

**UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD DEL CUSCO
FACULTAD DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA,
INFORMÁTICA Y MECÁNICA
ESCUELA PROFESIONAL DE INGENIERÍA ELÉCTRICA**



TESIS

**PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN
EL ALIMENTADOR QU-03 UTILIZANDO REDES NEURONALES
ARTIFICIALES EN EL PERÍODO 2023-2027**

PRESENTADA POR:

Br. GIOVANNI OSVER HUANCA TTITO
Br. JORGE HUAMAN QUISPE

**PARA OPTAR EL TÍTULO PROFESIONAL
DE INGENIERO ELECTRICISTA**

ASESOR:

Dr. EDGAR ZACARIAS ALARCON
VALDIVIA

CUSCO – PERÚ

2024

INFORME DE ORIGINALIDAD

(Aprobado por Resolución Nro.CU-303-2020-UNSAAC)

El que suscribe, **Asesor** del trabajo de investigación/tesis titulada: PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN EL ALIMENTADOR QU-03 UTILIZANDO REDES NEURONALES ARTIFICIALES EN EL PERIODO 2023-2027

Presentado por: Dr. GIOVANNI OSUNA HUANCA TITO DNI N° 44805267

presentado por: Dr. JORGE HUAMAN QUISPE DNI N° 42773218

Para optar el título profesional/grado académico de INGENIERO ELECTRICISTA

Informo que el trabajo de investigación ha sido sometido a revisión por 02 veces, mediante el Software Antiplagio, conforme al Art. 6° del **Reglamento para Uso de Sistema Antiplagio de la UNSAAC** y de la evaluación de originalidad se tiene un porcentaje de 04 %.

Evaluación y acciones del reporte de coincidencia para trabajos de investigación conducentes a grado académico o título profesional, tesis

Porcentaje	Evaluación y Acciones	Marque con una (X)
Del 1 al 10%	No se considera plagio.	☒
Del 11 al 30 %	Devolver al usuario para las correcciones.	☐
Mayor a 31%	El responsable de la revisión del documento emite un informe al inmediato jerárquico, quien a su vez eleva el informe a la autoridad académica para que tome las acciones correspondientes. Sin perjuicio de las sanciones administrativas que correspondan de acuerdo a Ley.	☐

Por tanto, en mi condición de asesor, firmo el presente informe en señal de conformidad y adjunto las primeras páginas del reporte del Sistema Antiplagio.

Cusco, 18 de JULIO de 2025


Firma

Post firma EDGAR ZACARIAS ALARCON VALDIVIA

Nro. de DNI 23821021

ORCID del Asesor 0000 - 0002 - 9168 - 7535

Se adjunta:

1. Reporte generado por el Sistema Antiplagio.
2. Enlace del Reporte Generado por el Sistema Antiplagio: oid: 27259:474145164

GIOVANI & JORGE HUAMAN & HUANCA

PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN EL ALIMENTADOR QU-03 UTILIZANDO REDES NEURONALES AR

 Universidad Nacional San Antonio Abad del Cusco

Detalles del documento

Identificador de la entrega

trn:oid:::27259:474145164

Fecha de entrega

15 jul 2025, 11:07 p.m. GMT-5

Fecha de descarga

15 jul 2025, 11:15 p.m. GMT-5

Nombre de archivo

TESIS Huanca - Huaman-TURNITIN-1.docx

Tamaño de archivo

14.0 MB

184 Páginas

30.349 Palabras

170.640 Caracteres

4% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 20 palabras)

Fuentes principales

- 4%  Fuentes de Internet
- 0%  Publicaciones
- 2%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Dr. EDGAR ZACARIAS ALARCÓN VALDIVIA
DNI N°: 23821021
ASESOR

Presentación

Señor:

Decano de la Facultad de Ingeniería Eléctrica, Electrónica, Informática Y Mecánica.

Señores:

Miembros Dictaminantes y Jurado de Tesis.

De conformidad al Reglamento de Grados y Títulos de la Escuela Profesional de Ingeniería Eléctrica de la Universidad Nacional de San Antonio Abad del Cusco, ponemos a nuestra consideración el trabajo de tesis intitulado: “Predicción de la Demanda de Energía Eléctrica en el Alimentador QU-03 Utilizando Redes Neuronales Artificiales en el Periodo 2023-2027”.

Para fines de optar el título profesional de Ingeniero Electricista de acuerdo a los aportes planteados por el jurado.

Trabajo que desarrolla estrategias y enfoques para predecir la demanda eléctrica, haciendo uso de las redes neuronales artificiales, metodología que explora esta que puede ofrecer una perspectiva única en la comprensión y predicción de los patrones de demanda eléctrica, contribuyendo así al avance y la optimización de la gestión energética para una mejor planificación en el sistema de distribución.

Giovanni Osver Huanca Ttito

Jorge Huaman Quispe

Resumen

El propósito principal de este trabajo se enfocó en emplear las redes neuronales para analizar la demanda eléctrica en el alimentador primario QU-03 en el periodo 2023-2027. La metodología se fundamentó en el uso de redes neuronales, un tipo de aprendizaje automático que se basa en algoritmos de aprendizaje, así como en los principios relacionados con la demanda eléctrica. Se comenzó con una descripción detallada del alimentador QU-03 para comprender sus especificaciones técnicas, seguido por la recopilación de datos históricos que abarcaban la evolución de la demanda en este alimentador. Una vez recopilados estos datos, se procedió con la fase de entrenamiento y aprendizaje utilizando el lenguaje de programación Python con el fin de realizar predicciones sobre la demanda eléctrica futura. Estos resultados obtenidos fueron comparados con las series de tiempo, con la finalidad de conocer la confiabilidad de esta metodología. Esta comparación reveló una consistencia notable entre las predicciones generadas por las redes neuronales y las tendencias observadas en las series de tiempo históricas de la demanda eléctrica. La cercanía entre los datos pronosticados y los datos reales reforzó la validez y precisión de la metodología propuesta. Estos resultados subrayaron la capacidad de las redes neuronales para realizar estudios de la demanda eléctrica y proporcionar proyecciones confiables para un periodo a mediano plazo, lo que respalda la relevancia de nuestro análisis en la comprensión y predicción de los patrones de consumo de energía eléctrica. Se concluyó que esta aplicación presentó un error inferior al 12% en comparación con otras metodologías tradicionales, lo que sugiere su idoneidad para aplicaciones futuras en el estudio de la demanda eléctrica.

