que ciertas unidades tienen sobre el resultado final [29].






Figura 3. 9: Estructura general de una red neuronal artificial [30].

### 3.2.14.4. 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 3.11, 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 3.11, se puede apreciar el símbolo matemático ( $\Sigma$ ) 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 [31].

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

Donde:

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

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

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

$\theta_j$  = 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

$\theta_j$  = 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  $\theta$  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. 10:** Esquema de una red neuronal artificial [30].

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 especio, 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

$\theta_j$  = sesgo

$F$  = función de activación no lineal.

La figura 3.12, 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 [30].

### 3.2.15. Arquitectura de redes neuronales

#### 3.2.15.1. 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 3.12.

- **Capa de Entrada.**

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

- **Capa Oculta.**

Característicamente 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 esta capa 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 [25].

#### 3.2.15.2. 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 3.12.

- **Multicapa**

Estas redes disponen de un 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 3.13 y 3.14.

### 3.2.15.3. 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**

La 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 [32].

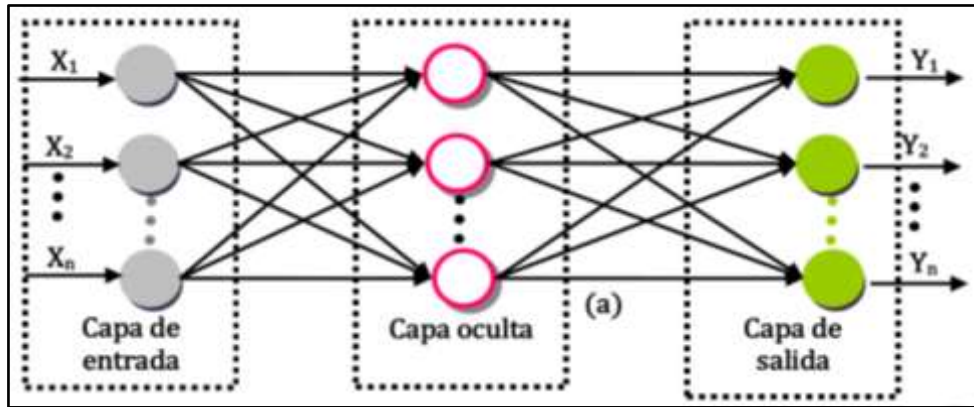
### 3.2.15.4. Según el flujo de los datos

- **Propagación hacia adelante (feedforward)**

Este tipo de propagacion se produce desde la entrada hacia la salida, no existe ningún tipo de realimentación tal como se presenta en la figura 3.13.

Donde:


(a) = Conexiones hacia adelante



**Figura 3. 11:** Red multicapa aplicando la propagación hacia adelante [24].

- **Propagación hacia atrás (feedback)**

Estas 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 3.14 [33].



**Figura 3. 12:** Red multicapa aplicando la propagación hacia atrás [24].

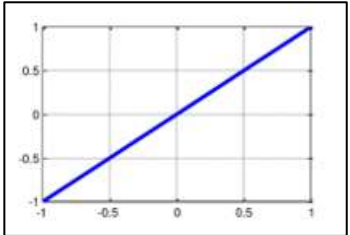
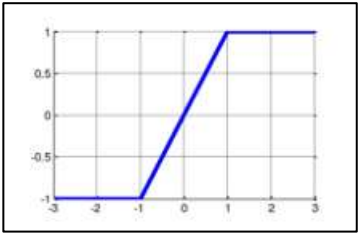
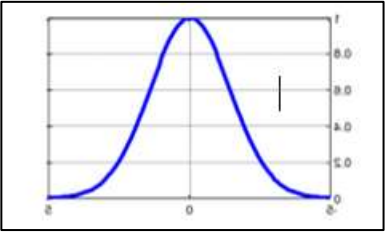
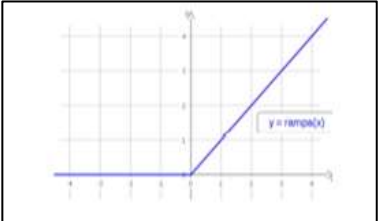
Donde:

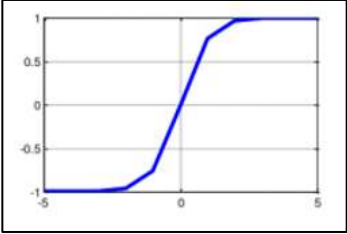
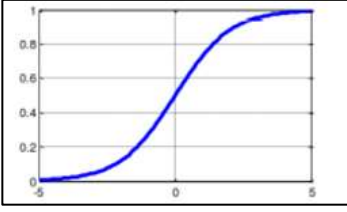
- (a) = Conexiones hacia adelante
- (b) = Conexiones hacia atrás
- (c) = Conexiones laterales
- (d) = Conexiones autorrecurrentes

### 3.2.16. Funciones de activación para la aplicación de redes neuronales artificiales

Es un proceso 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 3.5, en donde se puede apreciar una variedad de funciones de activación que comúnmente son aplicados en el desarrollo de redes neuronales artificiales [23]:

**Tabla 3. 5:** Funciones de activación para la aplicación de redes neuronales artificiales [23].

Función	Ecuación	Gráfica
Lineal	$y(x) = x$	
Lineal a tramos	$y(x) = \begin{cases} -1 & \text{si } x \leq -1 \\ x & \text{si } -1 < x < 1 \\ 1 & \text{si } x \geq 1 \end{cases}$	
Gaussiano	$y(x) = Ae^{-Bx^2}$	
Rampa	$y(x) = \begin{cases} x & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$	

Tangente hiperbólica	$y(x) = \tanh x$	
Sigmoidea	$y(x) = \frac{1}{1 + e^{-x}}$	

### 3.2.16.1. Función tangente sigmoidea

La función tangente hiperbólica transforma los valores introducidos a una escala (-1,1), donde los valores altos tienen de manera asintótica a 1 y los valores muy bajos tienden de manera asintótica a -1.

Las características principales que presenta esta función son:

- Muy similar a la función sigmoidea
- Satura y mata el gradiente.
- Lenta convergencia.
- Centrada en 0.
- Está acotada entre -1 y 1.
- Se utiliza para decidir entre una opción y la contraria.
- Buen desempeño en redes recurrentes.

Presentando como ecuación de representación:

$$y(x) = \frac{2}{1 + e^{-2x}} - 1$$

### 3.2.16.2. Función logarítmica sigmoidea

La función sigmoidea logarítmica es muy utilizada como función de activación de las neuronas que conforman una red neuronal artificial, transforma los valores introducidos a una escala (0,1), donde



los valores altos tienen de manera asintótica a 1 y los valores muy bajos tienden de manera asintótica a 0.

Las características de la función logarítmica sigmoide son:

- Satura y mata el gradiente.
- Lenta convergencia.
- No está centrada en el cero.
- Está acotada entre 0 y 1.
- Buen rendimiento en la última capa.

Representada por la siguiente función:

$$y(x) = \frac{1}{1 + e^{-x}}$$

### **3.2.17. 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 [25].

Según afirma [26] existen tres categorías de aprendizaje automático.

#### **3.2.17.1. 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.

### **3.2.17.2. Aprendizaje no supervisado**

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.


### **3.2.17.3. Aprendizaje por refuerzo**

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 [33].

### **3.2.18. 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 [25].

En la figura 3.15, se muestra de forma agrupada algunos de los algoritmos que se pueden aplicar en la predicción de consumo 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. 13:** Clasificación de algoritmos para el uso de redes neuronales artificiales [34].

### 3.2.19. Optimizadores de redes neuronales artificiales.

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.

### 3.2.20. 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 estudiados 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 matemático 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 [36].

### **3.2.20.1. 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 sobre entrenamiento. 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 sobre entrenamiento y afectará a los resultados pronosticados.

### **3.2.20.2. 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.

### **3.2.20.3. 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 [37].

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

#### 3.2.21.1. 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 [25]. 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 [24].

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

#### 3.2.21.2. 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.

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

#### 3.2.21.3. 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.

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

#### 3.2.21.4. 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 en la siguiente expresión: 3. [25].

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

**3.2.21.5. Error residual**

Según [38] 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.

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

**3.2.21.6. Error estándar múltiple**

El error estándar múltiple, mide la dispersión de los datos obtenidos en la predicción [39]. 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

**3.2.22. Distribución de probabilidad**

La distribución de probabilidad de una variable aleatoria es una función que asigna a cada suceso definido sobre la variable aleatoria, la probabilidad de que dicho suceso ocurra, es decir la distribución de probabilidad está definida sobre el conjunto de todos los rangos de valores de la variable aleatoria cuando la variable aleatoria toma valores en el conjunto de los números reales, la distribución de probabilidad está completamente especificada por la función de distribución, cuyo valor en cada valor de  $x$  es la probabilidad de que la variable aleatoria sea menor o igual que  $x$ . Dada una variable aleatoria  $X$ , se llama función de distribución a aquella que proporciona la probabilidad de que la variable aleatoria tome un valor menor o igual que  $x_i$  [13]. Es decir:

$$F(x_i) = P(X \leq x_i) \quad (3.21)$$

**3.2.23. Matriz de confusión.**

La matriz de confusión de un problema de clase  $n$  es una matriz  $n \times n$  en la que las filas se nombran según las clases reales y las columnas, según las clases previstas por el modelo, sirve para mostrar de

forma explícita cuándo una clase es confundida con otra. Por eso, permite trabajar de forma separada con distintos tipos de error.

Por ejemplo, en un modelo binario que busque predecir si un circuito eléctrico puede tener un cortocircuito, basándose en determinadas características de instalación de éstas consideraremos las clases reales p(ositivo= existe cortocircuito) y n(egativo= no existe cortocircuito), y las clases pronosticadas por el modelo, S(í, en cortocircuito), o N(o, no en cortocircuito).

De esta forma, la matriz de confusión para este modelo tiene etiquetadas sus filas con las clases reales, y sus columnas, con las predichas por el modelo, quedaría así:

VALORES PREDICCIÓN	Verdaderos positivos	Falsos Positivos
	Falsos Negativos	Verdaderos Negativos
	VALORES REALES	

**Figura 3. 14:** Matriz de confusión Binaria.

Estas 4 opciones se conocen como la matriz de confusión, pues veamos cuales son los 4 resultados posibles:

- Verdadero positivo: El valor real es positivo y la prueba predijo también que era positivo. O bien existe un cortocircuito y el análisis así lo demuestra.
- Verdadero negativo: El valor real es negativo y la prueba predijo también que el resultado era negativo. O bien no existe cortocircuito y el análisis así lo demuestra.
- Falso negativo: El valor real es positivo, y la prueba predijo que el resultado es negativo. O bien existe un cortocircuito, pero el análisis dice de manera incorrecta que no lo está. Esto es lo que en estadística se conoce como error tipo II, [11].

### 3.2.24. Power Log

Power Log es el software para PC de los modelos 345, 435, VR1710 y 1735 de Fluke. Es un software mediante el cual se puede visualizar datos descargados del cualquier analizador de Red perteneciente a la marca Fluke, dicho software fue diseñado para Microsoft Windows XP y se ha verificado que funciona con Vista.

Después de transferir los datos registrados a un PC para su evaluación gráfica y tabular, los datos pueden exportarse a una hoja de cálculo para generar e imprimir informes.

Con Power Log se puede realizar diferentes análisis de datos y se recomienda:

- Descargue los datos registrados a un PC
- Generar tablas de datos
- Ver, imprimir y exportar gráficos de tiempo de todos los canales
- Realice estudios de armónicos
- Imprima tablas, gráficos e informes completos y formateados
- Exportar datos para su manipulación en otros programas [9].



**Figura 3. 15:** Icono de Power Log [9].



### 3.2.24.1. Instalación de Power Log

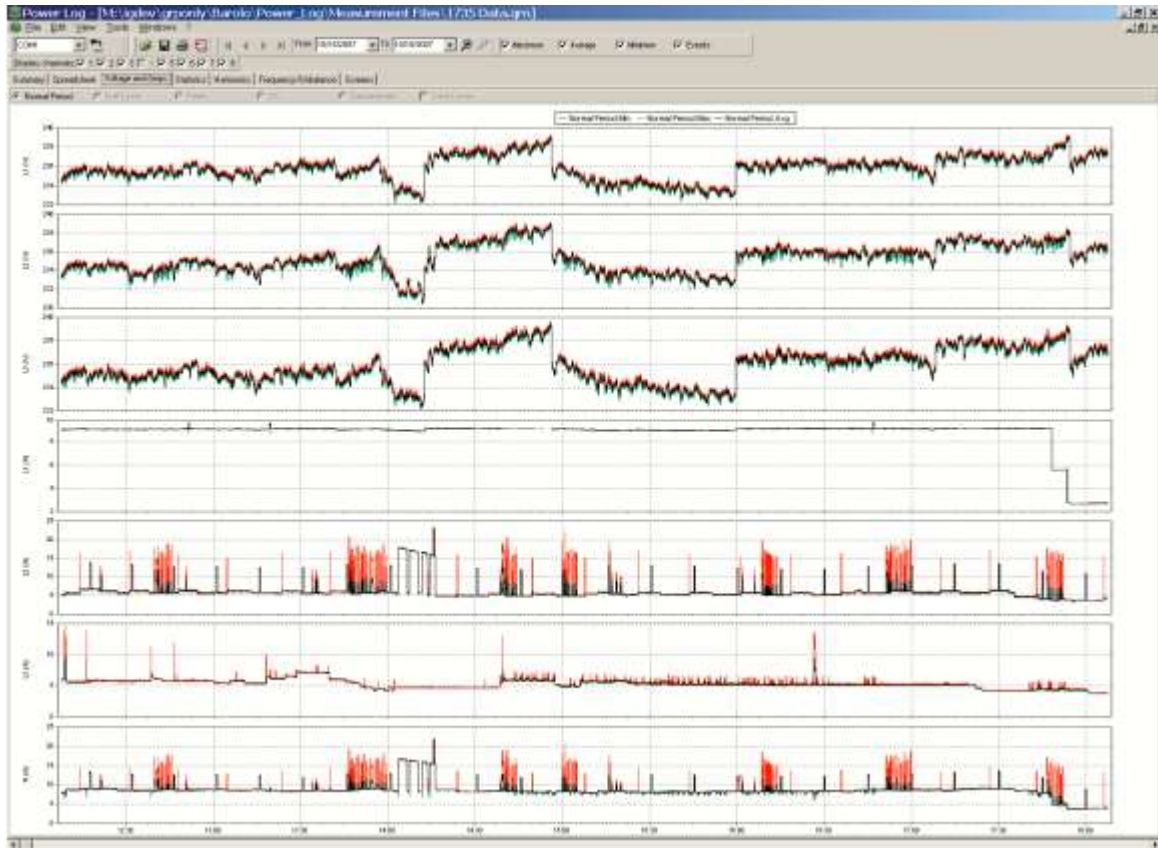
Acceda al sitio web de Fluke en [www.fluke.com](http://www.fluke.com) e instale siguiendo las instrucciones en la pantalla disponibles en la página del producto del instrumento.

La instalación desde el sitio web requiere un breve registro [9].

### 3.2.24.2. Descarga de datos del analizador de red hacia un PC

Para descargar los datos almacenados en el instrumento y poder ser transferidos a un PC, se debe realizar los siguientes pasos, es muy importante mencionar que no se puede descargar los datos mientras en equipo este registrando medidas, esto puede ocasionar medidas erróneas o pérdidas de lectura de datos.

1. El instrumento debe estar conectado desde el equipo Fluke hacia una computadora o puerto USB.
2. Para descargar los datos almacenados de un 434 o 435:
  - a) Pulse el botón MEMORIA.
  - b) Seleccione RECALL/DELETE (F1).
  - c) Seleccione el archivo de datos guardado para cargarlo.
  - d) Seleccione USAR (F5).
3. Seleccione el puerto COM de la lista desplegable, los instrumentos basados en USB pueden mostrarse como el modelo de instrumento.
4. Seleccione en el menú Archivo | Descarga, o pulse el icono de descarga, la transferencia de datos puede durar segundos o minutos, dependiendo de la velocidad de baudios y de la cantidad de datos. Una vez completada la descarga, aparece un gráfico de tiempo de los datos.
5. Finalmente el VR1710 indica que la descarga está completa y si usted desea seguir midiendo, con varias opciones de selección.
  - Sí
  - Sí, y borrar la memoria
  - No [9].



**Figura 3. 16:** Visualización de datos en Power log.

### 3.2.25.MATLAB

MATLAB es una plataforma de programación diseñada específicamente para que ingenieros y científicos analicen y diseñen sistemas y productos que transforman nuestro mundo.

El corazón de MATLAB es el lenguaje basado en matrices que permite la expresión más natural de las matemáticas computacionales.



**Figura 3. 17:** Icono de Matlab.

### 3.2.25.1. Aplicaciones de Matlab

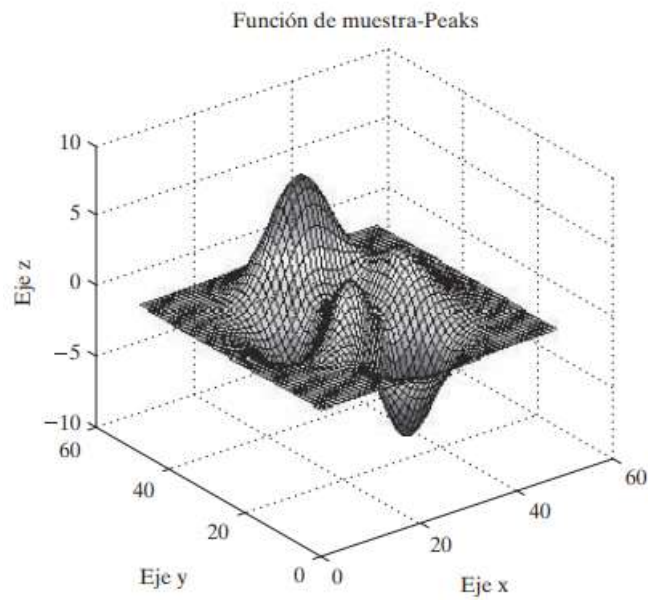
Matlab es un software de ingeniería utilizado para realizar diversas tareas desde varios ámbitos de educación, economía, programación, visualización e integración con otros softwares.

De acuerdo con MathWorks en el año 2020 se tiene que el software de ingeniería ofrece a los usuarios la capacidad de desarrollo, modelización, diseño y ajuste de algoritmos para el control en variados campos de la industria, por ejemplo en las máquinas eléctricas exploran un amplio espectro de diseño mediante el modelado del sistema y del equipo en físico, simulando de manera el comportamiento de las partes del sistema, lo que reduce los prototipos físicos mediante la realización de pruebas del sistema en condiciones que pueden ser demasiado peligrosas o lentas, además trabaja conjuntamente combinando programación textual y gráfica para diseñar el sistema en entornos de simulación.

Esto conlleva, a la simulación de los sistemas de control electrónicos de potencia empleados para crear los modelos de motores eléctricos y otros tipos de maquinarias generadoras de energía, bajo condiciones tanto de corriente continua como de corriente alterna.

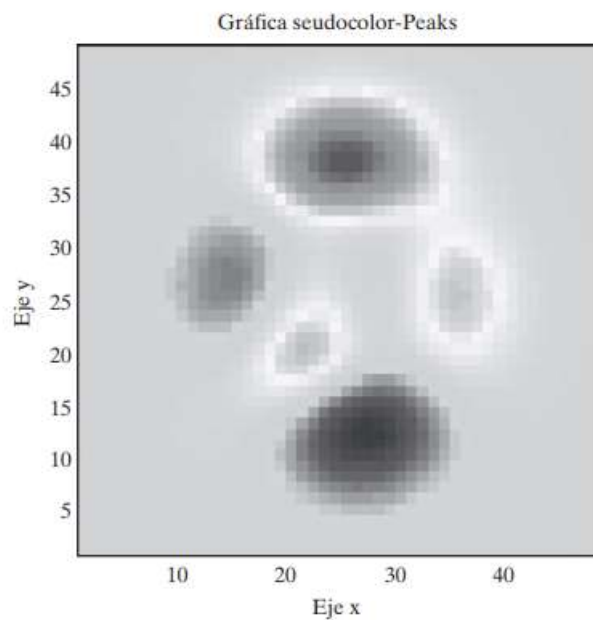
Con el estudio del comportamiento de los motores eléctricos inducidos por corriente alterna se pueden analizar las variables que rigen su conducta, lo que permite simular con este tipo de software los métodos de control y disminución de la elevada corriente de arranque, permitiendo mejorar la calidad de energía eléctrica en las industrias, además que dicho software ofrece una interfaz amigable con el usuario, [12].

Otra de las aplicaciones del software es la de realizar gráficas usadas comúnmente en ingeniería como el caballo de batalla de la gráfica x-y, las gráficas polares y las gráficas de superficie, así como algunas técnicas de graficación usadas con más frecuencia en aplicaciones de negocios, como las gráficas de pastel, las gráficas de barras y los histogramas. MATLAB permite al usuario un significativo control sobre la apariencia de estas gráficas, así como manipular imágenes y crear representaciones tanto de datos como de modelos de procesos físicos, se puede crear una gráfica de superficie tridimensional de la función al escribir surf (peaks).



**Figura 3. 18:** Grafica de la función peaks.

Una forma más sencilla de lograr el mismo objetivo es usar la gráfica de pseudocolor: pseudocolor (peaks), [2].



**Figura 3. 19:** Grafica de la función pseudocolor (Peaks).

MATLAB, cuenta con una particularidad muy especial la cual es que cuenta con la posibilidad de crear una interfaz gráfica con el usuario, denominado GUIDE el cual es un entorno de programación

visual disponible para realizar y ejecutar programas que necesiten ingreso continuo de datos. Tiene las características básicas de todos los programas visuales como Visual Basic o Visual C++, [12].



**Figura 3. 20:** Interfaz gráfica en Guide para conversión de unidades.

## **4. METODOLOGÍA**

### **4.1. TIPO DE INVESTIGACIÓN**

En el presente proyecto de investigación se plantea realizar la predicción del consumo de energía eléctrica en la Universidad Técnica de Cotopaxi Bloque B, por lo que es necesario utilizar diferentes métodos investigativos, como el exploratorio para obtener información bibliográfica acerca del tema, investigación de campo al momento de obtener los datos de consumo del lugar en mención y pronosticar el uso de la demanda energética.

#### **4.1.1. Investigación exploratoria**

Se utiliza este tipo de investigación con la finalidad de obtener información histórica para poder continuar con la investigación, es decir para realizar el proyecto es necesario determinar las condiciones actuales de consumo, así como también del crecimiento del lugar en donde se pretende realizar el proyecto, para reconocer parámetros eléctricos como el consumo de energía eléctrica, además mediante este tipo de investigación se utiliza para realizar una búsqueda bibliográfica y comprender diferentes conceptos básicos para la elaboración del marco teórico.

#### **4.1.2. Investigación de campo**

Esta investigación se utiliza con la finalidad de obtener datos reales sobre el consumo actual de energía eléctrica y en qué condiciones se encuentran las instalaciones eléctricas pertenecientes al bloque al bloque “B” de la Universidad Técnica de Cotopaxi, dichos datos serán obtenidos a través de un analizador de red Fluke 435, mediante el cual se obtendrá valores de potencia activa (W), potencia aparente (KVA), potencia reactiva (KVAR).

#### **4.1.3. Investigación aplicada**

En este apartado se identificarán los conocimientos científicos, así como el análisis y la programación de los algoritmos utilizando el software de Matlab, que permitan realizar la predicción del consumo de la energía eléctrica, obteniendo resultados cercanos a la realidad.

### **4.2. MÉTODO DE INVESTIGACIÓN**

#### **4.2.1. Metodología de la investigación bibliográfica**

Este tipo de investigación facilita la adquisición de datos para el análisis, el cual se basará en los antecedentes de consulta de artículos científicos, publicaciones de internet, libros y proyectos similares que involucren pronóstico del consumo de energía eléctrica.

Lo que facilita un razonamiento teórico lo que proporciona la votación sobre el procedimiento adecuado para la solución del problema.

#### **4.2.2. Inductivo – deductivo**

Este indaga todos los procedimientos, temas y subtemas utilizados en esta investigación de manera descriptiva, mientras que el procedimiento proporciona una descripción detallada de las conclusiones y recomendaciones de la pregunta que se investiga. En cuanto a los modelos utilizados, se analiza cada método sobre los pronósticos del consumo de la energía eléctrica, a su vez nos ayuda a implementar un algoritmo que nos permite obtener los datos necesarios para crear nuestras propias inferencias para recomendar procesos que puedan ser utilizados para tales investigaciones.

### **4.3. TÉCNICAS E INSTRUMENTOS**

#### **4.3.1. Técnica de la observación**

Esta técnica permitirá mediante un análisis detallado del comportamiento de consumo eléctrico – energía (Wh.) en el bloque “B” de la Universidad Técnica de Cotopaxi, además que esta técnica se la aplicara al análisis de los datos emitidos por el analizador de red Fluke 435, esta técnica es la más acertada para la investigación ya con esta se visualiza el registro y los datos obtenidos durante el proceso.

#### 4.4. Etapas de la Metodología:

Se presenta el desarrollo conceptual del proyecto de investigación, ubicación geográfica de la Universidad técnica de Cotopaxi, datos obtenidos por el analizador de red Fluke 435, tabulación de resultados y desarrollo de la herramienta computacional, así como también se presentan observación y resultados que se obtuvieron luego de aplicar el modelo matemático al consumo del bloque “B”.

El desarrollo del proyecto está dividido en 5 etapas para la predicción del consumo de energía utilizando redes neuroartificiales.

**Etapas 1:** Consiste en determinar el centro de educación superior el cual será usado para la aplicación y predecir del consumo de energía eléctrica, obtención de información, descripción del sitio, diagrama unifilar de las cargas conectadas.

**Etapas 2:** Obtener datos de parámetros eléctricos mediante el analizador FLUKE 435, para determinar las potencias de consumo en el lugar.

**Etapas 3:** Procesamiento y filtrado de los datos obtenidos mediante la medición del analizador de redes Fluke 435.

**Etapas 4:** Desarrollo de la herramienta computacional, en base a los datos obtenidos posterior al filtrado y validación, la cual permita realizar la predicción del consumo de energía utilizando las variables de entrada obtenidas anteriormente.

**Etapas 5:** Predicción de energía eléctrica necesaria para satisfacer el consumo de la institución de educación superior.

#### 4.5. Caso practico

El proyecto de investigación se plantea desarrollar en la Universidad Técnica de Cotopaxi o UTC es una Universidad de Ecuador con sede en la ciudad de Latacunga ubicada, con varias extensiones, la matriz, ubicada en San Felipe, en Salache, Pujili y otra en el Cantón La Maná de la misma provincia [13].

Para el desarrollo del proyecto se estudiará el consumo de energía eléctrica en la UTC de San Felipe especialmente en el Bloque “B”, al ser el bloque que más energía consume.




**Tabla 4. 1:** Consumo Eléctrico del mes de mayo de los 3 campus de la UTC.

CAMPUS UNIVERSITARIO	CONSUMO ELÉCTRICO MENSUAL (KWH)
UTC – Matriz	52.997
UTC – Salache	5.981
UTC – La Mana	13.157

En la **¡Error! No se encuentra el origen de la referencia.** se presenta la ubicación geográfica de la Universidad Técnica de Cotopaxi.

**Tabla 4. 2:** Coordenadas de la Universidad Técnica de Cotopaxi – La Matriz.

Coordenadas geográficas de la Universidad Técnica de Cotopaxi – La Matriz	
Coordenada Sur	0°55'04''S
Coordenada Oeste	78°37'58''O

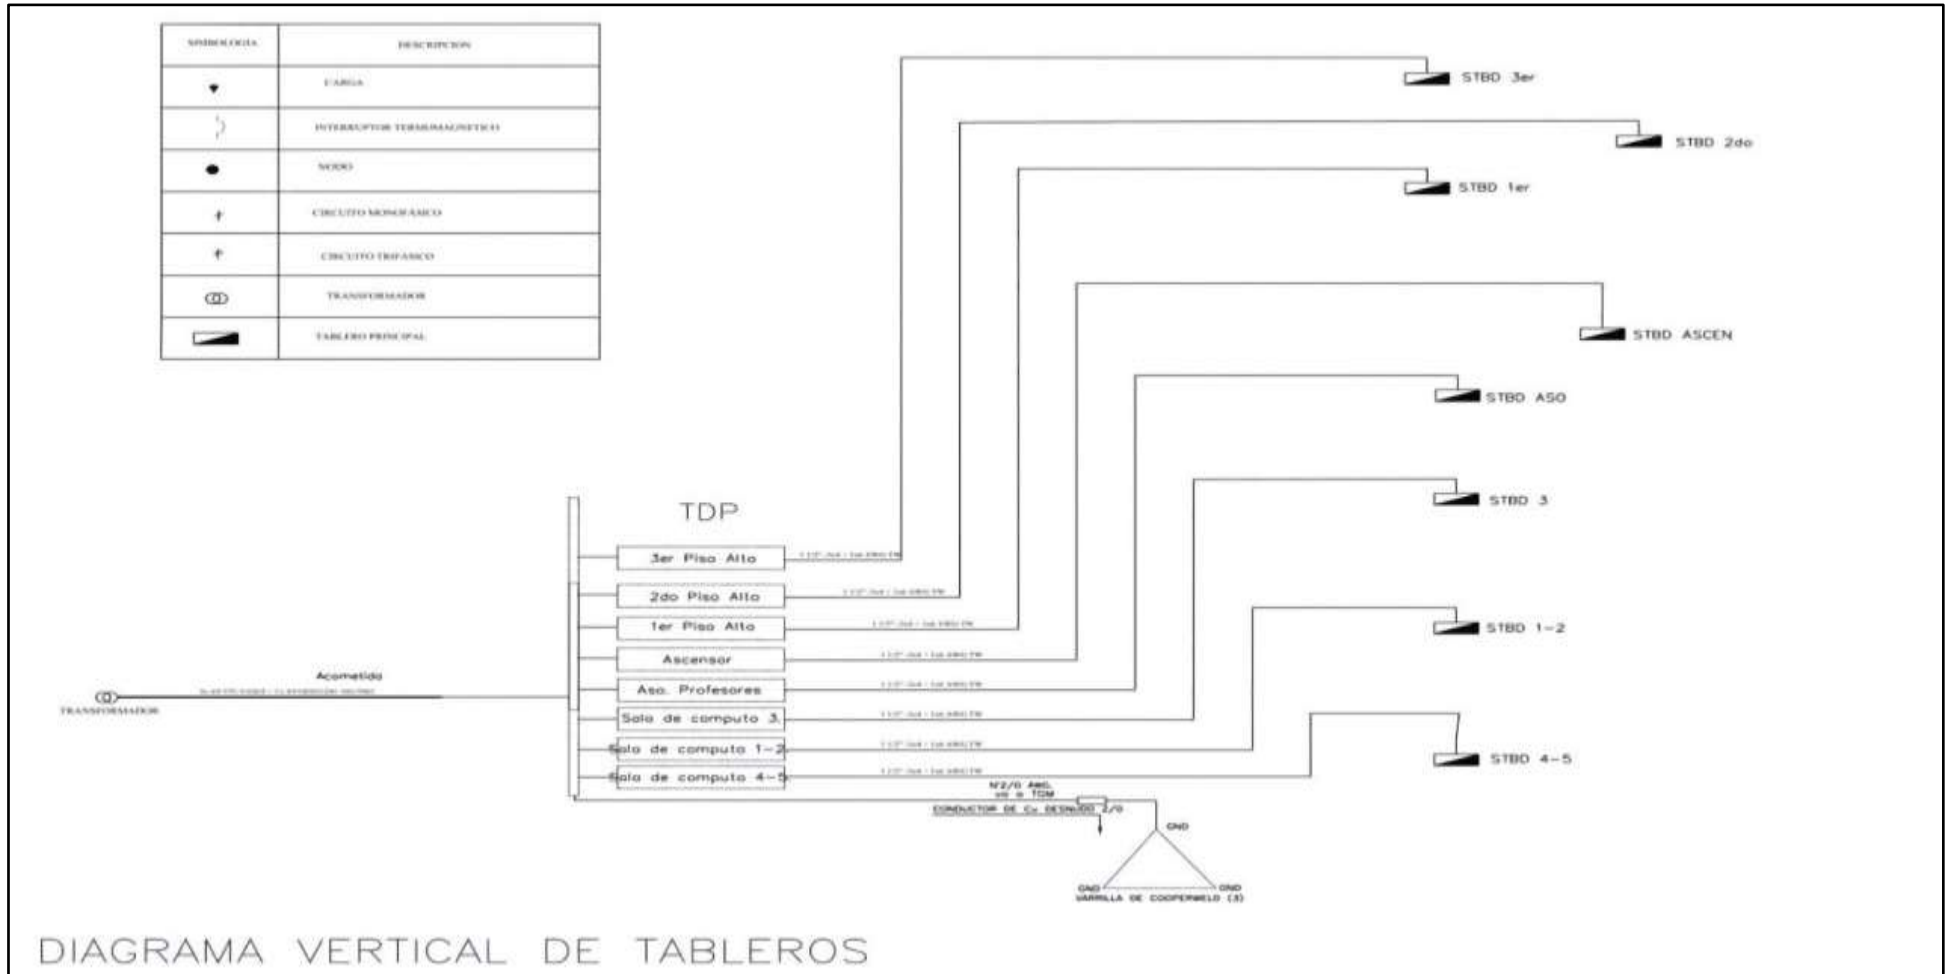
**Figura 4. 1:** Ubicación geográfica de la Universidad Técnica de Cotopaxi San Felipe.