Palabras Clave: Redes Neuronales, Demanda Eléctrica, Proyección de la demanda, Planificación Eléctrica.

Abstract

The main purpose of this work focused on using neural networks to analyze the electrical demand in the QU-03 primary feeder in the period 2023-2027. The methodology was based on the use of neural networks, a type of machine learning that is based on learning algorithms, as well as principles related to electrical demand. It began with a detailed description of the QU-03 feeder to understand its technical specifications, followed by the collection of historical data covering the evolution of demand on this feeder. Once this data was collected, the training and learning phase proceeded using the Python programming language in order to make predictions about future electricity demand. These results obtained were compared with the time series, in order to know the reliability of this methodology. This comparison revealed notable consistency between the predictions generated by the neural networks and the trends observed in historical time series of electricity demand. The closeness between the predicted data and the actual data reinforced the validity and precision of the proposed methodology. These results underlined the ability of neural networks to perform electricity demand studies and provide reliable projections for a medium-term period, supporting the relevance of our analysis in understanding and predicting electrical energy consumption patterns. It was concluded that this application presented an error of less than 10% compared to other traditional methodologies, which suggests its suitability for future applications in the study of electrical demand.

Keywords: Neural Networks, Electrical Demand, Demand Projection, Electrical Planning.

ÍNDICE

CARÁTULA.....	i
PRESENTACIÓN.....	ii
RESUMEN.....	iii
ABSTRACT.....	iv
ÍNDICE DE CONTENIDO.....	v
LISTADO DE TABLAS.....	xiv
LISTADO DE FIGURAS.....	xv
GLOSARIO DE TÉRMINOS.....	xvii
1. ASPECTOS GENERALES.....	1
1.1. Introducción.....	1
1.2. Ámbito Geográfico.....	1
1.3. El Problema.....	6
1.3.1. Planteamiento del Problema.....	6
1.3.2. Formulación del Problema.....	8
1.3.2.1. Problema General.....	8
1.3.2.2. Problemas Específicos.....	8
1.4. Objetivos.....	8
1.4.1. Objetivo General.....	8
1.4.2. Objetivos Específicos.....	8
1.5. Justificación del Estudio.....	9
1.6. Alcances de la Investigación.....	11

1.7.	Limitaciones de la Investigación	12
1.8.	Hipótesis.....	13
1.8.1.	Hipótesis General.....	13
1.8.2.	Hipótesis Específicas	13
1.9.	Operacionalización de Variables	13
1.10.	Metodología.....	14
1.10.1.	Tipo de investigación.....	14
1.10.2.	Nivel de investigación.....	14
1.10.3.	Enfoque de investigación.....	14
1.10.4.	Diseño de investigación	15
1.11.	Población y Muestra	15
1.12.	Procesamiento de Datos.....	15
1.13.	Técnicas de Recolección de Datos	16
1.14.	Matriz de Consistencia	16
2.	MARCO TEÓRICO	18
2.1.	Introducción.....	18
2.2.	Antecedentes de Estudio.....	18
2.2.1.	Antecedentes Nacionales	18
2.2.2.	Antecedentes Internacionales.....	20
2.3.	Fundamentos de las Redes Neuronales	23
2.3.1.	Inteligencia Artificial	23

2.3.2.	¿Qué Es Una Red Neuronal?	23
2.3.3.	Elementos Básicos Que Componen Una Red Neuronal	23
2.3.4.	Estructura De Una Neurona Artificial	24
2.3.5.	Entradas De Una Neuronal Artificial.....	24
2.3.6.	Pesos Sinápticos.....	24
2.3.7.	Funciones De Activación	25
2.3.7.1.	Función limitador fuerte	25
2.3.7.1.1.	Función limitador fuerte simétrico.....	26
2.3.7.1.2.	Función lineal.....	27
2.3.7.1.3.	Función sigmoide.....	28
2.3.7.1.4.	Función sigmoidal tangente hiperbólica	28
2.3.7.1.5.	Función ReLU.....	29
2.3.8.	Salida De Una Neuronal Artificial.....	30
2.3.9.	Formas De Interconexión Y Topología	30
2.3.10.	Mecanismo de Aprendizaje.....	31
2.3.10.1.	Aprendizaje supervisado	31
2.3.10.2.	Aprendizaje no supervisado	32
2.3.11.	Backpropagation	32
2.3.12.	Métodos De Inteligencia Artificial	33
2.3.13.	Redes Neuronales Artificiales.....	34
2.3.14.	Ventajas De Las Redes Neuronales Artificiales	34

2.3.14.1.	Aprendizaje Adaptativo	34
2.3.14.2.	Autoorganización.....	34
2.3.14.3.	Tolerancia a fallos.....	35
2.3.14.4.	Modelación no lineal.....	35
2.4.	Sistema De Distribución De Energía Eléctrica.....	35
2.4.1.	Tipos De Diseño De Sistemas De Distribución.....	36
2.4.1.1.	Tipo radial.....	36
2.4.1.1.1.	Configuración tipo radial simple	36
2.4.1.1.2.	Configuración Tipo Radial Expandido	37
2.4.1.1.3.	Configuración Tipo Radial con Uniones	37
2.4.1.2.	Configuración tipo anillo	38
2.4.2.	Clasificación De Los Sistemas De Distribución.....	39
2.4.2.1.	Subsistema de distribución primaria.....	39
2.4.2.2.	Subsistema de distribución secundaria	39
2.4.3.	Componentes Básicos de un Sistema de Distribución.....	39
2.4.3.1.	Subestación Transformadora	39
2.4.3.2.	Transformador de Potencia	40
2.4.3.3.	Alimentadores	40
2.4.3.4.	Subestación De Distribución.....	40
2.4.4.	Subestaciones Según El Tipo De Servicio.....	40
2.4.4.1.	Servicio público	40

2.4.4.2.	Servicio particular	40
2.4.5.	Subestaciones de Acuerdo al Tipo de Carga.....	41
2.4.5.1.	Cargas residenciales	41
2.4.5.2.	Cargas comerciales	41
2.4.5.3.	Cargas industriales	41
2.4.6.	Subestaciones Según El Tipo De Instalación.....	41
2.4.6.1.	Subestación de distribución monoposte	41
2.4.6.2.	Subestación de distribución biposte.....	41
2.4.6.3.	Subestación de distribución tipo caseta	42
2.4.6.4.	Subestación de distribución tipo compacta.....	42
2.4.7.	Subestaciones Según El Nivel De Tensión En El Secundario	42
2.5.	Pérdidas de Energía	42
2.5.1.	Factores influyentes en la gestión de la empresa	43
2.5.2.	Pérdidas Técnicas de Energía	44
2.5.3.	Pérdidas No Técnicas de Energía	44
2.5.4.	Pérdidas por la variación de la demanda.....	45
2.6.	Análisis De La Demanda	45
2.6.1.	Demanda eléctrica.....	45
2.6.2.	Demanda máxima	46
2.6.3.	Importancia de la Demanda Máxima.....	47
2.6.4.	Factor de simultaneidad	47

2.6.5.	Factor de carga.....	48
2.6.6.	Curva de la demanda.....	48
2.6.7.	Factor de pérdidas	49
2.7.	Tendencia Logística como Modelo de Crecimiento.....	49
2.8.	Precisión de Pronóstico	50
2.8.1.	Error Porcentual Absoluto Medio MAPE.....	51
2.8.2.	Error Absoluto Medio MAE	51
2.9.	Flujo de Potencia	52
2.9.1.	Ecuaciones Fundamentales del Flujo de Potencia	53
2.9.2.	Métodos de Solución del Flujo de Potencia.....	53
2.9.2.1.	Método de Gauss-Seidel	53
2.9.2.2.	Método de Newton-Raphson	54
2.9.2.3.	Métodos Basados en Teoría de Grafos	54
2.9.3.	Importancia del Análisis de Flujo de Potencia	54
2.10.	Producto Bruto Interno (PBI)	54
2.11.	Importancia del PBI.....	55
3.	DESCRIPCIÓN ACTUAL DEL ALIMENTADOR QU-03	56
3.1.	Introducción.....	56
3.2.	Descripción de la Subestación de Transformación Quencoro.....	56
3.3.	Descripción del Alimentador QU-03.....	58
3.4.	Tipos de Conductores Utilizados en el Alimentador QU-03.....	58

3.4.1.	Conductores Tipo Subterráneos	58
3.4.2.	Conductores Tipo Aéreos	59
3.5.	Clasificación de las Subestaciones del Alimentador QU-03	60
3.5.1.	Según el Tipo de Servicio	60
3.5.2.	Según el Tipo de Instalación	61
3.5.3.	Según el Nivel de Tensión en el Secundario	61
3.5.4.	Según la Potencia Instalada	61
3.5.5.	Distribución del Tipo de Alumbrado Público	62
3.6.	Análisis del Producto Bruto Interno (PBI) Histórico 2018 - 2023	63
3.6.1.	Análisis de la evolución del PBI para el sector Cusco	63
3.7.	Demanda Actual del Alimentador QU-03	64
4.	IMPLEMENTACIÓN DE LAS REDES NEURONALES PARA EL PRONÓSTICO DE LA DEMANDA EN EL ALIMENTADOR QU-03	71
4.1.	Introducción	71
4.2.	Definición del Horizonte de Estudio	71
4.2.1.	Corto Plazo (hasta 2 años)	71
4.2.2.	Mediano Plazo (de 2 a 5 años)	71
4.2.3.	Largo Plazo (de 5 a 10 años):	72
4.3.	Diagrama de Flujo para el Diseño de la Red Neuronal	72
4.4.	Descripción del diagrama de flujo	73
4.4.1.	Preprocesamiento de datos	73
4.4.2.	Partición de los datos de prueba Training - Test	74

4.4.3.	Entrenamiento de la red neuronal	74
4.4.3.1.	Arquitectura de la Red Neuronal	74
4.4.4.	Evaluación de resultados.....	75
4.4.5.	Modelo validado para la predicción.....	75
4.5.	Crecimiento Histórico de la Demanda en el Alimentador QU-03.....	76
4.6.	Procedimiento de la Metodología.....	86
4.7.	Selección de Variables.....	88
4.8.	Elección del Conjunto de Entrenamiento y Test	88
4.8.1.	Conjunto de Entrenamiento	88
4.8.2.	Conjunto de Prueba.....	89
4.9.	Diseño de la Red Neuronal para la predicción de la Demanda	89
4.9.1.	Pasos Temporales.....	89
4.9.2.	Configuración de la Red Neuronal	89
4.10.	Entrenamiento de la Red Neuronal.....	91
4.11.	Optimización del rendimiento de la Red Neuronal	91
4.11.1.	Cantidad de Capas.....	91
4.11.2.	Función de activación	93
4.11.3.	Optimizadores para modelos Keras	94
4.12.	Evaluación de Parámetros del Modelo Predictivo.....	95
4.13.	Resultados de la Predicción de la Demanda años 2023 al 2027.....	99
4.14.	Análisis de la Demanda Máxima.....	109

4.15. Simulación de flujo de potencia del Alimentador QU 03	113
4.16. Definición de los Resultados	116
4.16.1. Cargabilidad en los transformadores	116
4.16.2. Cargabilidad en las líneas	121
4.16.3. Pérdidas de energía del alimentador QU 03	122
5. ANÁLISIS COMPARATIVO CON LA IMPLEMENTACIÓN DE LAS SERIES TEMPORALES	127
5.1. Introducción.....	127
5.2. Método de Predicción de la Demanda Eléctrica mediante la Tendencia Logística.....	127
5.2.1. Tendencia Logística	128
5.3. Análisis Comparativo con la Tendencia Logística	128
CONCLUSIONES.....	133
RECOMENDACIONES	134
BIBLIOGRAFÍA.....	135
ANEXOS.....	139
ANEXO A	140
ANEXO B	145
ANEXO C	163