Se debe tomar en cuenta que la universidad técnica de Cotopaxi la matriz cuenta con dos bloques, los cuales están distribuidos como:


- Bloque A
- Bloque B

La investigación está centrada en el bloque “B” de dicha institución por lo que en la figura 5.2. Se puede visualizar el diagrama unifilar vertical del tablero de distribución principal mientras que en la

figura 5.3. se observa el diagrama unifilar de cargas del tablero de distribución principal el cual consta de una cámara de transformación N.º 1, en donde los bornes del transformador se derivan a tres fases de bajo voltaje de 110 voltios cada una al tablero de distribución principal, mediante un conductor 4/0 XLPE con una longitud de 50 metros y una acometida subterránea entre extremos. Este tablero consta de un breaker principal de 350 Amperios un breaker secundario de 125 Amperios, dos conductores por cada fase de tipo #4/0 AWG TTU, un conductor de neutro #4/0 AWG desnudo y un conductor a tierra de tipo #2/0 AWG.



**Figura 4. 2:** Diagrama Unifilar vertical del tablero de distribución principal del Bloque B de la UTC.



**Figura 4. 3:** Diagrama Unifilar de cargas del tablero de distribución del Bloque B de la UTC.

## 4.6. Adquisición de datos

En este apartado se describe el procedimiento realizado para medir y adquirir datos eléctricos de los parámetros de consumo de energía eléctrica en (WH).

### 4.6.1. Conexión y configuración de analizador de red FLUKE 435

El primer procedimiento que se realizó para a adquisición de datos fue conectar el analizador de red de marca FLUKE modelo 435 al tablero de distribución principal del bloque “B”.




**Figura 4. 4:** Conexión de analizador de red Fluke 435 a tablero general de distribución.

Una vez implantado el equipo de medición se procedió a calibrar y verificar el correcto funcionamiento del mismo, realizando una medición de tensión conocida, posterior a eso se configuro los parámetros necesarios para la toma de datos, los tiempos para intervalos de medición, tipo de red, voltaje, tipo de almacenamiento, es importante mencionar que, tras activar una determinada medida, transcurrirá un tiempo de respuesta de unos 10 segundos antes de iniciarse la medición.

Durante este tiempo, el símbolo U (Unstable, o inestable) aparece en el encabezado de la pantalla.

Además, el temporizador realiza la cuenta atrás a partir de -10 segundos, cuando llegue a 0 el equipo iniciara con la toma de datos



**Figura 4. 5:** Configuración de los parámetros eléctricos del analizador de red Fluke 435.

Dicho equipo fue conectado en las instalaciones del bloque “B” de la Universidad técnica de Cotopaxi en el Subtablero de distribución STD que aloja a sus circuitos y cargas del lugar de análisis, el equipo se mantuvo conectado a un sistema trifásico realizando las mediciones correspondientes a los parámetros eléctricos con un lapso de tiempo de 32 segundos entre medición, es importante mencionar que por la gran cantidad de datos arrojados por el analizador de red se realizó un filtrado de los mismos a 1 minuto entre medición.

Todo esto fue realizado en cumplimiento con la regulación No. ARCONEL 005/18, la misma menciona que para verificar el correcto funcionamiento de un equipo analizador de red se debe mantener mediante constante monitoreo.

Para cada mes, la medición, registro y almacenamiento de los valores en cada punto seleccionado se efectuará durante un período de evaluación no inferior a siete días continuos, en intervalos de 10 minutos.

Únicamente, la distribuidora podrá utilizar los equipos de medida que registren mediciones en intervalos de 15 minutos, siempre y cuando estos equipos tengan la capacidad de registrar todas las variables necesarias para determinar los índices de calidad de producto [15].



**Figura 4. 6:** Verificación de funcionamiento de equipo de medición.

#### **4.6.2. Obtención de datos del analizador de red Fluke 435**

Una vez transcurrido el periodo de análisis se procede a retirar el equipo de medición del Subtablero de distribución y se extrae el dispositivo USB con los datos obtenidos para su análisis.

##### **4.6.2.1. Transferencia de información del equipo fluke al software POWER LOG**

Existen dos formas para transferir los datos obtenidos desde el equipo de medición hasta un ordenador.

- La primera se puede realizar mediante una conexión entre el equipo y el ordenador con un cable de conexión de USB a USB 2.0.



**Figura 4. 7:** Cable Usb a Usb 2.0.

- La segunda es mediante la extracción del sistema de almacenamiento USB instalada en el equipo y su conexión en el ordenador para copiar el archivo con los datos arrojados.

Para realizar la transferencia de información de utilizo el software Power log 430 II perteneciente a a marca Fluke,



**Figura 4. 8:** Vinculación entre Analizador de red FLUKE 435 y software Power Log para análisis de datos.




#### 4.7. Análisis e interpretación de datos obtenidos en el software Power Log

En este apartado se hace referencia al análisis de la energía activa consumida, máxima, media y mínima para el periodo de tiempo establecido.

##### 4.7.1. Visualización de datos en Power Log

Para visualizar los datos en el software de debe seguir los siguientes pasos:

1. Abrir la pestaña fichero y seleccionar el archivo que contiene los datos del intervalo de mediciones que se desea analizar.



**Figura 4. 9:** Apertura de base de datos extraída de analizador de red.

2. Se visualiza la información principal, configurada en del analizador de red, así como un resumen de los datos registrados.




Figura 4. 10: Panel principal con datos configurados.





Figura 4. 11: Resumen de parámetros medidos.

También se puede visualizar los datos obtenidos mediante graficas estadísticas.

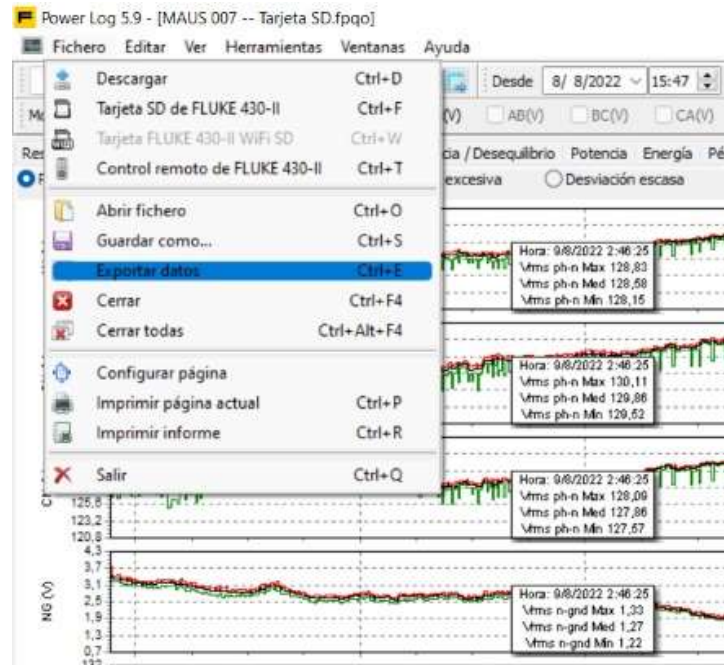


**Figura 4. 12:** Datos obtenidos del consumo de energía eléctrica.

#### 4.7.2. Transferencia de datos desde Power log a Microsoft Excel


Una vez obtenidos los datos desde en el software Power log, se procedió a transferir los mismos hasta una hoja de cálculo de Microsoft Excel para realizar graficas descriptivas del consumo semanal que utiliza el sitio en estudio, para transferir dichos datos se debe seguir los siguientes pasos:

1. Se debe abrir la pestaña ficheros, selecciona exportar datos, como se muestra a continuación:



**Figura 4. 13:** Transferencia de datos desde Power Log a Microsoft Excel.

2. Luego se selecciona los parámetros a estudiar, tales parámetros corresponden al consumo de energía registrado.



**Figura 4. 14:** Selección de datos a exportar.

3. Presionando la tecla guardar se clasifican los datos en los ficheros de Excel.




Figura 4. 15: Clasificación de datos de Excel.

4. Finalmente se exportan los datos




Figura 4. 16: Transferencia finalizada de los datos a Excel.

### 4.7.3. Clasificación y validación de datos en Excel

Debido a que el proyecto presentado se basa en realizar un modelo matemático que sea capaz de predecir el consumo de energía eléctrica, se filtró de todas las mediciones obtenidas utilizando únicamente la columna que contiene las mediciones de consumo de energía, como se muestra en la siguiente figura:

	H1	H2	H3	H4	H5	H6	H7	H8	H9	
4	Fecha	Hora	Energía Activa kWh Estado	Energía Activa kWh Min	Energía Activa kWh Med	Energía Activa kWh Max	Energía Activa kWh Estado	Energía Activa Total Min	Energía Activa Total Med	Energía Activa Total Max
5	23/7/2022	11:20:05.225	0	0	0	30	0	0	0	510
6	23/7/2022	11:21:05.225	0	0	0	80	0	0	0	219
7	23/7/2022	11:22:05.225	0	0	0	91	0	0	0	328
8	23/7/2022	11:23:05.225	0	0	0	121	0	0	0	441
9	23/7/2022	11:24:05.225	0	0	0	151	0	0	0	544
10	23/7/2022	11:25:05.225	0	0	0	181	0	0	0	651
11	23/7/2022	11:26:05.225	0	0	0	211	0	0	0	753
12	23/7/2022	11:27:05.225	0	0	0	241	0	0	0	858
13	23/7/2022	11:28:05.225	0	0	0	271	0	0	0	957
14	23/7/2022	11:29:05.225	0	0	0	302	0	0	0	1052
15	23/7/2022	11:30:05.225	0	0	0	332	0	0	0	1158
16	23/7/2022	11:31:05.225	0	0	0	362	0	0	0	1270
17	23/7/2022	11:32:05.225	0	0	0	392	0	0	0	1371
18	23/7/2022	11:33:05.225	0	0	0	422	0	0	0	1479
19	23/7/2022	11:34:05.225	0	0	0	452	0	0	0	1577
20	23/7/2022	11:35:05.225	0	0	0	482	0	0	0	1679
21	23/7/2022	11:36:05.225	0	0	0	513	0	0	0	1781
22	23/7/2022	11:37:05.225	0	0	0	543	0	0	0	1881
23	23/7/2022	11:38:05.225	0	0	0	573	0	0	0	1988
24	23/7/2022	11:39:05.225	0	0	0	603	0	0	0	2100
25	23/7/2022	11:40:05.225	0	0	0	633	0	0	0	2205
26	23/7/2022	11:41:05.225	0	0	0	663	0	0	0	2305
27	23/7/2022	11:42:05.225	0	0	0	693 (7)	0	0	0	2445 (7)
28	23/7/2022	11:43:05.225	0	0	0	723 (7)	0	0	0	2549 (7)
29	23/7/2022	11:44:05.225	0	0	0	753 (7)	0	0	0	2655 (7)
30	23/7/2022	11:45:05.225	0	0	0	784 (7)	0	0	0	2758 (7)
31	23/7/2022	11:46:05.225	0	0	0	814 (7)	0	0	0	2869 (7)
32	23/7/2022	11:47:05.225	0	0	0	845 (7)	0	0	0	2974 (7)
33	23/7/2022	11:48:05.225	0	0	0	875 (7)	0	0	0	3081 (7)

Figura 4. 17: Base de datos inicial.

De esta manera se obtuvo nuestra base de datos a partir de la cual se desarrolló la predicción de consumo eléctrico.




Figura 4. 18: Base de datos filtrados.

#### 4.8. Selección de variables de entrada para el algoritmo

Luego de haber filtrado los datos y realizar el análisis de los mismos mediante Excel, se procedió a identificar las variables de entrada para el algoritmo de programación, es decir los datos que proporcionan la información para que la red neuronal los valide y pueda ejecutar la predicción de consumo de energía de manera adecuada.

Los datos que formaron parte de las variables ingresadas se describe a continuación:

Tabla 4. 3: Variables seleccionadas para el proyecto.

Variable	Descripción	Unidad de medida
Día y mes de medición	Tiempo en el cual se efectuó la medición.	Horas, minutos, segundos
Consumo de energía en WH	Energía activa utilizada para el desarrollo de actividades	Wh

#### 4.9. Validación de datos para el desarrollo del algoritmo

Los datos empleados para el desarrollo del modelo matemático que se utilizaron fueron los obtenidos del analizador de red Fluke 435.

Estos datos deben cumplir con dos condiciones para que las líneas de código de programación de Matlab no arrojen resultados con errores mayor o igual al 5%:

1. El conjunto de datos a analizar debe ser una cantidad significativa de mediciones, por tal razón se realizó varias mediciones en diferentes días, obteniendo valores suficientemente grandes como para obtener resultados significativos.
2. Todo el conjunto de datos debe ser representativo de un intervalo de tiempo determinado, para el caso de estudio representa los días del mes.

#### **4.10. Programación en Matlab**

Para el desarrollo de la red neuronal se utilizó el software de ingeniería MATLAB en el cual se procede a elaborar el código de programación:

#### **4.11. Librerías utilizadas en el código de programación**

Se utilizaron diferentes librerías pertenecientes al software MATLAB, las cuales se detallan a continuación, así como una breve explicación de su uso en el código.

##### **4.11.1.Librería Datos=xlsread**

Esta librería permite leer los datos almacenados en un archivo de hoja de cálculo en Excel, como se menciona en apartados anteriores se filtró los datos para importarlos al código de programación.

##### **4.11.2.Librería Objetivo=xlsread**

Esta librería permite graficar los datos almacenados en un archivo de hoja de cálculo en Excel, importados al código de programación.

##### **4.11.3.Librería tansig, logsig**

Una vez que nuestro algoritmo se encuentra configuradas las entradas se proceden a configurar la red neuronal definiendo cuantas capas se van a utilizar, para nuestro estudio se realizaron ensayos de entrenamiento usando varias funciones que el software nos da como alternativas, obteniendo como resultados que el mejor entrenamiento para nuestra predicción son las funciones tansig, logsig pues estas funciones tienen un aprendizaje supervisado mediante el algoritmo backpropagation para su aprendizaje, además de un set de entrenamiento para minimizar el error, sin antes a ver calibrado el número de neuronas en el caso de este caso de investigación se asigna 10 neuronas.

##### **4.11.4. Librería trainparam. Epoch, max fail, min grade, mu (dec, inc)**

Mediante esta librería Matlab permite simular dentro de las líneas de código cambios rápidos de funciones en tiempos cortos además ajustar nuestros límites para entrenamiento para de esta manera



evitar que el algoritmo se sobrentrene, lo que se busca es generar un patrón en los días de estudio los datos que se presentan a continuación son ajustes de numero de interacciones, el nivel de error, el gradiente con el que se va a graficar nuestra predicción, la traza que va a generar a partir del registro.

#### 4.11.5. Librería divideparam. Trainratio, valratio, test ratio

En esta librería se definen del total (100 %) los datos para validación del error o falla, seguida del test para que pueda encontrar la mejor función objetivo o de predicción validación.

#### 4.11.6. Definición de librerías de la red neuroartificiales.

Una vez configurado los parámetros para nuestra función objetivo, empieza el proceso de aprendizaje de la RNA ya que empieza a validar los datos de ingreso, salida para un día cualquiera de los datos que Matlab importa de la validación de Excel.


#### 4.11.7. Librería hardlim y tansig

Mediante el software de ingeniería Matlab se hace el uso de dos librerías para encontrar la mejor función objetivo de predicción citando en nuestro programa dichas librerías en capa uno que es la capa oculta se configura la función hardlim y en capa dos la red neuronal de salida se configura la función tansig encontrando los siguientes resultados gráficamente:



**Figura 4. 19:** Diferencia de consumo de energía eléctrica librería 1.

EL rango de tolerancia que debe existir no debe supera los 100 Wh, por lo tanto, se concluye que esta función es una de las menos optimas la combinación de funciones, no es la correcta ya que en el rango de error medio cuadrático supero el 30%.




**Figura 4. 20:** Rango de error medio cuadrático librería 1.

Igualmente se puede evidencia en la gráfica de objetivo vs predicción la perdida de tendencia, debido al uso de la función harline ya que esta es una función escalón, a pesar de buscar una configuración adecuada.



**Figura 4. 21:** Perdida de error medio cuadrático librería 1.

Con el uso de esta función se graficó la curva de predicción para un día, usando una cantidad de 300 épocas lo que da como resultado 20 iteraciones para resolverlo con una validación de 14 puntos, observamos que el nivel de gradiente puede tomar direcciones opuestas por lo que termina siendo inútil esta configuración.




**Figura 4. 22:** Gradiente, validación de épocas e iteraciones librería 1.

Finalmente se concluye que el uso de las funciones mencionadas con anterioridad generan un entrenamiento de red inestable sin aprendizaje ya que el modelo matemático que está manejando no permite que la curva de aprendizaje y test se adapten y su valor de predicción se aleje totalmente del valor medido ya que no sigue su tendencia los pesos configurados además del Bias no son en realidad la mejor opción; Pero como muestran la graficas se puede utilizar la función tansig es una alternativa en capa debido a sus funciones internas, como ensayo supervisado es una prueba con un error alto.

#### 4.11.8.Purelin-Satlin

Se registra la nueva combinación de funciones en capa uno que viene siendo la oculta, la red de entrenamiento Purelin es una función lineal que de acuerdo a su concepto de diseño debe funcionar conjuntamente con una lineal o de similares características y este caso se asoció a las Satlin

Por cuestiones de simulación se prueba estas dos variables obteniendo los siguientes resultados:



**Figura 4. 23:** Diferencia de consumo de energía eléctrica librería 2.

Para dichas funciones, la diferencia de consumo existente tiene un valor de tolerancia, por lo tanto, se concluye que esta combinación de funciones es una de las más óptimas, ya que en el rango de error medio cuadrático supero es 0%, lo cual es imposible, por lo tanto, fueron descartadas.

#### 4.11.9.Librería tansig – logsig

Luego de investigar, probar distintas topologías, configuraciones, funciones cambios de variables llegamos a determinar las dos librerías que se ajustan al resultado que deseamos obtener siendo estas dos librerías de Matlab cuadráticas que simplifican el error significativamente, de igual manera se indica que las redes neuronales poseen una topología supervisada a muy corto tiempo, y cuando se enlazan al nodo de salida convergen en muy corto tiempo el nivel de interacciones y las épocas también se reducen, no hay afectación a nivel del error y su nivel es de 5 % ya que es un valor absoluto determinado de esta forma que la red neuronal aprendió.



**Figura 4. 24:** Error porcentual con función tansig – logsin.


Empezamos indicando el nivel de error que presenta y determinamos que el error disminuye significativamente en comparación de las metodologías anteriores ya que se encuentra por debajo del 6% por ciento y simplemente un número menor a 10 picos son los que pasan ese valor y los demás valores se encuentran por el valor medio aceptable usando el backpropagation que es una adaptación en dos fases, misma que es inyectado por un valor de entrada y se propagan desde las capas de atrás hacia adelante una vez encontrado el error de tal manera que va verificando cada vez su salida y que no se va alejando del valor buscado.

Una vez simulado los resultados graficamos el día de validación al igual que su función objetivo, así determinamos que nuestra función sigue la tendencia interna a la externa y es el modelo que se va utilizar, a continuación, se muestra la gráfica de objetivo vs predicción para el mismo día que los anteriores ensayos.




**Figura 4. 25:** Grafica de curva de consumo con backpropagation.

Este modelo nos indica que en 100 épocas pudo realizar un total de 110 interacciones además que su nivel de aprendizaje es el óptimo de entre los anteriores, pero hay valores que se pueden pulir con los pesos y el valor de los cambios de parámetros, cabe indicar que cuando se configura el error de la red neuronal los datos se están desplazando del valor de 0 haciendo que el error como se puede observar en la siguiente figura.



**Figura 4. 26:** Histograma de errores.

Al encontrar la función adecuada para la predicción de consumo energético, se presenta el proceso de aprendizaje de la función.



**Figura 4. 27:** Proceso de aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo.

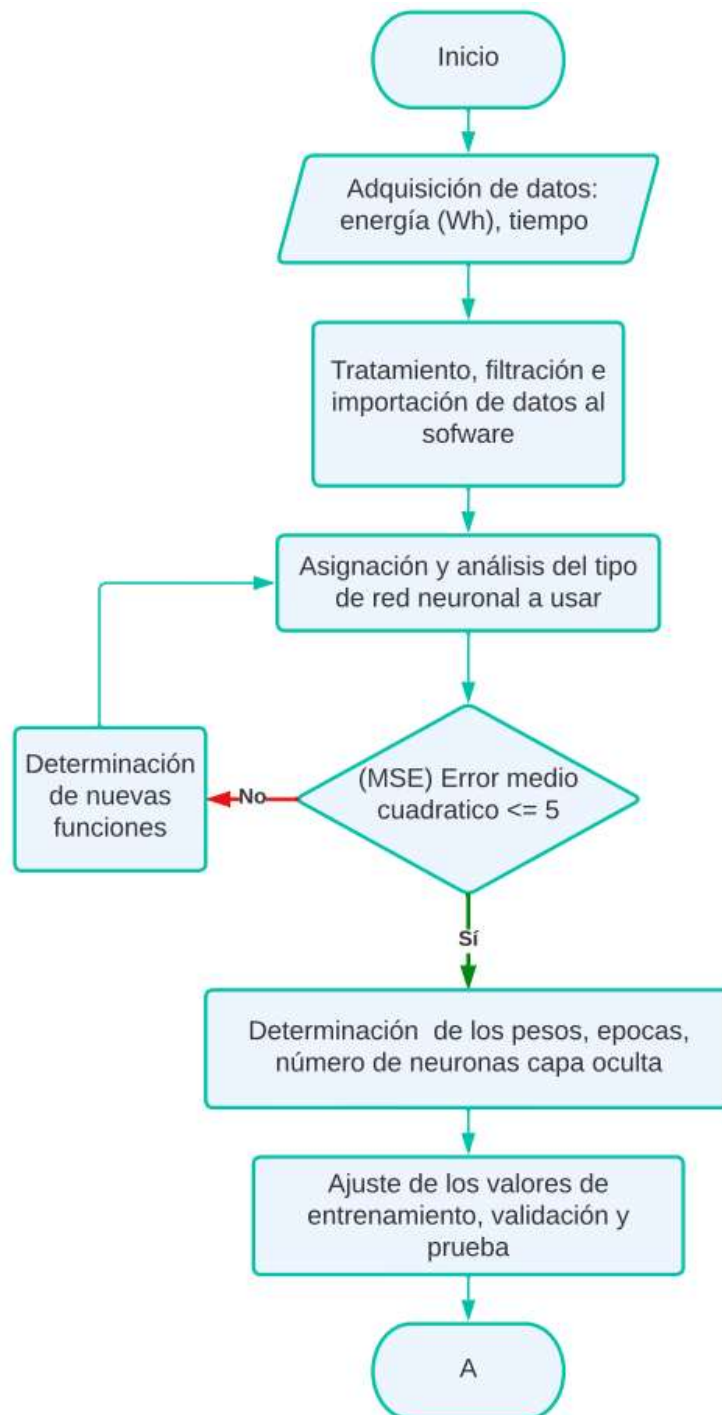
Luego se puede observar que reduce notablemente el error medio cuadrático y su curva se mantenga en un solo punto luego de haber empezado a calcular esto indica que nuestro algoritmo empezó en su fase de entrenamiento para aprendizaje en el corto tiempo en comparación al número de interacciones que las realiza tanto en prueba validación y entrenamiento.

Se construye el algoritmo en base al error que dicha predicción pueda realizar en base a sus funciones estas de igual manera se basan en modelos matemáticos y los resuelven de manera inmediata, estos modelos no se los puede calcular a mano pues llevarían mucho tiempo su cálculo detallado a continuación el nivel de error de las metodologías probadas hasta obtener el modelo actual.

**Tabla 4. 4:** Tabla de comparación de errores para diferentes funciones.

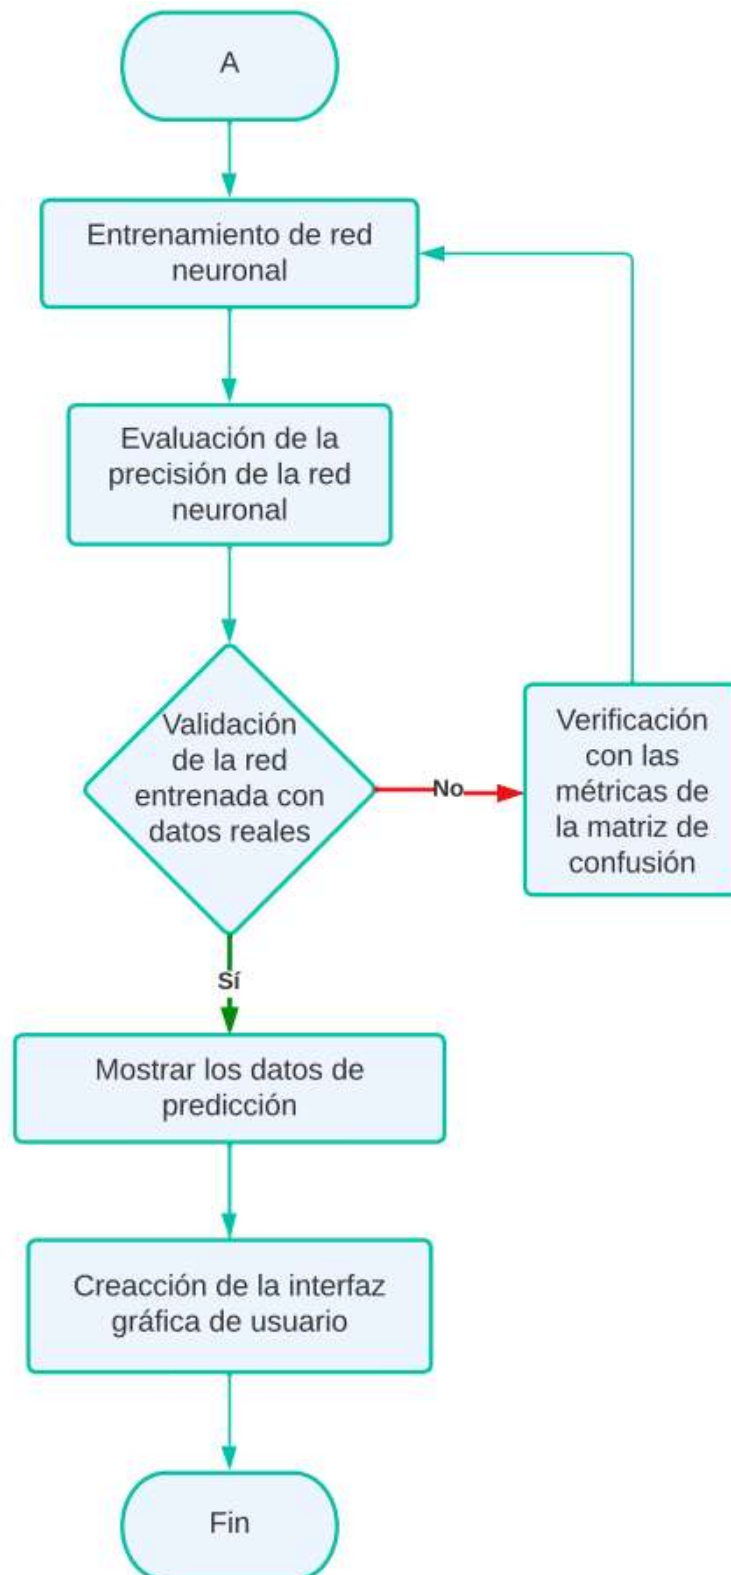
<b>Configuración</b>	<b>Error</b>
Hardlim- Tansig	30 %
Purelin-Satlin	0 %
Tansig-Lonsig	5 %

## 4.12. Diagrama de flujo



**Figura 4. 28:** Estructura de funcionamiento de Red Neuro-artificiales (A).





**Figura 4. 29:** Estructura de funcionamiento de Red Neuro-artificiales (B).

## 5. ANÁLISIS Y DISCUSIÓN DE RESULTADOS


### 5.1. Resultados obtenidos

Una vez elegido el tipo de función con la cual la red neuronal arroja un error igual o inferior al 5% se analiza el consumo de energía eléctrica diario que requiere la Universidad Técnica de Cotopaxi, dichos datos se presentan a continuación.

#### 5.1.1. Análisis de la demanda eléctrica diaria para el día lunes de cada mes

Para realizar el análisis de la demanda eléctrica se tomaron los valores de consumo eléctrico del día lunes de cada mes y se graficó el consumo con respecto al tiempo, para encontrar el valor máximo y mínimo se consumió.

Encontrando la siguiente curva de consumo.



**Figura 5. 1:** Curva de consumo del día lunes para los meses de análisis.

En la curva de consumo perteneciente al día lunes de los meses en estudio se evidencio que en el bloque “B” se comienza a consumir energía eléctrica a partir de las 5 horas 00 minutos, con un decremento al medio día y finalmente donde se registra un consumo menor a las 11 horas 30 minutos, esto debido a que las actividades dicho lugar comienzan a partir de las 5 de la mañana con el encendido de luminarias, áreas de comunicación, ordenadores, etc.

El máximo día de consumo se representa el 12 de diciembre del 2022, con una potencia de 790 W/h.

Para el segundo análisis de los días martes se obtuvo la siguiente curva de consumo:



**Figura 5. 2:** Curva de consumo del día martes para los meses de análisis.

Se evidencia que el inicio de las actividades los días martes de cada mes en análisis se da a partir de las 5 am y termina a las 22 horas 30 minutos.

El máximo día de consumo se representa el 13 de diciembre del 2022, con una potencia de 787 W/h.

Para el tercer análisis de consumo se obtuvo la siguiente curva de consumo:



**Figura 5. 3:** Curva de consumo del día miércoles para los meses de análisis.

En donde se puede evidenciar que al igual que de manera similar que los días martes de los meses analizados, el inicio de las actividades se da a partir de las 5 am y termina a las 22 horas 30 minutos.

El máximo día de consumo se representa el 14 de diciembre del 2022, con una potencia de 835 W/h.

Para el cuarto análisis representado el día jueves se obtuvo la siguiente curva de consumo:



**Figura 5. 4:** Curva de consumo del día jueves para los meses de análisis.

En donde se puede evidenciar que al igual que de manera similar que los días miércoles de los meses analizados, el inicio de las actividades se da a partir de las 5 am y termina a las 22 horas 30 minutos.

El máximo día de consumo se representa el 15 de diciembre del 2022, con una potencia de 748 W/h.

Para el quinto análisis representado el día viernes se obtuvo la siguiente curva de consumo:



**Figura 5. 5:** Curva de consumo del día viernes para los meses de análisis.

En donde se puede evidenciar que al igual que de manera similar que los días miércoles de los meses analizados, el inicio de las actividades se da a partir de las 5 am y termina a las 22 horas 30 minutos.

El máximo día de consumo se representa el 07 de diciembre del 2022, con una potencia de 671 W/h.

Para el sexto análisis representado el día sábado se obtuvo la siguiente curva de consumo:



**Figura 5. 6:** Curva de consumo del día sábado para los meses de análisis.

El análisis de la curva de demanda para el día sábado, varía drásticamente a comparación del resto de la semana debido a la ausencia de estudiantes y personal administrativo, el inicio de las actividades

se da a partir de las 5 am con un pico pequeño de consumo, a las 17 pm se da un incremento de energía y termina a las 22 horas.

El máximo día de consumo se representa el 17 de diciembre del 2022, con una potencia de 310 W/h.

Para el séptimo análisis representado el día domingo se obtuvo la siguiente curva de consumo:



Figura 5. 7: Curva de consumo del día domingo para los meses de análisis.

El análisis de la curva de demanda para el día domingo, varía drásticamente a comparación del resto de la semana debido a la ausencia de estudiantes y personal administrativo, el inicio de las actividades se da a partir de las 5 am con un pico pequeño de consumo, a las 17 pm se da un incremento de energía y termina a las 21 horas con 30 minutos.

El máximo día de consumo se representa el 18 de diciembre del 2022, con una potencia de 310 W/h.

### 5.1.2. Análisis de la demanda eléctrica en la semana de validación

Previa la predicción del consumo eléctrico se toma una muestra de datos de 2 016 caracteres numéricos, que permiten validar de manera comparativa el perfil de carga entre la curva objetivo y la curva de predicción arrojadas por la herramienta computacional, es importante mencionar que para el análisis que se presenta a continuación se lo realiza en forma diaria y para cada día se utiliza 288 caracteres numéricos, obtenidos del analizador de Red en un día normal de trabajo en la institución.

#### 5.1.2.1. Lunes

Mediante los datos obtenidos por el analizador de red se procedió a graficar la situación actual de la demanda de energía eléctrica diaria, para un día lunes en jornada laboral, tomando como referencia un total de 288 datos, a continuación, se presenta el perfil de consumo para dicho día:




**Figura 5. 8:** Consumo de energía eléctrica lunes en el bloque "B" de la UTC.

Mediante el análisis realizado para el día lunes se puede evidenciar que existe un consumo máximo requerido en el sitio de estudio de 542 Wh la cual considerando que el sistema eléctrico esta a plena carga, este perfil de consumo es de manera prolongada en un lapso de tiempo de 19:00 a 20:00 pm.