ÍNDICE DE TABLAS

Tabla 1-1	Características de los transformadores de potencia de la SET Quencoro	2
Tabla 1-2	Datos técnicos del alimentador QU 03	2
Tabla 1-3	Variable Independiente (Predictora).....	13
Tabla 1-4	Variable Dependiente (Endógena).....	14
Tabla 3-1	Datos Generales del Alimentador QU-03.....	58
Tabla 3-2	PBI sector Electricidad, Gas y Agua años 2018 – 2023.....	63
Tabla 3-3	Demanda de Energía del Alimentador QU-03 año 2023.....	65
Tabla 4-1	Crecimiento de la demanda años 2018 al 2022	76
Tabla 4-2	Tabla comparativa con la manipulación del nro. de capas	92
Tabla 4-3	Tabla comparativa con la manipulación de la función de activación.....	93
Tabla 4-4	Tabla comparativa de los optimizadores para modelos Keras	95
Tabla 4-5	Márgenes de Desviación (MW-h) por Año y Número de Capas	97
Tabla 4-6	Predicción de la demanda años 2023 al 2027	99
Tabla 4-7	Demanda máxima de las SEDS del alimentador QU-03 año 2027	110
Tabla 4-8	Cargabilidad en los transformadores del alimentador QU-03 año 2027 ..	116
Tabla 4-9	Cargabilidad en las líneas del alimentador QU-03 año 2027	121
Tabla 4-10	Pérdidas del alimentador QU-03 año 2027.....	123
Tabla 4-11	Tabla de pérdidas de energía del alimentador QU-03 año 2027	124
Tabla 5-1	EPAM para una tendencia logística.....	129
Tabla 5-2	Tabla comparativa del error absoluto medio de las series de tiempo	131

ÍNDICE DE FIGURAS

Figura 1-1 SET Quencoro 138/34.5/10.5 kV	3
Figura 1-2 Distribución del alimentador QU 03 en la ciudad del Cusco.....	5
Figura 1-3 Comportamiento de la demanda AMT QU-03, años 2018-2023.....	7
Figura 2-1 Ejemplo de una red neuronal	23
Figura 2-2 Estructura de una neurona artificial	24
Figura 2-3 Gráfica de una función limitador fuerte	26
Figura 2-4 Función limitador fuerte simétrico.....	27
Figura 2-5 Función lineal.....	27
Figura 2-6 Función sigmoide.....	28
Figura 2-7 Función sigmoideal tangente hiperbólica	29
Figura 2-8 Función ReLU.....	29
Figura 2-9 Esquema de una red neuronal artificial.....	30
Figura 2-10 Aprendizaje supervisado	31
Figura 2-11 Aprendizaje no supervisado	32
Figura 2-12 Clasificación de los métodos de predicción.....	33
Figura 2-13 Esquema general del sistema de distribución	36
Figura 2-14 Topología tipo radial simple	37
Figura 2-15 Topología tipo radial expandido	37
Figura 2-16 Topología tipo radial con uniones.....	38
Figura 2-17 Topología tipo anillo	38
Figura 2-18 Subestación de transformación Quencoro.....	39
Figura 2-19 Tipos de Pérdidas en Sistemas Eléctricos: Técnicas y No Técnicas.....	44
Figura 2-20 Curva de la Demanda	48
Figura 2-21 Ejemplo de un modelo de tendencia logística.....	50

Figura 3-1 Diagrama unifilar SET Quencoro	57
Figura 3-2 Conductores subterráneos utilizados en el alimentador QU-03.....	59
Figura 3-3 Conductores aéreos utilizados en el alimentador QU-03.....	60
Figura 3-4 Distribución AMT QU-03 según el tipo de servicio.....	60
Figura 3-5 Distribución del AMT QU-03 según el tipo de instalación	61
Figura 3-6 Número de subestaciones AMT QU-03 por potencia instalada.....	62
Figura 3-7 Distribución del tipo de luminaria del alimentador QU-03	62
Figura 4-1 Diagrama de flujo.....	73
Figura 4-2 Crecimiento de la demanda año 2018 al 2023	84
Figura 4-3 Estructura de la Red neuronal para el pronóstico de la demanda	90
Figura 4-4 Gráfico de pérdidas para 5capas y una validación de 100 épocas	92
Figura 4-5 Gráfico de pérdidas para una función de activación Softmax	93
Figura 4-6 Gráfico de pérdidas para ReLU, Sigmoide y Tanh.....	94
Figura 4-7 Pérdidas para los optimizadores RMSprop y Adam	95
Figura 4-8 Tendencia de la red neuronal con respecto a los datos observados para cada año	96
Figura 4-9 Demanda real vs predecida por la red neuronal	98
Figura 4-10 Crecimiento de la demanda AMT QU-03 años 2018 al 2027.....	108
Figura 4-11 Diagrama del factor de carga AMT QU-03	109
Figura 4-12 Diagrama de flujo de potencia AMT QU-03, proyección año 2027....	115
Figura 4-13 Crecimiento de la demanda considerando las pérdidas técnicas en el AMT QU-03 años 2018 al 2027	125
Figura 5-1 Comparación de la demanda predecida por la red neuronal y la tendencia logística	130

GLOSARIO DE TÉRMINOS

Término	Significado
RNA	Red Neuronal Artificial
NTCSE	Norma Técnica de Calidad de Suministro Eléctrico
SED	Subestación de Distribución
AMT	Alimentador de Media Tensión
QU-03	Alimentador de la Subestación de Transformación Quencoro 03
QU	Alimentador de la Subestación de Transformación Quencoro
DO	Alimentador de la Subestación de Transformación Dolorespata
CNE	Código Nacional de Electricidad
SET	Subestación Transformadora
ELSE	Electro Sur Este S.A.A.
kW	Kilo Watt
kW- h	Kilo Watt-hora
RMSE	Error Cuadrático Medio
RELU	Rectified Lineal Unit (unidad lineal rectificada)
MAPE	Error Porcentual Absoluto Medio
EAM	Error Absoluto Medio
LCE	Ley de Concesiones Eléctrica
OSINERMING	Organismo Supervisor de la Inversión en Energía y Minería
MINEM	Ministerio de Energía y Minas
CNE	Código Nacional de Electricidad
NBT	Nodo de Baja Tensión
NMT	Nodo de Media Tensión

CAPÍTULO I

ASPECTOS GENERALES

1.1. Introducción

Conocer la demanda eléctrica es fundamental para dimensionar adecuadamente los equipos en el sistema de distribución de energía. La falta de planificación por parte de las empresas distribuidoras puede llevar a decisiones precipitadas y poco eficientes, resultando en pérdidas económicas y energéticas significativas. Por ello, una planificación efectiva por parte de las empresas concesionarias, enfocada en la optimización de recursos, garantiza el abastecimiento continuo de una demanda en crecimiento, cumpliendo con los estándares de calidad establecidos por el NTCSE.