### 5.1.2.2. Martes

De manera similar a la realizada anteriormente se procedió a graficar el perfil de consumo para el día martes como se muestra a continuación:




**Figura 5. 9:** Consumo de energía eléctrica martes en el bloque "B" de la UTC.

De la gráfica presentada se evidencia que el día martes no existe una caída de demanda de energía eléctrica al medio día, a diferencia del lunes, esto debido a los diferentes horarios de estudio, prácticas y demás actividades realizadas por los estudiantes, la demanda máxima necesaria para satisfacer la necesidad es de 523 WH.

### 5.1.2.3. Miércoles

Para el día miércoles se presenta el siguiente perfil de carga, en donde se evidencia que la máxima demanda que presenta es de 546 WH a las 19h10.



**Figura 5. 10:** Consumo de energía eléctrica miércoles en el bloque "B" de la UTC.

### 5.1.2.4. Jueves

De igual manera se presenta la gráfica de consumo actual para el jueves.






**Figura 5. 11:** Consumo de energía eléctrica jueves en el bloque "B" de la UTC.

### 5.1.2.5. Viernes


Para el día viernes se presenta el siguiente perfil de carga, en donde se evidencia que la máxima demanda que presenta es de 241 WH debido a que muchos de los estudiantes de las diferentes facultadas y oficinas terminan su semana de labores.



**Figura 5. 12:** Consumo de energía eléctrica viernes en el bloque "B" de la UTC.

### 5.1.2.6.Sábado


En la curva de consumo, a diferencia del resto de la semana puede observar en la curva de consumo que el inicio de las actividades es a las 7:45 am, además que el consumo de energía eléctrica es moderado, a comparación del resto de días.



**Figura 5. 13:** Consumo de energía eléctrica sábado en el bloque "B" de la UTC.

### 5.1.2.7.Domingo

Al igual que en la curva de consumo del día sábado, el perfil de energía eléctrica muestra que no se necesita mucha potencia debido a la suspensión de actividades por ser fin de semana excepto por actividades que se desarrollan en el interior de la misma, como uso de canchas, iluminación interior y demás, se obtiene como valor máximo de energía de 241.



**Figura 5. 14:** Consumo de energía eléctrica domingo en el bloque "B" de la UTC.


## 5.2. Resultados obtenidos

### 5.2.1. Lunes

Este apartado se analiza la comparación entre curvas de consumo de la energía eléctrica generada de los datos importados en la validación o curva objetivo vs el perfil de carga que proyecta la herramienta computacional, para realizar la representación gráfica de curva objetivo se utilizaron 4 608 datos que corresponden a un día cualquiera, los cuales son seleccionados de un total de 32 256 valores numéricos, correspondientes a las mediciones realizadas, por ejemplo si se quiere encontrar la predicción para un día lunes, la herramienta computacional realiza la gráfica objetivo utilizando los datos de validación del día mencionado, mientras que para graficar la curva de predicción utiliza la base de datos más la generación de nuevos valores provenientes del entrenamiento de la red.

#### 5.2.1.1. Perfil de carga curva objetivo vs curva predicha lunes

Con lo mencionado anteriormente se procede a realizar la predicción de demanda diaria para una semana, en la siguiente figura, se puede observar el comportamiento de la variación de la curva de demanda eléctrica con los datos extraídos de la data base para el día lunes durante el tiempo establecido.




**Figura 5. 15:** Comparación de demanda entre perfil de carga actual vs predicha lunes

En la gráfica se puede observar que tanto la curva objetivo como el perfil de carga de predicción tienen similitud en las cuales se observa el alto grado de precisión, aproximación y generalización de la red neuronal, en la gráfica presentada en el apartado 5.9.2.1 se obtuvo una demanda máxima de 542 Wh, mientras que en el perfil de carga predicho se estima que se necesitara 524,4 Wh como máximo para un día lunes cualquiera en el cual la Universidad técnica de Cotopaxi bloque “B” desarrolle sus actividades curriculares de manera normal.

#### **5.2.1.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho lunes**

La herramienta computacional desarrollada también permite observar de manera gráfica el valor de errores que presenta, para el caso de estudio, se aprecia que el error no tiene valores extremos, en la curva se observa que el promedio del mismo no excede el 5%.




**Figura 5. 16:** Error porcentual existente entre demanda actual y demanda predicha lunes

En la gráfica se observa que existe un pico de error de 13,25% correspondiente a varios instantes durante el día, una de las razones puede ser que existe un lapso de tiempo en el cual la curva objetivo disminuye su valor y corresponde al medio día, por un lapso de tiempo en el cual finalizan las actividades académicas de la jornada matutina, mientras que, en el entrenamiento de la red, esta predice que existirán intervalos de tiempo en donde se necesitara más energía.

### 5.2.1.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho lunes

En este apartado se presenta la diferencia que existe entre la demanda de consumo actual y la demanda de consumo predicha.




**Figura 5. 17:** Diferencia existente entre demanda actual y demanda predicha lunes

Como se detalló anteriormente, el error porcentual ponderado muy bajo con una diferencia máxima de 34,56 Wh, debido al correcto entrenamiento de la red neuronal en la herramienta tecnológica, por lo tanto, la diferencia entre los dos perfiles de carga analizados es muy pequeña.

#### 5.2.1.4. Predicción de demanda lunes


Es el apartado más importante del presente proyecto, ya que, en base a los filtrados, el error, diferencia de curvas de consumo, la red neuronal predice la cantidad de energía eléctrica que se va necesitar la instalación para el mismo día de la siguiente semana, para el día lunes, la red herramienta tecnológica predice que se va a necesitar 524.4 Wh para el desarrollo de las actividades en el bloque B de la Universidad Técnica de Cotopaxi como se muestra en la siguiente figura.



**Figura 5. 18:** Predicción de demanda para el día lunes

### 5.2.1.5. Error medio cuadrático RMSE lunes


En la gráfica representativa del error medio cuadrático se observa que la comparación entre el valor de demanda de energía eléctrica predicho y el valor de demanda de energía eléctrica, además se muestra el proceso de aprendizaje de la red neuronal, se aprecia el proceso de aprendizaje de los datos de validación, prueba y entrenamiento.



**Figura 5. 19:** Error medio cuadrático para el día lunes.

### 5.2.1.6. Error de histograma lunes


En la presente grafica se presenta la visualización de errores, es decir las veces que se repite un mismo número, durante la predicción.



**Figura 5. 20:** Histograma de error para el día jueves

### 5.2.1.7. Avance del entrenamiento de red lunes

Mediante la siguiente grafica se observa el desarrollo de entrenamiento por la red neuronal, en la cual se ve el proceso de aprendizaje automático que tiene la misma, gracias a esta visualización de parámetros se tiene noción de que parámetros a ajustar para un mejor entrenamiento, en la primera grafica se visualiza que el valor de los pesos introducidos al momento de desarrollar la herramienta tecnológica son los adecuados y no se necesita realizar un reajuste de los mismos, la segunda grafica permite visualizar el cambio que tiene el error con respecto al tiempo.



**Figura 5. 21:** Entrenamiento de la herramienta tecnológica.




### 5.2.1.8. Matriz de confusión lunes

En la gráfica se observa los valores de obtenidos en la matriz de confusión, de la cual, el primer cuadro corresponde al entrenamiento, el segundo a la validación de datos, el tercero al test y el cuarto a los resultados generales de la matriz, de esta última se obtiene una síntesis de los resultados obtenidos de las tres anteriores, en donde al observar en la clase 1 se obtuvo un valor de 27,1% prediciendo un valor favorable a los verdaderos positivos, en la clase 2 se obtuvo un valor de 70,8% prediciendo un valor favorable a los verdaderos negativos, finalmente el resultado presentado por la matriz se ve un porcentaje de aceptación del 97,9%, y un error de 3,1%, es importante mencionar que la suma de los verdaderos positivos y verdaderos negativos debe ser igual al número de datos seleccionados para el análisis diario, es decir 288 valores.



Figura 5. 22: Matriz de confusión del día lunes.

Finalmente, las métricas obtenidas al desarrollar y operar la matriz de confusión son las siguientes:



**Figura 5. 23:** Métrica obtenida día lunes

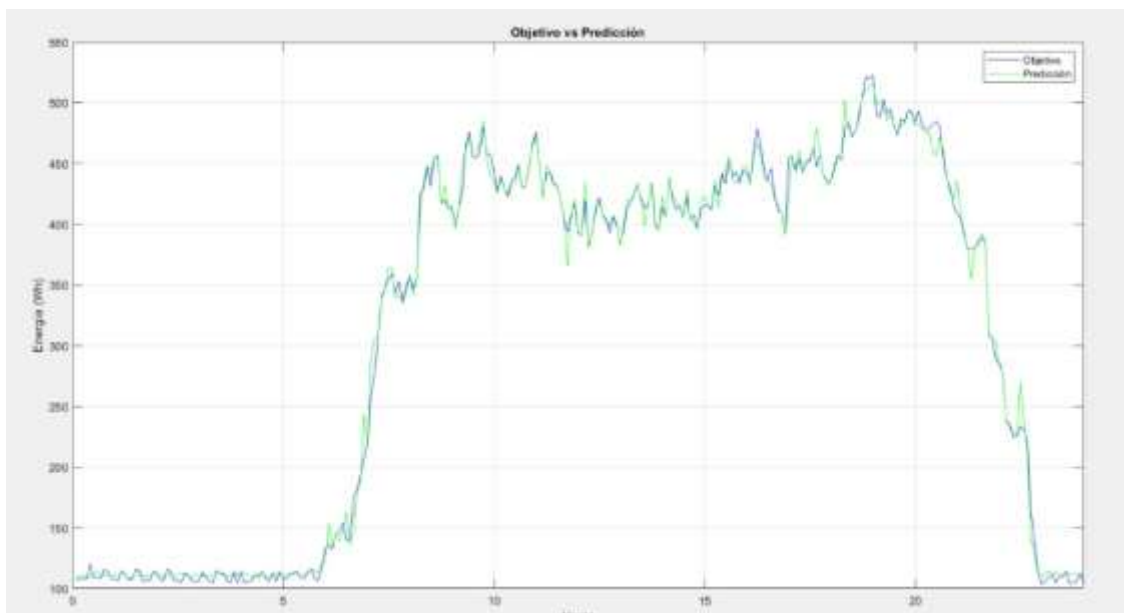
La precisión encontrada al desarrollar la predicción para el día lunes es de 93,97%, con una tasa de recuperación del 98,73%, una exactitud del 97,91% y un puntaje del 96,29%, basándonos en las métricas obtenidas se determina que la predicción realizada es muy acertada, pues los puntajes presentados sobrepasan el 90%.

### 5.2.2. Datos obtenidos martes.

De manera similar que se realizó para el día lunes, se ejecutó el programa para visualizar los resultados para un día martes cualquiera.

#### 5.2.2.1. Perfil de carga curva objetivo vs curva predicha martes

Con lo mencionado anteriormente se procede a realizar la predicción de demanda diaria para el día martes, en la siguiente figura, se puede observar el comportamiento de la variación de la curva de demanda eléctrica con los datos extraídos de la data base.




**Figura 5. 24:** Comparación de demanda entre perfil de carga actual vs predicha martes

En la gráfica se puede observar que tanto la curva objetivo como el perfil de carga de predicción tienen similitud en las cuales se observa el alto grado de precisión, aproximación y generalización de la red neuronal, en el perfil de la demanda objetivo se tiene una demanda de 523 Wh, mientras que en el perfil de carga predicho se estima que se necesitaría 516 Wh como máximo para un día martes cualquiera en el cual la Universidad técnica de Cotopaxi bloque “B” desarrolle sus actividades curriculares de manera normal.

#### **5.2.2.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho martes**

La herramienta computacional desarrollada también permite observar de manera gráfica el valor de errores que presenta, para el caso de estudio, se aprecia que el error no tiene valores extremos, en la curva se observa que el promedio del mismo no excede el 5%.




**Figura 5. 25:** Error porcentual existente entre demanda actual y demanda predicha martes

En la gráfica se observa que existe un pico de error de 4,80 % correspondiente a varios instantes durante el día.

### 5.2.2.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho martes

En este apartado se presenta la diferencia que existe entre la demanda de consumo actual y la demanda de consumo predicha.




**Figura 5. 26:** Diferencia existente entre demanda actual y demanda predicha martes

Como se detalló anteriormente, el error porcentual ponderado muy bajo con una diferencia máxima de 36,01 Wh, debido al correcto entrenamiento de la red neuronal en la herramienta tecnológica, por lo tanto, la diferencia entre los dos perfiles de carga analizados es muy pequeña.

#### 5.2.2.4. Predicción de demanda martes

Es el apartado más importante del presente proyecto, ya que, en base a los filtrados, el error, diferencia de curvas de consumo, la red neuronal predice la cantidad de energía eléctrica que se va necesitar la instalación para el mismo día de la siguiente semana, para el día martes, la red herramienta tecnológica predice que se va a necesitar 516.2 Wh para el desarrollo de las actividades, como se muestra en la siguiente figura.



**Figura 5. 27:** Predicción de demanda para el día martes

#### 5.2.2.5. Matriz de confusión martes


En la gráfica se observa los valores de obtenidos en la matriz de confusión, de la cual, el primer cuadro corresponde al entrenamiento, el segundo a la validación de datos, el tercero al test y el cuarto a los resultados generales de la matriz, de esta última se obtiene una síntesis de los resultados obtenidos de las tres anteriores, en donde al observar en la clase 1 se obtuvo un valor de 53,5% prediciendo un valor favorable a los verdaderos positivos, en la clase 2 se obtuvo un valor de 33%

prediciendo un valor favorable a los verdaderos negativos, finalmente el resultado presentado por la matriz se ve un porcentaje de aceptación del 86,5%, y un error de 13,5%, es importante mencionar que la suma de los verdaderos positivos y verdaderos negativos debe ser igual al número de datos seleccionados para el análisis diario, es decir 288 valores.



Figura 5. 28: Matriz de confusión del día martes.

Finalmente, las métricas obtenidas al desarrollar y operar la matriz de confusión son las siguientes:



**Figura 5. 29:** Métricas obtenidas día martes.


La precisión encontrada al desarrollar la predicción para el día martes es de 82,7957%, con una tasa de recuperación del 95,5522%, una exactitud del 86,4583% y un puntaje del 88,76%, basándonos en las métricas obtenidas se determina que la predicción realizada es muy acertada, pues los puntajes presentados sobrepasan el 85%.

### 5.2.3. Datos obtenidos miércoles

De manera similar que se realizó para los días anteriores, se ejecutó el programa para visualizar los resultados para un día miércoles cualquiera.

#### 5.2.3.1. Perfil de carga curva objetivo vs curva predicha miércoles

Con lo mencionado anteriormente se procede a realizar la predicción de demanda diaria para el día miércoles, en la siguiente figura, se puede observar el comportamiento de la variación de la curva de demanda eléctrica con los datos extraídos de la data base.




**Figura 5. 30:** Comparación de demanda entre perfil de carga actual vs predicha miércoles

Mediante el análisis realizado a la figura, se observa que el perfil de carga representado de color azul representa la demanda de energía extraída de la base de datos validada en la herramienta computacional, en la cual se obtiene que para un día miércoles existió una necesidad de 534,4 Wh para satisfacer la demanda generada, mientras que en el perfil de carga representado por color verde correspondiente a la predicción la misma herramienta predice que se va necesitar de 532,2 Wh, para desarrollar sus actividades curriculares de manera normal.

### **5.2.3.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho miércoles**

Como se presentó anteriormente tanto para el día lunes y martes, en la gráfica de error entre perfiles desarrollada por la herramienta computacional se observa que el promedio del mismo no excede el 5% de error, para este día se obtiene un error porcentual del 1,2% determinando una predicción muy satisfactoria.






**Figura 5. 31:** Error porcentual existente entre demanda actual y demanda predicha miércoles

**5.2.3.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho miércoles**

En este apartado se presenta la diferencia que existe entre la demanda de consumo actual y la demanda de consumo predicha.