En este capítulo se aborda el área de influencia del proyecto, se desarrolla el planteamiento del problema, se establecen la formulación y los objetivos de la investigación. Además, se detalla la metodología utilizada para llevar a cabo el trabajo.

1.2. Ámbito Geográfico

El presente trabajo se desarrollará en la ciudad del Cusco, en el área de concesión de la empresa ELSE conformada por la troncal y los ramales del alimentador primario de la Subestación de Transformación Quencoro.

La subestación de Quencoro ubicada en el distrito de San Jerónimo, posee 02 transformadores de potencia de tres devanados de características que se muestran en la tabla 4-1, los que mediante una barra de 10.5 kV suministran a 07 circuitos o alimentadores.

Tabla 1-1*Características de los transformadores de potencia de la SET Quencoro*

Ítem	Potencia (MW)	Tensión (kV)	Conexión
TF 1 - 3Ø	20/6/14	132±8x1.25/34.5/10.5	Yn/Yn0/d11
TF 2 - 3Ø	10/3/7	132±8x1.25/34.5/10.5	Yn/Yn0/d11

Fuente: Elaboración propia

Tabla 1-2*Datos técnicos del alimentador QU 03***Especificaciones Generales**

Característica	Unidad	Valor Especificado
Configuración de la línea	-	Radial aérea y Subterránea
Cantidad de fases	-	Trifásico
Tensión de operación	kV	10.5
Frecuencia de la red	Hz	60
Altitud de operación	msnm	3117 - 3716
Elementos estructurales	-	Postes de concreto C.A.C. (12/200 – 12/300)
Crucetas y aislamiento	-	Crucetas de acero galvanizado o madera tratada, aisladores tipo 25 de perno PIN o de suspensión
Protecciones implementadas	-	Fusibles tipo Cut-Out, reconectores y recloser con fusibles en porta fusibles

Características del Conductor de Media Tensión


Característica	Unidad	Valor Especificado
Tipo de cable utilizado	-	AAAC - NAXSZSY
Secciones disponibles	mm ²	35 – 50 – 75 – 90 - 120
Carga de rotura del conductor	kN	32
Peso por unidad de longitud	kg/km	260
Módulo de elasticidad	kN/mm ²	62
Coeficiente de dilatación térmica	10 ⁻⁶ / °C	17.8

Parámetros de la Red de Baja Tensión

Característica	Unidad	Valor Especificado
Tensión nominal de operación	kV	0.22-0.38-0.44 - 3Ø
Tipos de conductor	-	Terna simple o doble
Método de instalación	-	Autoportante con sistema CPI
Secciones de conductor utilizadas	mm ²	16-25-35-50-70-120

Fuente: Electro Sur Este SAA

Figura 1-1
SET Quencoro 138/34.5/10.5 kV



Fuente. Centro de operaciones Electro Sur Este, 2022.

Esta subestación opera con tres niveles de tensión: 138 kV, 34.5 kV y 10.5 kV. El nivel de 138 kV corresponde a las líneas de transmisión de alta tensión que provienen de otras centrales o subestaciones, como Machupicchu-Quencoro, Quencoro-Tintaya y Dolorespata-Quencoro. Estas líneas alimentan la subestación a través de un sistema de barras, denominadas Barra A y Barra B, las cuales permiten la conexión entre los diferentes elementos del sistema y proporcionan flexibilidad operativa.

En la subestación, la reducción de tensión se lleva a cabo mediante dos transformadores de potencia, identificados como T80-131 y T47-131, los cuales disminuyen la tensión de 138 kV a 34.5 kV. Posteriormente, a través de un segundo sistema de transformación, la energía es convertida a 10.5 kV para su distribución a nivel local. Este proceso es crucial para garantizar que la energía pueda ser utilizada de manera eficiente y segura en distintos sectores de consumo.


El diagrama unifilar muestra diversos componentes esenciales para el funcionamiento de la subestación. Entre ellos, se pueden identificar los interruptores y seccionadores, dispositivos encargados de la maniobra y protección de los circuitos. También se incluyen los transformadores de corriente (TC) y transformadores de potencial (TP), los cuales permiten la medición de variables eléctricas y el correcto funcionamiento de los sistemas de protección.

En el nivel de 10.5 kV, se encuentran los alimentadores que distribuyen la energía a distintas zonas de la ciudad. Estos alimentadores, identificados como QU-01, QU-02, QU-03, QU-04, etc., llevan la energía transformada a redes de media y baja tensión para su consumo en áreas residenciales, comerciales e industriales. Cada alimentador está equipado con dispositivos de protección, como relés y fusibles, que garantizan la seguridad y estabilidad del suministro eléctrico ante posibles fallas o sobrecargas.

Además, la subestación cuenta con un sistema de puesta a tierra y sistemas auxiliares que aseguran la correcta operación y seguridad de los equipos.

Figura 1-2

Distribución del alimentador QU 03 en la ciudad del Cusco



Fuente. Base de Datos GIS – ELSE, 2023.

1.3. El Problema

1.3.1. Planteamiento del Problema

Uno de los principales desafíos que enfrentan las empresas distribuidoras de energía eléctrica es garantizar un suministro adecuado para satisfacer la creciente demanda de energía en la ciudad del Cusco y sus distritos circundantes. En los últimos años, se ha observado un incremento significativo en el consumo de energía debido a la incorporación de nuevas cargas y la expansión de las redes eléctricas. Este crecimiento genera una mayor presión sobre los alimentadores, afectando su capacidad operativa y aumentando el riesgo de sobrecargas o fallas en el sistema de distribución.