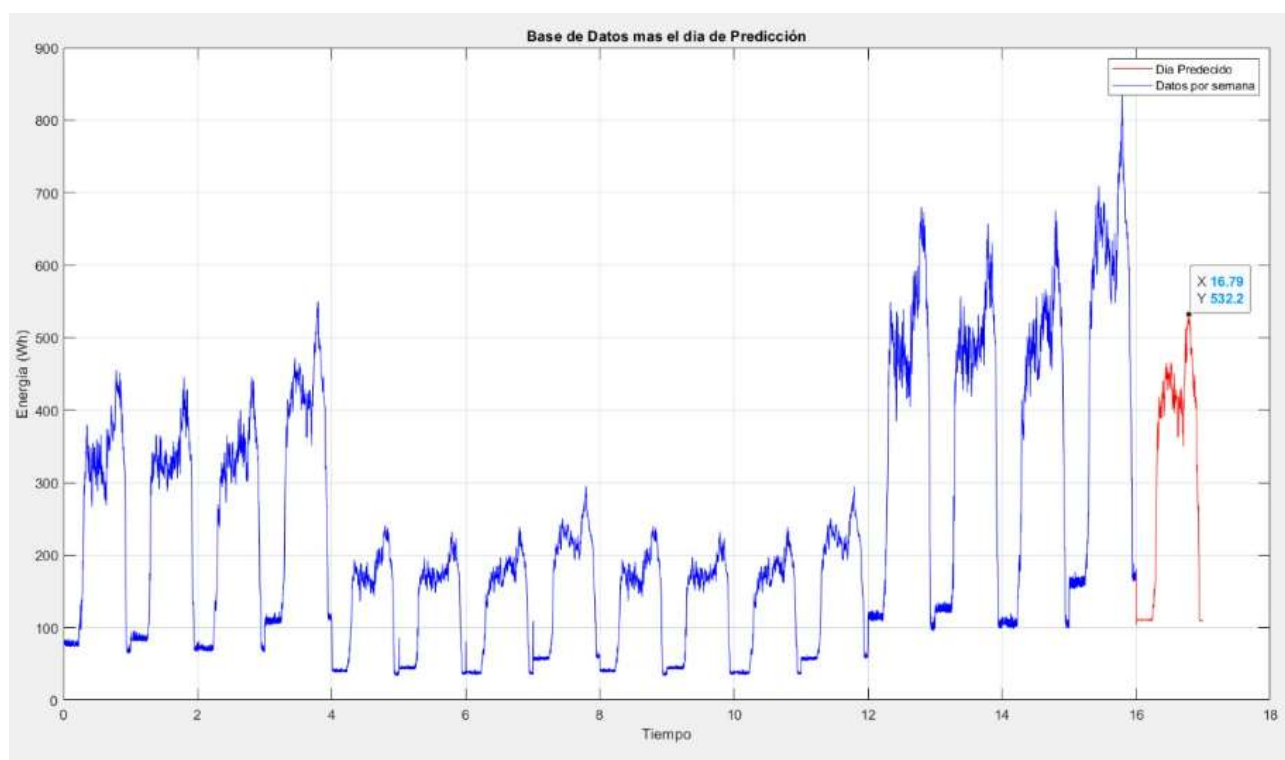


**Figura 5. 32:** Diferencia existente entre demanda actual y demanda predicha miércoles

A diferencia del día martes, el error porcentual ponderado es muy bajo con una diferencia máxima de 36,49 Wh, debido al correcto entrenamiento de la red neuronal en la herramienta tecnológica, por lo tanto, la diferencia entre los dos perfiles de carga analizados es muy pequeña.

#### 5.2.3.4. Predicción de demanda miércoles

Es el apartado más importante del presente proyecto, ya que, en base a los filtrados, el error, diferencia de curvas de consumo, la red neuronal predice la cantidad de energía eléctrica que se va necesitar la instalación para el mismo día de la siguiente semana, para el día miércoles, la herramienta tecnológica predice que se va a necesitar 532,2 Wh para el desarrollo de las actividades en el bloque B de la Universidad Técnica de Cotopaxi como se muestra en la siguiente figura.



**Figura 5. 33:** Predicción de demanda para el día miércoles

#### 5.2.3.5. Matriz de confusión miércoles

En la gráfica se observa los valores de obtenidos en la matriz de confusión, de la cual, el primer cuadro corresponde al entrenamiento, el segundo a la validación de datos, el tercero al test y el cuarto a los resultados generales de la matriz, de esta última se obtiene una síntesis de los resultados obtenidos de las tres anteriores, en donde al observar en la clase 1 se obtuvo un valor de 24.3% prediciendo un valor favorable a los verdaderos positivos, en la clase 2 se obtuvo un valor de 71.5%

prediciendo un valor favorable a los verdaderos negativos, finalmente el resultado presentado por la matriz se ve un porcentaje de aceptación del 95,8%, y un error de 4,2%, es importante mencionar que la suma de los verdaderos positivos y verdaderos negativos debe ser igual al número de datos seleccionados para el análisis diario, es decir 288 valores.



**Figura 5. 34:** Matriz de confusión del día miércoles.

Finalmente, las métricas obtenidas al desarrollar y operar la matriz de confusión son las siguientes:




Figura 5. 35: Métricas obtenidas día miércoles.


La precisión encontrada al desarrollar la predicción para el día martes es de 94,35%, con una tasa de recuperación del 89,93%, una exactitud del 92,0139% y un puntaje del 92,0962%, basándonos en las métricas obtenidas se determina que la predicción realizada es muy acertada, pues los puntajes presentados sobrepasan el 90%.

#### 5.2.4. Datos obtenidos jueves

De manera similar que se realizó para los días anteriores, se ejecutó el programa para visualizar los resultados para un día jueves cualquiera.

##### 5.2.4.1. Perfil de carga curva objetivo vs curva predicha jueves

Con lo mencionado anteriormente se procede a realizar la predicción de demanda diaria para el día jueves, en la siguiente figura, se puede observar el comportamiento de la variación de la curva de demanda eléctrica con los datos extraídos de la data base.




**Figura 5. 36:** Comparación de demanda entre perfil de carga actual vs predicha jueves

Mediante el análisis realizado a la figura, se observa que el perfil de carga representado de color azul representa la demanda de energía extraída de la base de datos validada en la herramienta computacional, en la cual se obtiene que para un día miércoles existió una necesidad de 496 Wh para satisfacer la demanda generada, mientras que en el perfil de carga representado por color verde correspondiente a la predicción la misma herramienta predice que se va necesitar de 492,3 Wh, para desarrollar sus actividades curriculares de manera normal.

#### **5.2.4.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho jueves**

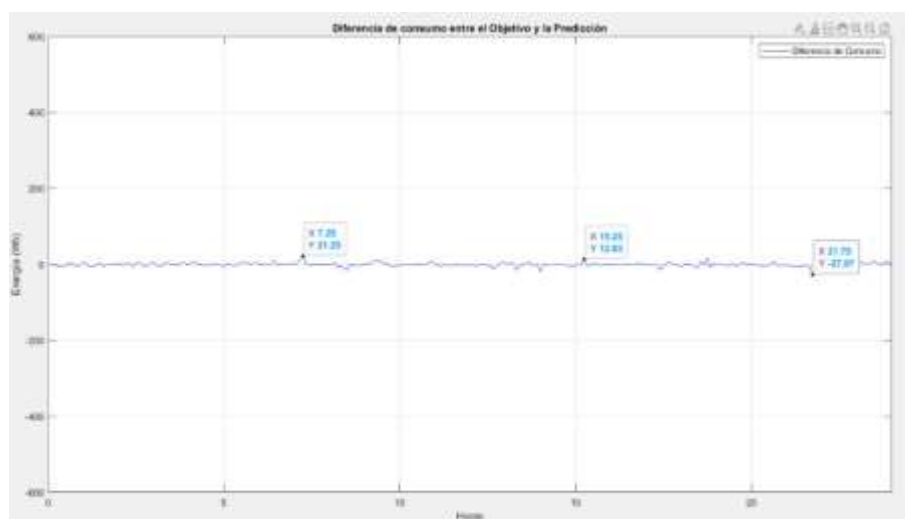
Como se presentó anteriormente tanto para el día martes y miércoles, en la gráfica de error entre perfiles desarrollada por la herramienta computacional se observa que el promedio del mismo no excede el 5% de error, para el día jueves se obtiene un error porcentual del 0,91% determinando una predicción muy satisfactoria, además este error es el error mas bajo encontrado en todo el análisis.



**Figura 5. 37:** Error porcentual existente entre demanda actual y demanda predicha jueves

### 5.2.4.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho jueves

En este apartado se presenta la diferencia que existe entre la demanda de consumo actual y la demanda de consumo predicha.




**Figura 5. 38:** Diferencia existente entre demanda actual y demanda predicha jueves

A diferencia del día martes, el error porcentual ponderado es muy bajo con una diferencia máxima de 21,25 Wh, debido al correcto entrenamiento de la red neuronal en la herramienta tecnológica, por lo tanto, la diferencia entre los dos perfiles de carga analizados es muy pequeña.

#### 5.2.4.4. Predicción de demanda jueves

Como se realizó anteriormente para el resto de días, se presenta a continuación la predicción realizada por la herramienta tecnológica para el día jueves, cual predice que se va a necesitar 492,3 Wh para el desarrollo de las actividades en el bloque B de la Universidad Técnica de Cotopaxi como se muestra en la siguiente figura.



**Figura 5. 39:** Predicción de demanda para el día jueves

#### 5.2.4.5. Matriz de confusión jueves

En la gráfica se observa los valores de obtenidos en la matriz de confusión, de la cual, el primer cuadro corresponde al entrenamiento, el segundo a la validación de datos, el tercero al test y el cuarto a los resultados generales de la matriz, de esta última se obtiene una síntesis de los resultados obtenidos de las tres anteriores, en donde al observar en la clase 1 se obtuvo un valor de 50 % prediciendo un valor favorable a los verdaderos positivos, en la clase 2 se obtuvo un valor de 47,2% prediciendo un valor favorable a los verdaderos negativos, finalmente el resultado presentado por la matriz se ve un porcentaje de aceptación del 97,2 %, y un error de 2,8%, es importante mencionar que la suma de los verdaderos positivos y verdaderos negativos debe ser igual al número de datos seleccionados para el análisis diario, es decir 288 valores.



Figura 5. 40: Matriz de confusión del día jueves

Finalmente, las métricas obtenidas al desarrollar y operar la matriz de confusión son las siguientes:




Figura 5. 41: Métricas obtenidas día jueves.

La precisión encontrada al desarrollar la predicción para el día martes es de 99,06%, con una tasa de recuperación del 97,80%, una exactitud del 97,56% y un puntaje del 98,70%, basándonos en las




métricas obtenidas se determina que la predicción realizada es muy acertada, pues los puntajes presentados sobrepasan el 90%.

### 5.2.5. Datos obtenidos viernes

De manera similar que se realizó para los días anteriores, se ejecutó el programa para visualizar los resultados para un día viernes cualquiera.

#### 5.2.5.1. Perfil de carga curva objetivo vs curva predicha viernes

Con lo mencionado anteriormente se procede a realizar la predicción de demanda diaria para el día viernes, en la siguiente figura, se puede observar el comportamiento de la variación de la curva de demanda eléctrica con los datos extraídos de la data base.




**Figura 5. 42:** Comparación de demanda entre perfil de carga actual vs predicha viernes

Mediante el análisis realizado a la figura, se observa que el perfil de carga representado de color azul representa la demanda de energía extraída de la base de datos validada en la herramienta computacional, en la cual se obtiene que para un día viernes existió una necesidad de 241 Wh para satisfacer la demanda generada, mientras que en el perfil de carga representado por color verde correspondiente a la predicción la misma herramienta predice que se va necesitar de 367 Wh para desarrollar sus actividades curriculares de manera normal, para este día se pudo evidenciar que el

consumo de energía necesarios comienza a disminuir, debido a que la mayoría de estudiantes retornan a sus hogares y la única jornada que desarrolla sus actividades es la nocturna, y el consumo que presenta el perfil es únicamente por las aulas encendidas y no el consumo en cyber, biblioteca, laboratorios y demás.

#### 5.2.5.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho viernes


Como se presentó anteriormente tanto para el día lunes y martes, en la gráfica de error entre perfiles desarrollada por la herramienta computacional se observa que el promedio del mismo no excede el 5% de error, para este día se obtiene un error porcentual del 1,52% determinando una predicción muy satisfactoria.



**Figura 5. 43:** Error porcentual existente entre demanda actual y demanda predicha viernes

#### 5.2.5.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho viernes

En este apartado se presenta la diferencia que existe entre la demanda de consumo actual y la demanda de consumo predicha.




**Figura 5. 44:** Diferencia existente entre demanda actual y demanda predicha viernes

A diferencia de los días anteriores, el error porcentual ponderado es muy bajo con una diferencia máxima de 23,61 Wh, debido al correcto entrenamiento de la red neuronal en la herramienta tecnológica, por lo tanto, la diferencia entre los dos perfiles de carga analizados es muy pequeña.

#### 5.2.5.4. Predicción de demanda viernes

Es el apartado más importante del presente proyecto, ya que, en base a los filtrados, el error, diferencia de curvas de consumo, la red neuronal predice la cantidad de energía eléctrica que se va necesitar la instalación para el mismo día de la siguiente semana, para el día viernes, la herramienta tecnológica predice que se va a necesitar 395,7 Wh para el desarrollo de las actividades en el bloque B de la Universidad Técnica de Cotopaxi como se muestra en la siguiente figura.



**Figura 5. 45:** Predicción de demanda para el día viernes

#### 5.2.5.5. Matriz de confusión viernes

En la gráfica se observa los valores de obtenidos en la matriz de confusión, de la cual, el primer cuadro corresponde al entrenamiento, el segundo a la validación de datos, el tercero al test y el cuarto a los resultados generales de la matriz, de esta última se obtiene una síntesis de los resultados obtenidos de las tres anteriores, en donde al observar en la clase 1 se obtuvo un valor de 87,2% prediciendo un valor favorable a los verdaderos positivos, en la clase 2 se obtuvo un valor de 4,2% prediciendo un valor favorable a los verdaderos negativos, finalmente el resultado presentado por la matriz se ve un porcentaje de aceptación del 91,3%, y un error de 8,7%, es importante mencionar que la suma de los verdaderos positivos y verdaderos negativos debe ser igual al número de datos seleccionados para el análisis diario, es decir 288 valores.



Figura 5. 46: Matriz de confusión del día viernes

Finalmente, las métricas obtenidas al desarrollar y operar la matriz de confusión son las siguientes:




Figura 5. 47: Métricas obtenidas para el día viernes


La precisión encontrada al desarrollar la predicción para el día martes es de 97,16%, con una tasa de recuperación del 94,48%, una exactitud del 92,70% y un puntaje del 95,80%, basándonos en las métricas obtenidas se determina que la predicción realizada es muy acertada, pues los puntajes presentados sobrepasan el 90%, como se mencionó en el apartado anterior, debido al perfil de carga que se presenta, pues el perfil de carga tiende a tener un avance descendente.

### 5.2.6. Datos obtenidos sábado

De manera similar que se realizó para los días anteriores, se ejecutó el programa para visualizar los resultados para un día miércoles cualquiera.

#### 5.2.6.1. Perfil de carga curva objetivo vs curva predicha sábado

Con lo mencionado anteriormente se procede a realizar la predicción de demanda diaria para el día miércoles, en la siguiente figura, se puede observar el comportamiento de la variación de la curva de demanda eléctrica con los datos extraídos de la data base.




**Figura 5. 48:** Comparación de demanda entre perfil de carga actual vs predicha sábado

Mediante el análisis realizado a la figura, se observa que el perfil de carga representado de color azul representa la demanda de energía extraída de la base de datos validada en la herramienta computacional, en la cual se obtiene que para un día sábado existió una necesidad de 211 Wh para satisfacer la demanda generada, mientras que en el perfil de carga representado por color verde correspondiente a la predicción la misma herramienta predice que se va necesitar de 208 Wh, para

desarrollar sus actividades curriculares de manera normal, cabe destacar que existe un incremento súbito de demanda debido que a las 17:00 pm se encienden los reflectores interiores y exteriores del centro de educación superior, de lo contrario el perfil de carga se mantendría constante con intervalos de tiempo y potencia que no sobrepasa de los 96 Wh.

### 5.2.6.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho sábado


Como se presentó anteriormente tanto para el día lunes y martes, en la gráfica de error entre perfiles desarrollada por la herramienta computacional se observa que el promedio del mismo no excede el 5% de error, para este día se obtiene un error porcentual del 1,2% determinando una predicción muy satisfactoria.



**Figura 5. 49:** Error porcentual existente entre demanda actual y demanda predicha sábado

### 5.2.6.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho sábado

En este apartado se presenta la diferencia que existe entre la demanda de consumo actual y la demanda de consumo predicha.




**Figura 5. 50:** Diferencia existente entre demanda actual y demanda predicha sábado

A diferencia del resto de días laborales, el error porcentual ponderado es moderadamente medio con una diferencia máxima de 211 Wh, debido a la tendencia semilineal que presenta el perfil de carga.

#### **5.2.6.4. Predicción de demanda sábado**

Es el apartado más importante del presente proyecto, ya que, en base a los filtrados, el error, diferencia de curvas de consumo, la red neuronal predice la cantidad de energía eléctrica que se va necesitar la instalación para el mismo día de la siguiente semana, para el día sábado, la herramienta tecnológica predice que se va a necesitar 208,9 Wh para el desarrollo de las actividades en el bloque B de la Universidad Técnica de Cotopaxi como se muestra en la siguiente figura.





**Figura 5. 51:** Predicción de demanda para el día sábado

#### 5.2.6.5. Matriz de confusión sábado

En la gráfica se observa los valores de obtenidos en la matriz de confusión, de la cual, el primer cuadro corresponde al entrenamiento, el segundo a la validación de datos, el tercero al test y el cuarto a los resultados generales de la matriz, de esta última se obtiene una síntesis de los resultados obtenidos de las tres anteriores, en donde al observar en la clase 1 se obtuvo un valor de 52,4% prediciendo un valor favorable a los verdaderos positivos, en la clase 2 se obtuvo un valor de 42,4% prediciendo un valor favorable a los verdaderos negativos, finalmente el resultado presentado por la matriz se ve un porcentaje de aceptación del 94,8%, y un error de 5,2%, es importante mencionar que la suma de los verdaderos positivos y verdaderos negativos debe ser igual al número de datos seleccionados para el análisis diario, es decir 288 valores.



Figura 5. 52: Matriz de confusión del día sábado

Finalmente, las métricas obtenidas al desarrollar y operar la matriz de confusión son las siguientes:




Figura 5. 53: Métricas obtenidas día sábado.


La precisión encontrada al desarrollar la predicción para el día martes es de 98,05%, con una tasa de recuperación del 92,63%, una exactitud del 95,26% y un puntaje del 95,27%, basándonos en las métricas obtenidas se determina que la predicción realizada es muy acertada, pues los puntajes presentados sobrepasan el 90%, como se mencionó en el apartado anterior, debido al perfil de carga que se presenta, pues el perfil de carga tiende a tener un avance descendente.

### 5.2.7. Datos obtenidos domingo

De manera similar que se realizó para los días anteriores, se ejecutó el programa para visualizar los resultados para un día miércoles cualquiera.

#### 5.2.7.1. Perfil de carga curva objetivo vs curva predicha domingo

Con lo mencionado anteriormente se procede a realizar la predicción de demanda diaria para el día miércoles, en la siguiente figura, se puede observar el comportamiento de la variación de la curva de demanda eléctrica con los datos extraídos de la data base.




**Figura 5. 54:** Comparación de demanda entre perfil de carga actual vs predicha día domingo

Mediante el análisis realizado a la figura, se observa que el perfil de carga representado de color azul representa la demanda de energía extraída de la base de datos validada en la herramienta computacional, en la cual se obtiene que para un día domingo existió una necesidad de 213 Wh para satisfacer la demanda generada, mientras que en el perfil de carga representado por color verde correspondiente a la predicción la misma herramienta predice que se va necesitar de 202,5 Wh, para desarrollar sus actividades curriculares de manera normal un día domingo, a diferencia del resto de

días en el perfil de consumo se puede observar que no existe una gran cantidad de demanda, debido a que no existe una jornada de labores académicas, exceptuando por el consumo de energía que se da a las 17:00 pm que es representada por la activación de reflectores y luminarias.

### 5.2.7.2. Error porcentual entre perfil de carga objetivo vs perfil de carga predicho domingo


Como se presentó anteriormente tanto para el día lunes y martes, en la gráfica de error entre perfiles desarrollada por la herramienta computacional se observa que el promedio del mismo no excede el 5% de error, para este día se obtiene un error porcentual del 0,83% determinando una predicción muy satisfactoria.



**Figura 5. 55:** Error porcentual existente entre demanda actual y demanda predicha día domingo

### 5.2.7.3. Diferencia entre perfil de carga objetivo vs perfil de carga predicho domingo

En este apartado se presenta la diferencia que existe entre la demanda de consumo actual y la demanda de consumo predicha.




**Figura 5. 56:** Diferencia existente entre demanda actual y demanda predicha día domingo

A diferencia del día martes, el error porcentual ponderado es muy bajo con una diferencia máxima de 9,31 Wh, debido al correcto entrenamiento de la red neuronal en la herramienta tecnológica, por lo tanto, la diferencia entre los dos perfiles de carga analizados es muy pequeña.

#### **5.2.7.4. Predicción de demanda domingo**

Es el apartado más importante del presente proyecto, ya que, en base a los filtrados, el error, diferencia de curvas de consumo, la red neuronal predice la cantidad de energía eléctrica que se va a necesitar la instalación para el mismo día de la siguiente semana, para el día miércoles, la herramienta tecnológica predice que se va a necesitar 202,6 Wh para el desarrollo de las actividades en el bloque B de la Universidad Técnica de Cotopaxi como se muestra en la siguiente figura.



**Figura 5. 57:** Predicción de demanda para el día domingo

#### 5.2.7.5. Matriz de confusión domingo

En la gráfica se observa los valores de obtenidos en la matriz de confusión, de la cual, el primer cuadro corresponde al entrenamiento, el segundo a la validación de datos, el tercero al test y el cuarto a los resultados generales de la matriz, de esta última se obtiene una síntesis de los resultados obtenidos de las tres anteriores, en donde al observar en la clase 1 se obtuvo un valor de 40,06% prediciendo un valor favorable a los verdaderos positivos, en la clase 2 se obtuvo un valor de 53,5% prediciendo un valor favorable a los verdaderos negativos, finalmente el resultado presentado por la matriz se ve un porcentaje de aceptación del 94,1%, y un error de 5,9%, es importante mencionar que la suma de los verdaderos positivos y verdaderos negativos debe ser igual al número de datos seleccionados para el análisis diario, es decir 288 valores.

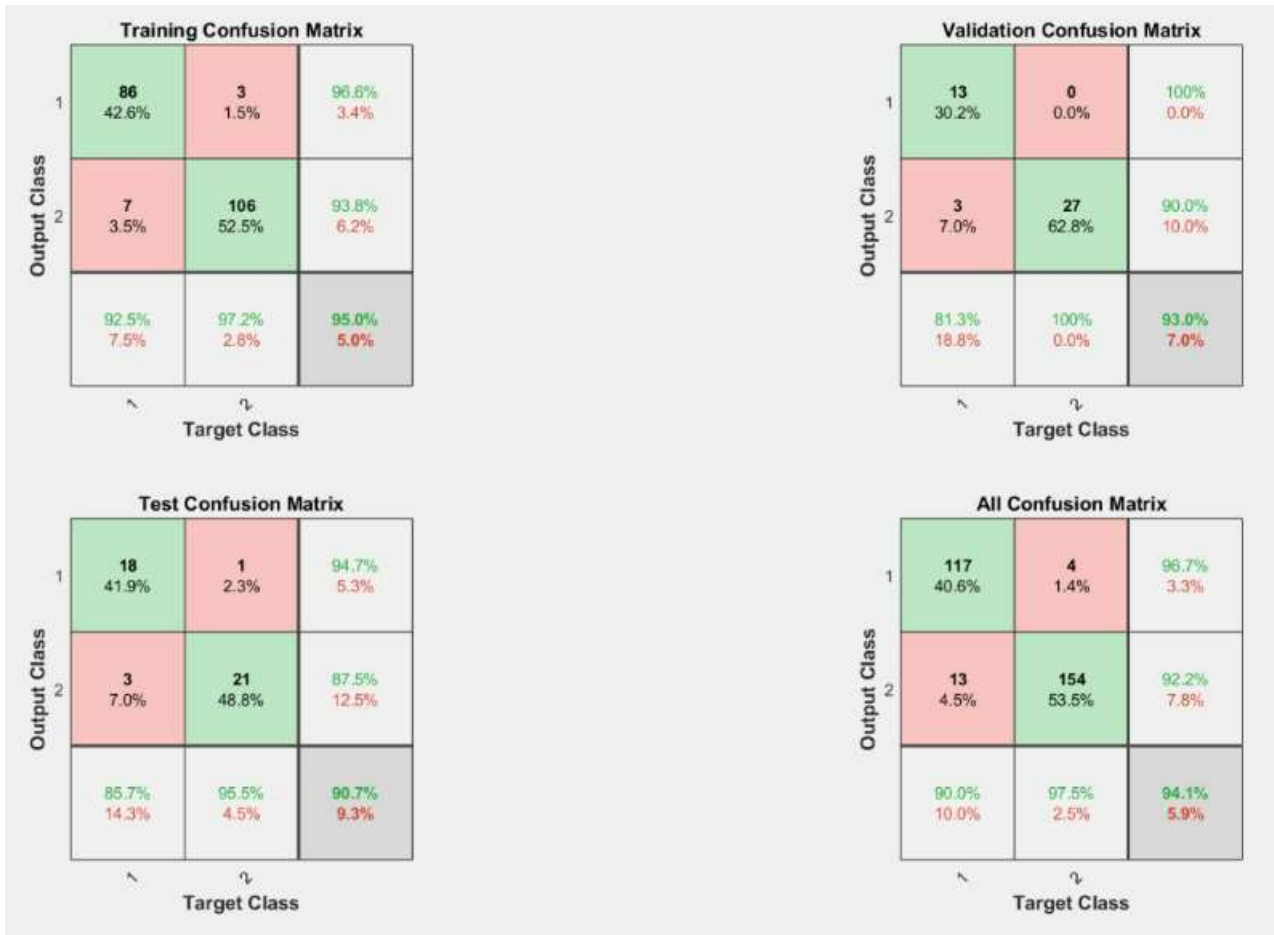


Figura 5. 58. Matriz de confusión del día domingo

Finalmente, las métricas obtenidas al desarrollar y operar la matriz de confusión son las siguientes:




Figura 5. 59: Métrica obtenida del día sábado.

La precisión encontrada al desarrollar la predicción para el día martes es de 96,69%, con una tasa de recuperación del 90%, una exactitud del 94,09% y un puntaje del 93,22%, basándonos en las métricas obtenidas se determina que la predicción realizada es muy acertada, pues los puntajes presentados sobrepasan el 93,22%, como se mencionó en el apartado anterior, debido al perfil de carga que se presenta, pues el perfil de carga tiende a tener un avance continuo hasta las 17:00 como se mencionó anteriormente.



## 6. CONCLUSIONES Y RECOMENDACIONES

### 6.1. Conclusiones

- Con la recolección de información bibliográfica se determinó las variables que intervienen en el proceso de predicción del consumo de energía eléctrica en el bloque “B” de la Universidad Técnica de Cotopaxi, además esta información facilita entender y seleccionar de manera óptima las funciones para el desarrollo del sistema computacional.
- Mediante la obtención de información utilizando el analizador de red Fluke 435 se determinó que el perfil de consumo energético del Bloque “B” de la Universidad Técnica de Cotopaxi es de características similares a la residencial, el cual inicia sus actividades subiendo su consumo eléctrico desde las 5h00 a.m. en adelante con picos que oscilan entre los 550 y 600 Wh y termina alrededor de las 23h00 p.m. los días laborales, mientras que los fines de semana el consumo eléctrico cae a un promedio de 200 Wh dando como inicio de las actividades a las 6h00 a.m. y termina a las 21h30 p.m en horario de consumo normal de UTC.
- Para el entrenamiento de la red neuronal se realizó diferentes escenarios, con el uso de varias funciones, la primera función que se ejecuto fue la función Hardlim - Tansig con la que se obtuvo un 30% de error porcentual, posterior se utilizó la función Purelin-Satlin con la cual se obtuvo un 0% de error porcentual dado que la curva de demanda de energía eléctrica sigue tendencia a la función objetivo, finalmente la función Tansig-Logsig arrojó resultados muy eficientes con el 5% de error porcentual, determinados valores de entrenamiento 75%, prueba 15%, validación 10% , por lo tanto, se trabajó con esta.
- Mediante el uso de software de ingeniería Matlab y la ejecución de librerías propias del mismo se obtuvo una herramienta computacional capaz de predecir el consumo de energía eléctrica con un error medio cuadrático de debajo del 2% y con las métricas de matriz de confusión con un puntaje (F1) de 88% el día martes y los demás días superan el 92%, de tal manera la dispersión de los datos, precisión son de 86,5% mismo martes luego de viernes superior al 91,3% determinando una herramienta perceptron multicapa muy efectiva para predicción de carga .

## 6.2. Recomendaciones

- Para aplicaciones futuras del pronóstico de consumo eléctrico en la Universidad Técnica de Cotopaxi, se recomienda realizar un análisis a mediano y largo plazo, obteniendo mayor cantidad de datos mediante un análisis continuo con el equipo de medición Fluke 435, además tener en cuenta variables demográficas del sitio que puedan ser sensibles en el pronóstico, con el fin de que permita seguir la tendencia de la demanda real.
- Se sugiere realizar mediciones continuas con el analizador de red Fluke 435 en un intervalo de tiempo menor a 5 minutos para que al graficar el perfil energético, sea más preciso y se pueda determinar de manera exacta las elevaciones de consumo.
- Al momento de entrenar la herramienta computacional se utilizó varias librerías, en la capa oculta y funciones de activación, con las cuales se obtuvo un error porcentual del 5%, se sugiere seleccionar como porcentaje de datos de entrenamiento, prueba y validación de una red neuronal en el pronóstico de demanda a corto plazo, los siguientes valores:
  - Entrenamiento: 65% de los datos.
  - Prueba: 25% de los datos.
  - Validación: 10% de los datos.
- Para aplicaciones futuras del pronóstico de demanda, se recomienda tomar una mayor cantidad de datos adicionales que puedan ser sensibles en el pronóstico, con el fin de que el mismo sea más óptimo y permita seguir la tendencia de la demanda real para un tiempo más prolongado.

## 7. 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. Mubarak 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]P. Uyaguari y P. Esteban, «Pronostico de perfiles de consumo de electricidad a través de modelos estadísticos y desarrollo de una metodología comparativa», p. 112.
- [11]A. Toapanta-Lema *et al.*, «Comparación de modelos de regresión para la eficiencia en el consumo de electricidad en las escuelas ecuatorianas: un caso de estudio», p. 11.
- [12]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.
- [13]«historia-de-la-universidad-tecnica-de-cotopaxi\_compress.pdf».
- [14]T. Gönen, *Electric Power Distribution Engineering*, Third Edition. New York: CRC Press, 2014.
- [15]P. K. Nag, *Power Plant Engineering*. Tata McGraw-Hill Education, 2008.
- [16]«Consumo Energía Eléctrica • SMARTGRIDSINFO.pdf».
- [17]«2018-01-11-Pliego-y-Cargos-Tarifarios-del-SPEE-20182.pdf».
- [18]«El impacto de la relación de consumo y demanda al costo de energía de tu negocio. – RIC Energy - Suministro de Energia.pdf».
- [19]«vsip.info\_54-estudio-del-factor-de-carga-pdf-free.pdf».
- [20]«434\_II\_smeng0100.pdf».
- [21]«TESIS\_BASTIDAS\_MOYA\_FINAL.pdf».
- [22]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.
- [23]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>

- [24]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>
- [25]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>
- [26]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>
- [27]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).
- [28]P. Isasi y I. Galván, *Redes neuronales artificiales un enfoque práctico*. Madrid: Pearson Educación S.A., 2004.
- [29]L. G. Rodríguez y A. P. Salgueiro, «Comparación de frameworks de aprendizaje profundo», p. 11.
- [30]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>
- [31]E. X. Chafra 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>
- [32]J. R. Hilera González y V. J. Martínez Hernando, *Redes neuronales artificiales : fundamentos, modelos y aplicaciones*. Madrid: RA-MA Editorial, 1995.
- [33]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>

- [34]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.
- [35]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>
- [36]A. E. Repetur, «Redes neuronales artificiales», p. 89, ago. 2019.
- [37]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).
- [38]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.
- [39]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>
- [40]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>
- [41]«Conceptos básicos sobre redes neuronales», *Vicente Rodríguez blog*. <https://vincentblog.xyz/posts/conceptos-basicos-sobre-redes-neuronales> (accedido 29 de enero de 2022).
- [42]M. Cabezón, «Predicción demanda eléctrica española. Implementación de redes neuronales recurrentes en Python», [info:eu-repo/semantics/masterThesis](https://info.eu-repo/semantics/masterThesis), 2018. Accedido: 25 de enero de 2022. [En línea]. Disponible en: <https://eprints.ucm.es/id/eprint/49444/>
- [43]«scikit-learn - 6.3.Preprocesamiento de datos - El paquete sklearn.preprocessing proporciona varias funciones de utilidad comuna - Español». [https://runebook.dev/es/docs/scikit\\_learn/modules/preprocessing](https://runebook.dev/es/docs/scikit_learn/modules/preprocessing) (accedido 31 de enero de 2022).
- [44]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).

[45]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).