A pesar de la importancia de anticipar estos cambios en la demanda, los métodos tradicionales de pronóstico suelen presentar limitaciones en la precisión de sus estimaciones, lo que dificulta la toma de decisiones estratégicas para la operación y mantenimiento del sistema eléctrico. La falta de modelos de predicción eficaces puede conducir a una inadecuada planificación de la infraestructura, afectando la confiabilidad del servicio y aumentando los costos operativos de las empresas distribuidoras.


En este contexto, surge la necesidad de desarrollar un modelo de predicción de la demanda eléctrica que permita mejorar la planificación y gestión del sistema de distribución. Para abordar esta problemática, se propone la implementación de un modelo basado en redes neuronales artificiales, el cual emplea algoritmos avanzados de aprendizaje automático para analizar patrones históricos de consumo y generar predicciones más precisas. Este enfoque permitirá optimizar la toma de decisiones, minimizando el riesgo de sobrecargas y garantizando un suministro eficiente y confiable.

El presente estudio se centrará en el Alimentador QU-03, perteneciente a la Subestación Eléctrica Quencoro, debido a que presenta la mayor cantidad de transformadores dentro de su red. Su selección como caso piloto permite evaluar la aplicabilidad del modelo de predicción en un escenario representativo del sistema de distribución eléctrica en Cusco. Sin embargo, la

metodología propuesta podría extenderse a otros alimentadores, brindando una herramienta flexible para la gestión de la demanda en toda la red de distribución.

Figura 1-3

Comportamiento de la demanda AMT QU-03, años 2018-2023



Fuente. Base de Datos GIS – ELSE, 2023.

Los datos recopilados evidencian un crecimiento constante en el consumo eléctrico. En 2018, la demanda anual registrada fue de 14,098.04 MWh, incrementándose a 15,062.98 MWh en 2019 y alcanzando los 15,916.34 MWh en 2020. En 2021, el consumo se disparó a 20,622.51 MWh, principalmente debido al confinamiento por la pandemia de COVID-19, que generó un mayor uso de energía en los sectores residenciales. Para el año 2022, la demanda máxima registrada en el mes de septiembre fue de 139.26 MW, reflejando un incremento del 7.29% respecto a 2021, impulsado por la reactivación económica en la región (Memoria Anual ELSE, 2022).

Dada la tendencia creciente de la demanda y la necesidad de mejorar la precisión de las proyecciones de consumo, esta investigación busca proporcionar una solución innovadora basada en inteligencia artificial. El uso de redes neuronales artificiales permitirá generar

predicciones más confiables, facilitando la toma de decisiones estratégicas y garantizando la eficiencia del sistema de distribución eléctrica en Cusco durante el periodo 2023-2027.

1.3.2. Formulación del Problema

1.3.2.1. Problema General

¿De qué manera la utilización de las redes neuronales artificiales podrá mejorar el nivel de la precisión de la demanda de energía eléctrica del alimentador QU-03 para el periodo 2023-2027?

1.3.2.2. Problemas Específicos

1. ¿Cómo influye la arquitectura de la red neuronal artificial en la precisión de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027?
2. ¿De qué manera influye la selección de las variables de entrada en el desempeño predictivo de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027?
3. ¿De qué manera influye los parámetros de entrenamiento de la red neuronal artificial en la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027?

1.4. Objetivos

1.4.1. Objetivo General

Utilizar las redes neuronales artificiales para mejorar la precisión en la predicción de la demanda de energía eléctrica del alimentador QU-03 para el período 2023-2027.

1.4.2. Objetivos Específicos

1. Analizar el impacto de la arquitectura de la red neuronal artificial en la precisión de la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2025.

2. Analizar el impacto de la selección de las variables de entrada en el desempeño predictivo de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027.
3. Analizar el impacto de los parámetros de entrenamiento de la red neuronal artificial en la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027.

1.5. Justificación del Estudio

La predicción de la demanda eléctrica es un aspecto fundamental en la planificación y operación del sistema de distribución de energía. Una estimación precisa permite a las empresas distribuidoras optimizar la gestión de la infraestructura eléctrica, reducir riesgos de sobrecarga y mejorar la eficiencia en la distribución de energía. Asimismo, facilita la toma de decisiones estratégicas en la expansión y mantenimiento de las redes eléctricas, asegurando un suministro confiable y sostenible para los usuarios.

En este contexto, la presente investigación busca contribuir al desarrollo de métodos de predicción más precisos mediante la implementación de redes neuronales artificiales, una técnica basada en inteligencia artificial que permite analizar patrones complejos en grandes volúmenes de datos. A diferencia de los métodos tradicionales de pronóstico, que suelen presentar limitaciones en la captura de variaciones no lineales y tendencias emergentes, las redes neuronales tienen la capacidad de adaptarse y mejorar su precisión con el tiempo, proporcionando proyecciones más confiables.

Este estudio adquiere especial relevancia debido a la falta de investigaciones previas sobre la predicción de la demanda en el alimentador QU-03, perteneciente a la Subestación Eléctrica Quencoro en Cusco. Dado el crecimiento sostenido del consumo eléctrico en la región, resulta crucial contar con herramientas que permitan anticipar futuras necesidades energéticas y garantizar la estabilidad del sistema de distribución. Además, la metodología

propuesta no solo beneficiará a este alimentador en particular, sino que podrá ser replicada en otros alimentadores del área de concesión de la empresa ELSE, ampliando su aplicabilidad en la planificación energética regional.

Finalmente, este estudio también tiene un impacto significativo en la formulación de políticas energéticas y en la optimización de costos para el sector comercial e industrial. Los resultados obtenidos podrán ser utilizados por instituciones gubernamentales y organismos reguladores para mejorar la toma de decisiones en la fijación de tarifas eléctricas y en el desarrollo de estrategias de eficiencia energética. De igual manera, investigadores y académicos podrán aprovechar esta investigación como base para la generación de nuevos estudios en el campo del modelado y predicción de la demanda eléctrica.

1. El Alimentador QU-03, que abastece una parte significativa de la ciudad, está experimentando un rápido crecimiento en la demanda debido a la expansión urbana y la aparición de nuevas cargas. Esta investigación ayudará a prever las necesidades futuras del alimentador, permitiendo a las autoridades y empresas de energía planificar adecuadamente la expansión de la red. Así, se evitarán problemas de sobrecarga y se garantizará que la infraestructura eléctrica pueda soportar el crecimiento proyectado de la demanda en el período 2023-2027.
2. La predicción precisa de la demanda de energía eléctrica es crucial para la planificación y gestión eficiente del sistema de distribución. Utilizando redes neuronales artificiales, se pueden anticipar variaciones en la demanda con mayor exactitud, lo que permitirá a las empresas distribuidoras ajustar su infraestructura y recursos de manera proactiva. Esto incluye la optimización de la capacidad de los transformadores, la mejora de la gestión de carga y la reducción de costos operativos, asegurando un suministro de energía más confiable y eficiente.

3. Implementar redes neuronales artificiales para la predicción de la demanda de energía representa un avance significativo en el uso de tecnologías avanzadas en el sector energético. Este enfoque no solo mejora la precisión de las predicciones en comparación con los métodos tradicionales, sino que también demuestra el potencial de la inteligencia artificial para resolver problemas complejos en la gestión de la energía. La adopción de estas tecnologías innovadoras fomentará la eficiencia operativa y la toma de decisiones basada en datos, estableciendo un nuevo estándar en el manejo de redes de distribución eléctrica.

Los aportes del trabajo de tesis denominado “**PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN EL ALIMENTADOR QU-03 UTILIZANDO REDES NEURONALES ARTIFICIALES EN EL PERIODO 2023-2027**”, son:

- **Desde el punto de vista metodológico.** – Las Redes Neuronales tienen un nivel aceptable para resolver diversos problemas, mediante este método se desarrollará la metodología para predecir la demanda futura; así también se demostrarán los resultados comparándolos con otros métodos de pronóstico de la demanda.
- **Desde el punto de vista Social.** –Al tener una buena predicción en el estudio de la demanda, se podrá tener una mejor planificación y por ende no se tendrán inconvenientes para implementar cargas futuras en diversos sectores, beneficiando tanto a clientes como a usuarios. Estos incluyen escuelas, centros de salud, centros comerciales, parques y otros lugares donde se requiere un suministro eléctrico confiable y adecuado para satisfacer las necesidades de las personas.

1.6. Alcances de la Investigación

- Analizar el fundamento teórico de las RNA y sus aplicaciones en la predicción de la demanda eléctrica, con énfasis en su implementación en sistemas de distribución de energía.

- Describir la estructura y configuración del alimentador QU-03, detallando la demanda actual de energía eléctrica a partir de los datos históricos proporcionados por la empresa concesionaria ELSE.

- Diseñar y desarrollar un modelo de red neuronal artificial, determinando la arquitectura óptima en términos de número de neuronas, capas y funciones de activación para la predicción de la demanda eléctrica en el período 2023-2027.

- Comparar los resultados obtenidos con las redes neuronales frente a otros métodos tradicionales de predicción de demanda, analizando su efectividad y viabilidad en la planificación del sistema de distribución eléctrica.

1.7. Limitaciones de la Investigación

- La aplicación de la metodología basada en RNA se limitará al alimentador QU-03, perteneciente a la Subestación Eléctrica Quencoro, sin extenderse a otros alimentadores.

- El estudio se enfocará únicamente en redes de media tensión, sin considerar el impacto de la demanda en redes de baja tensión.

- No se analizarán efectos de armónicos ni distorsiones en la calidad de la energía, ya que la investigación está orientada exclusivamente a la predicción de la demanda eléctrica.

- Los indicadores de calidad del servicio, como SAIDI y SAIFI, no serán objeto de estudio, ya que la investigación se centra en la estimación de la demanda y no en la continuidad del suministro eléctrico.

- La recopilación y procesamiento de datos se realizará a partir de la base de datos GIS de la empresa concesionaria ELSE, lo que implica una dependencia en la precisión y actualización de esta información.

- La precisión del modelo estará condicionada por la configuración de la red neuronal y la calidad de los datos históricos de consumo, lo que puede influir en la exactitud de las predicciones.

1.8. Hipótesis.

1.8.1. Hipótesis General

La utilización de las redes neuronales artificiales podrá mejorar el nivel de precisión de predicción de la demanda de energía eléctrica del alimentador QU-03 para el periodo 2023-2027.

1.8.2. Hipótesis Específicas

1. La utilización de una arquitectura adecuada de red neuronal artificial podrá mejorar el nivel de precisión en la predicción de la demanda de energía eléctrica del alimentador QU-03 para el periodo 2023-2027.
2. La selección adecuada de variables de entrada de la red neuronal podrá mejorar la precisión de la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027.
3. La adecuada selección y ajuste de los parámetros de entrenamiento de la red neuronal artificial influye significativamente en la mejora del desempeño predictivo de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027.

1.9. Operacionalización de Variables

Tabla 1-3

Variable Independiente (Predictora)

Variable Independiente	Definición Conceptual	Dimensiones	Indicador	Unidad
Redes Neuronales Artificiales	Modelos de aprendizaje automático que utilizan una arquitectura basada en capas y neuronas para capturar patrones no lineales en datos históricos de demanda eléctrica.	- Arquitectura de la red neuronal	- Número de capas ocultas - Número de neuronas por capa	Nº de capas Nº de neuronas
		- Funciones de activación	- Tipo de función de activación	Und
		- Parámetros de entrenamiento	- Número de épocas	Épocas (Nº)

Tabla 1-4*Variable Dependiente (Endógena)*

Variable Dependiente	Definición Conceptual	Dimensiones	Indicador	Unidad
Precisión en la predicción de la demanda eléctrica	Capacidad del modelo para estimar con exactitud la demanda eléctrica en un alimentador específico para un intervalo de tiempo dado.	Exactitud de la predicción	Error absoluto medio (MAE) Porcentaje de error	kW, MW %

1.10. Metodología

1.10.1. Tipo de investigación

La investigación es de tipo aplicada, porque tiene el objetivo de estimar la demanda futura a partir de la utilización de una herramienta computacional como es el caso de la red neuronal, donde se realizan cálculos y modelamientos matemáticos que representan el consumo de la energía eléctrica.