## **8. ANEXOS**





**Anexo II: Instalaciones eléctricas del bloque “B” Universidad Técnica de Cotopaxi**



**Figura I. I:** Interior de tablero de distribución bloque "B"



**Figura I. II:** Verificación del funcionamiento de Analizador de red FLUKE 435.

**Anexo II: Código de programación**

```

function varargout = Tesis_Prediccion(varargin)
% TESIS_PREDICCION MATLAB code for Tesis_Prediccion.fig
%     TESIS_PREDICCION, by itself, creates a new TESIS_PREDICCION or raises
the existing
%     singleton*.
%
%     H = TESIS_PREDICCION returns the handle to a new TESIS_PREDICCION or
the handle to
%     the existing singleton*.
%
%     TESIS_PREDICCION('CALLBACK',hObject,eventData,handles,...) calls the
local
%     function named CALLBACK in TESIS_PREDICCION.M with the given input
arguments.
%
%     TESIS_PREDICCION('Property','Value',...) creates a new TESIS_PREDICCION
or raises the
%     existing singleton*. Starting from the left, property value pairs are
%     applied to the GUI before Tesis_Prediccion_OpeningFcn gets called. An
%     unrecognized property name or invalid value makes property application
%     stop. All inputs are passed to Tesis_Prediccion_OpeningFcn via
varargin.
%
%     *See GUI Options on GUIDE's Tools menu. Choose "GUI allows only one
%     instance to run (singleton)".
%
% See also: GUIDE, GUIDATA, GUIHANDLES

% Edit the above text to modify the response to help Tesis_Prediccion

% Last Modified by GUIDE v2.5 01-Feb-2023 18:03:30

% Begin initialization code - DO NOT EDIT
gui_Singleton = 1;
gui_State = struct('gui_Name',       mfilename, ...
                  'gui_Singleton',  gui_Singleton, ...
                  'gui_OpeningFcn', @Tesis_Prediccion_OpeningFcn, ...
                  'gui_OutputFcn',  @Tesis_Prediccion_OutputFcn, ...
                  'gui_LayoutFcn',  [] , ...
                  'gui_Callback',   []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargout
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
% End initialization code - DO NOT EDIT

% --- Executes just before Tesis_Prediccion is made visible.
function Tesis_Prediccion_OpeningFcn(hObject, eventdata, handles, varargin)

```

```

% This function has no output args, see OutputFcn.
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
% varargin   command line arguments to Tesis_Prediccion (see VARARGIN)

% Choose default command line output for Tesis_Prediccion
handles.output = hObject;

% Update handles structure
guidata(hObject, handles);

% UIWAIT makes Tesis_Prediccion wait for user response (see UIRESUME)
% uiwait(handles.figure1);
imagen= imread('logo-utc.png');
axes(handles.axes1);
imshow(imagen);

imagen2= imread('carrera.png');
axes(handles.axes2);
imshow(imagen2);

%%% /////////////////////////////////////////////////// MOSTRAR LOGOS DE LA CARRERA Y LA UNIVERSIDAD EN EL
%%% GUIDE

% --- Outputs from this function are returned to the command line.
function varargout = Tesis_Prediccion_OutputFcn(hObject, eventdata, handles)
% varargout  cell array for returning output args (see VARARGOUT);
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Get default command line output from handles structure
varargout{1} = handles.output;

% --- Executes on button press in Iniciar.
function Iniciar_Callback(hObject, eventdata, handles)
% hObject    handle to Iniciar (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
global XTrain
global YTrain
global v

%%% /////////////////////////////////////////////////// DECLARAR VARIABLES GLOBALES PARA UTILIZARLO EN TODAS LAS
%%% FUNCIONES

v = get(handles.menu, 'Value')
%%% /////////////////////////////////////////////////// LEO EL DIA QUE VOY A PREDECIR

XTrain=xlsread('Pruebas202',1,'C05:DJ292');
XTrain=XTrain';
%%% /////////////////////////////////////////////////// LEO LA INFORMACION DE EXCEL (DATOS)

if v==1
    YTrain=xlsread('Pruebas202',1,'DK05:DL292');
elseif v==2

```

```

YTrain=xlsread('Pruebas202',1,'DL05:DM292');
elseif v==3
    YTrain=xlsread('Pruebas202',1,'DM05:DN292');
elseif v==4
    YTrain=xlsread('Pruebas202',1,'DN05:DO292');
elseif v==5
    YTrain=xlsread('Pruebas202',1,'DO05:DP292');
elseif v==6
    YTrain=xlsread('Pruebas202',1,'DP05:DQ292');
elseif v==7
    YTrain=xlsread('Pruebas202',1,'DQ05:DR292');
end
%%% //////////////// LEO LA INFORMACION DE EXCEL (VALIDACION) SEGUN EL DIA
%%% SELECCIONADO

set(handles.mensaje,'string','-');
pause(1)
set(handles.mensaje,'string',"Datos Cargados Exitosamente");
%%% //////////////// MOSTRAR MENSAJE DE DATOS CARGADOS EXITOSAMENTE

% --- Executes on selection change in menu.
function menu_Callback(hObject, eventdata, handles)
% hObject    handle to menu (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Hints: contents = cellstr(get(hObject,'String')) returns menu contents as
cell array
%         contents{get(hObject,'Value')} returns selected item from menu

% --- Executes during object creation, after setting all properties.
function menu_CreateFcn(hObject, eventdata, handles)
% hObject    handle to menu (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% Hint: popupmenu controls usually have a white background on Windows.
%         See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

% --- Executes on button press in Prediccion.
function Prediccion_Callback(hObject, eventdata, handles)
% hObject    handle to Prediccion (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

global XTrain
global YTrain
global net
%%% //////////////// DECLARAR VARIABLES GLOBALES PARA UTILIZARLO EN TODAS LAS
%%% FUNCIONES

```

```

%%%% GENERAR LA RED

net=patternnet(5);
net.layers{1}.transferFcn = 'tansig';          % 'tansig' 'logsig' 'hardlim'
'purelin' 'satlin' 'hardlims'
net.layers{2}.transferFcn = 'logsig';          % 'tansig' 'logsig' 'hardlim'
'purelin' 'satlin' 'hardlims'
net.trainFcn = 'trainlm';                      % 'trainlm' 'trainbr' 'traingdm'
'traincgb'

net.trainParam.show = 1000;
net.trainParam.goal = 0.00000000000000000001;

net.trainParam.epochs=(300); % parametros para el ent
net.trainParam.max_fail=100;
net.trainParam.min_grad=1e-29;
net.trainParam.mu=0.1;
net.trainParam.mu_dec=0.1;
net.trainParam.mu_inc=10;

net.divideParam.trainRatio=75/100;
net.divideParam.valRatio=15/100;
net.divideParam.testRatio=10/100;

% net = newff(XTrain,YTrain,20);
configure(net,XTrain,YTrain);
net=init(net);
[net,tr] = train(net,XTrain,YTrain);
ntraintool %entren
%%%% //////////// CONFIGURACION DE LOS PARAMETROS DE LA RED

% --- Executes on button press in Graficar.
function Graficar_Callback(hObject, eventdata, handles)
% hObject    handle to Graficar (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

global XTrain
global YTrain
global net
global v
%%%% //////////// DECLARAR VARIABLES GLOBALES PARA UTILIZARLO EN TODAS LAS
%%%% FUNCIONES

cla(handles.axes3,'reset')
cla(handles.axes4,'reset')
cla(handles.axes5,'reset')
cla(handles.axes6,'reset')
%%%% //////////// LIMPIAR LOS GRAFICOS DEL GUIDE

YPredicted=net(XTrain);
x=1:1:288;
x=x/12;

```

```

axes(handles.axes3); %%%
plot(x,YTrain(1,:), 'b')
hold on
grid on
plot(x,YPredicted(1,:), 'g')
legend("Objetivo", "Predicción")
xlabel("Horas")
ylabel("Energía (Wh)")
title("Objetivo vs Predicción")
xlim([0 24])
%% %% %% //////////////// GRAFICA 1 OBJETIVO Y PREDICCION

DiferenciaWh=(YPredicted-YTrain)';
perf = perform(net,YPredicted,YTrain)
Dat=[XTrain ; YPredicted];

%% %% %% //////////////// CALCULAR LA DIFERENCIA DE CONSUMO ENTRE EL OBJETIVO Y LA
%% %% %% PREDICCION

YPredicted';
disp('*** Proceso Finalizado')

axes(handles.axes4);
plot(x,DiferenciaWh(:,1), 'b');
grid on
legend("Diferencia de Consumo")
xlabel("Horas")
ylabel("Energía (Wh)")
xlim([0 24])
ylim([-600 600])
title("Diferencia de consumo entre el Objetivo y la Predicción")

%% %% %% //////////////// GRAFICAR DIFERENCIA DE CONSUMO

% %% %% GRAFICAR TODOS LOS DIAS
% data=[];
% data2=[];
% tam=size(Dat);
% for i=1 : tam(1)-1
%     data = [data,Dat(i,:)];
% end
% for i=1 : tam(1)-2
%     data2 = [data2,Dat(i,:)];
% end

% %% %% GRAFICAR SOLO LOS DIAS ELEGIDOS
data=[];
data2=[];
k=v;
for i=1:16

    data = [data,Dat(k,:)];
    k=k+7;

end

data2=[data,YPredicted(1,:)];

```

```

xc=1:1:4896;
xc=xc/288;

xc2=1:1:4608;
xc2=xc2/288;

%%% ////////////////////////////////////////////////// GENERAR VECTOR DE LOS DIAS SELECCIONADOS (SOLO LUNES - SOLO
MARTES)

% figure(10);          %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% plot(xc,data2,'r')
% grid on
% hold on
% plot(xc2,data,'b')
% legend("Dia Predecido","Datos por semana")
% xlabel("Tiempo")
% ylabel("Energía (Wh)")
% xlim([0 18])
% title("Base de Datos mas el dia de Predicción")
% %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%% ////////////////////////////////////////////////// GRAFICO VECTOR DE LOS DIAS SELECCIONADOS (SOLO LUNES - SOLO
MARTES)

if v==1
    anterior=xlsread('Pruebas202',1,'DQ05:DQ292');
elseif v==2
    anterior=xlsread('Pruebas202',1,'DK05:DK292');
elseif v==3
    anterior=xlsread('Pruebas202',1,'DL05:DL292');
elseif v==4
    anterior=xlsread('Pruebas202',1,'DM05:DM292');
elseif v==5
    anterior=xlsread('Pruebas202',1,'DN05:DN292');
elseif v==6
    anterior=xlsread('Pruebas202',1,'DO05:DO292');
elseif v==7
    anterior=xlsread('Pruebas202',1,'DP05:DP292');
end

nuevograf = [];
nuevograf = [anterior, YPredicted(1,:)];
nuevograf2 = [];
nuevograf2 = [anterior];

xcn=1:1:576;
xcn=xcn/12;

xcn2=1:1:288;
xcn2=xcn2/12;

axes(handles.axes5)
plot(xcn, nuevograf, 'r')
hold on
grid on
plot(xcn2, nuevograf2, 'b')

```



```

legend("Dia de Prediccion","Dia Anterior")
xlabel("Tiempo")
ylabel("Energía (Wh)")
xlim([0 48])
title("Dia Anterior mas el dia de Prediccion") %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% GRAFICA DIA ANTERIOR Y DIA PREDECIDO

for i=1:length(YPredicted)
    Nerror(i) = ((YTrain(i)-YPredicted(i))/YTrain(i))*100;
end
Nerror=abs(Nerror/2);

for i=1:length(Nerror)
    if(Nerror(i)>5)
        Nerror(i)=Nerror(i)/2;
    end
end

%%% //////////////// CALCULO DEL VECTOR DE ERRORES
axes(handles.axes6);
plot(x,Nerror, 'r')
grid on
xlim([0 24])
ylim([0 20])
legend("Error Porcental")
xlabel("Tiempo")
ylabel("%")
title("Porcentaje de Error por dia")

%%% //////////////// GRAFICAR EL VECTOR DE ERRORES

for i=1:length(YPredicted)
    Resta(i)=YPredicted(i)-YTrain(i);
end

ErrorMedio=abs(sum(Nerror))/length(Nerror);
set(handles.errorporcentual,'string',ErrorMedio);

%%% //////////////// CALCULO EL ERROR MEDIO Y MUESTRO EN EL GUIDE

[c,cm,ind,per] = confusion(YTrain,YPredicted);
TP=cm(1)
FP=cm(2)
FN=cm(3)
TN=cm(4)

VP=TP;
VN=TN;

%%% //////////////// EXTRAER LOS PARAMETROS DE LA MATRIZ DE CONFUCION

Precision = TP/(TP+FP)
Recuperacion = TP/(TP+FN)
Exactitud = (VP+VN)/(VP+FP+FN+VN)
F1 = 2 * (Precision * Recuperacion) / (Precision + Recuperacion)

```

```

%%%% ////////////////////////////////////////////////// CALCULO DE LOS INDICES

set(handles.tp, 'string', TP);
set(handles.fp, 'string', FP);
set(handles.fn, 'string', FN);
set(handles.tn, 'string', TN);

set(handles.precision, 'string', Precision*100);
set(handles.recuperacion, 'string', Recuperacion*100);
set(handles.exactitud, 'string', Exactitud*100);
set(handles.fl, 'string', F1*100);
%%%% ////////////////////////////////////////////////// MOSTRAR PARAMETROS EN EL GUIDE

% --- Executes on button press in Salir.
function Salir_Callback(hObject, eventdata, handles)
% hObject    handle to Salir (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
close

% --- Executes on button press in desplegar.
function desplegar_Callback(hObject, eventdata, handles)
% hObject    handle to desplegar (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

global XTrain
global YTrain
global net
global v

YPredicted=net(XTrain);
x=1:1:288;
x=x/12;

figure(1); %%%%%%%%%%%%%%%////////////////////////////////////// CREO FIGURAS INDEPENDIENTES
plot(x, YTrain(1,:), 'b')
hold on
grid on
plot(x, YPredicted(1,:), 'g')
legend("Objetivo", "Predicción")
xlabel("Horas")
ylabel("Energía (Wh)")
title("Objetivo vs Predicción")
xlim([0 24])

DiferenciaWh=(YPredicted-YTrain)';
perf = perform(net, YPredicted, YTrain)
Dat=[XTrain ; YPredicted];

YPredicted';
disp('*** Proceso Finalizado')

figure(2)
plot(x, DiferenciaWh(:,1), 'b');
grid on

```

```

xlabel("Horas")
ylabel("Energía (Wh)")
xlim([0 24])
ylim([-600 600])
title("Diferencia de consumo entre el Objetivo y la Predicción")

% %%% GRAFICAR TODOS LOS DIAS
% data=[];
% data2=[];
% tam=size(Dat);
% for i=1 : tam(1)-1
%     data = [data,Dat(i,:)];
% end
% for i=1 : tam(1)-2
%     data2 = [data2,Dat(i,:)];
% end

% %%% GRAFICAR SOLO LOS DIAS ELEGIDOS
data=[];
data2=[];
k=v;
for i=1:16

    figure(3)
    plot(x,Dat(k,:))
    grid on
    hold on
    xlabel("Tiempo")
    ylabel("Energía (Wh)")
    xlim([0 24])
    title("Base de Datos mas el dia de Predicción")
    %%%%%%%%%%%

    data = [data,Dat(k,:)];
    k=k+7;
end
plot(x,YPredicted(1,:), 'r', 'LineWidth',2)

data2=[data,YPredicted(1,:)];

xc=1:1:4896;
xc=xc/288;

xc2=1:1:4608;
xc2=xc2/288;

%%%%%%%%%%%

if v==1
    anterior=xlsread('Pruebas202',1,'DQ05:DQ292');
elseif v==2
    anterior=xlsread('Pruebas202',1,'DK05:DK292');
elseif v==3
    anterior=xlsread('Pruebas202',1,'DL05:DL292');

legend("Diferencia de Consumo")

```

```

elseif v==4
    anterior=xlsread('Pruebas202',1,'DM05:DM292');
elseif v==5
    anterior=xlsread('Pruebas202',1,'DN05:DN292');
elseif v==6
    anterior=xlsread('Pruebas202',1,'DO05:DO292');
elseif v==7
    anterior=xlsread('Pruebas202',1,'DP05:DP292');
end

nuevograf = [];
nuevograf = [anterior, YPredicted(1,:)];
nuevograf2 = [];
nuevograf2 = [anterior];

xcn=1:1:576;
xcn=xcn/12;

xcn2=1:1:288;
xcn2=xcn2/12;

figure(4)
plot(xcn, nuevograf, 'r')
hold on
grid on
plot(xcn2, nuevograf2, 'b')
legend("Dia de Prediccion","Dia Anterior")
xlabel("Tiempo")
ylabel("Energía (Wh)")
xlim([0 48])
title("Dia Anterior mas el dia de Prediccion") %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

figure(5) %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
plot(xc,data2,'r')
grid on
hold on
plot(xc2,data,'b')
legend("Dia Predecido","Datos por semana")
xlabel("Tiempo")
ylabel("Energía (Wh)")
xlim([0 18])
title("Base de Datos mas el dia de Predicción")
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

for i=1:length(YPredicted)
    Nerror(i) = ((YTrain(i)-YPredicted(i))/YTrain(i))*100;
end
Nerror=abs(Nerror/2);

for i=1:length(Nerror)
    if(Nerror(i)>5)
        Nerror(i)=Nerror(i)/2;
    end
end
end

```

```
Nerror';  
  
figure(6)  
plot(x,Nerror, 'r')  
grid on  
xlim([0 24])  
ylim([0 20])  
legend("Error Porcental")  
xlabel("Tiempo")  
ylabel("%")  
title("Porcentaje de Error por dia")
```