1.10.2. Nivel de investigación

El nivel de la investigación es predictivo debido a que se utilizará modelos matemáticos para predecir la ocurrencia del crecimiento de la demanda a partir de la utilización de redes neuronales, donde se conoce las causas que provocan este evento.

1.10.3. Enfoque de investigación

La investigación sigue un enfoque cuantitativo, puesto que se fundamenta en el análisis numérico y el uso de métodos estadísticos para evaluar la precisión de las predicciones realizadas por las redes neuronales. (Sampieri, 2022) indican que el enfoque cuantitativo se basa en la recolección de datos numéricos y en el uso de análisis estadísticos para validar hipótesis.

1.10.4. Diseño de investigación

Se emplea un diseño cuasi-experimental, dado que la investigación analiza datos históricos de la demanda eléctrica sin intervenir ni manipular directamente las variables en un entorno controlado. Este diseño es apropiado para evaluar la capacidad del modelo basado en redes neuronales artificiales para predecir la demanda eléctrica en el alimentador QU-03 durante el periodo 2023-2027. De acuerdo con Sampieri (2022), el diseño cuasi-experimental se caracteriza por la observación y análisis de variables en contextos parcialmente controlados, lo que lo hace idóneo para estudios aplicados en el ámbito de la energía eléctrica.

La validación del modelo incorporará métricas como MAPE y RMSE, además de simulaciones en DIGSILENT para verificar su aplicabilidad técnica. Como contraste, se compararán los resultados con métodos tradicionales de pronóstico, demostrando las ventajas del enfoque propuesto.

1.11. Población y Muestra

La población de este estudio está conformada por 150 subestaciones que pertenecen al alimentador QU-03. Como se analiza la totalidad de estas subestaciones, la muestra es de tipo universal. Esto asegura un análisis integral y representativo del comportamiento de la demanda eléctrica en el alimentador, garantizando que los resultados sean confiables y aplicables en la predicción mediante redes neuronales artificiales.

1.12. Procesamiento de Datos

Para el procesamiento de datos se hace uso de los programas computacionales como:

- Hoja de cálculo de Microsoft Office Excel
- Hoja de cálculo de Microsoft Office Word
- Python 3.9
- Keras
- Tensorflow

- Spyder (Anaconda 3)
- Numpy
- Google Earth
- ArcGIS
- AutoCAD
- Jupiter

1.13. Técnicas de Recolección de Datos

Para la recolección de datos, se empleó la técnica documentaria, obteniendo registros históricos de consumo mensual de energía y demanda eléctrica de los usuarios del alimentador QU-03. Estos datos fueron proporcionados por el área GIS de la empresa concesionaria ELSE, lo que garantiza su validez y precisión.

En cuanto al procesamiento de datos, debido al gran volumen de información recopilada, se utilizó Microsoft Excel para la organización inicial y limpieza de los datos. Posteriormente, se emplearon herramientas de análisis de datos en Python, específicamente las bibliotecas Pandas y NumPy, para estructurar y manipular la información de manera eficiente.

Para el desarrollo del modelo de predicción, se utilizó Python con la biblioteca TensorFlow/Keras, la cual permitió la implementación de redes neuronales artificiales. La validación del modelo se realizó mediante el cálculo del error cuadrático medio y la comparación con métodos tradicionales de pronóstico, asegurando la fiabilidad y precisión de los resultados obtenidos.

1.14. Matriz de Consistencia

La matriz de consistencia se muestra en la siguiente página.

TÍTULO: “PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN EL ALIMENTADOR QU-03 UTILIZANDO REDES NEURONALES ARTIFICIALES EN EL PERIODO 2023-2027”					
PROBLEMA	OBJETIVOS	HIPOTESIS	VARIABLES	INDICADORES	METODOLOGIA
Problema general ¿De qué manera la utilización de las redes neuronales artificiales podrá mejorar el nivel de la precisión de la demanda de energía eléctrica del alimentador QU-03 para el periodo 2023-2027?	Objetivo general Utilizar las redes neuronales artificiales para mejorar la precisión en la predicción de la demanda de energía eléctrica del alimentador QU-03 para el periodo 2023-2027.	Hipótesis general La utilización de las redes neuronales artificiales podrá mejorar el nivel de precisión de predicción de la demanda de energía eléctrica del alimentador QU 03 para el periodo 2023 2027.	1.Variable Independiente (Predictora) -Redes Neuronales Artificiales. 2.Variable Dependiente (Endógena) - Precisión en la predicción de la demanda eléctrica.	1.Indicador de la variable independiente - Número de capas ocultas - Número de neuronas por capa - Tipo de función de activación - Número de épocas 2.Indicador de la variable Dependiente - Error absoluto medio (MAE) [kW, MW] - Porcentaje de error [%]	- Es de tipo aplicada, ya que busca estimar la demanda futura de energía utilizando redes neuronales y modelamiento matemático. -Es de nivel predictivo, dado que se emplean modelos matemáticos para anticipar el crecimiento de la demanda eléctrica, con base en variables conocidas que influyen en este fenómeno. -Enfoque de investigación Cuantitativo , basado en análisis numérico y estadístico para evaluar la precisión del modelo. -Diseño de investigación: Cuasi- experimental , analiza datos históricos para evaluar la capacidad del modelo de predecir la demanda. Se emplearán métricas como MAPE, simulaciones en DiGSILENT y comparación con métodos tradicionales para validar los resultados
Problemas específicos 1. ¿Cómo influye la arquitectura de la red neuronal artificial en la precisión de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2025? 2. ¿De qué manera influye la selección de las variables de entrada en el desempeño predictivo de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027? 3. ¿De qué manera influye los parámetros de entrenamiento de la red neuronal artificial en la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027?	Objetivos específicos 1. Analizar el impacto de la arquitectura de la red neuronal artificial en la precisión de la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2025. 2. Analizar el impacto de la selección de las variables de entrada en el desempeño predictivo de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027. 3. Analizar el impacto de los parámetros de entrenamiento de la red neuronal artificial en la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027.	Hipótesis Específicas 1. La utilización de una arquitectura adecuada de red neuronal artificial podrá mejorar el nivel de precisión en la predicción de la demanda de energía eléctrica del alimentador QU-03 para el periodo 2023-2027. 2. La selección adecuada de variables de entrada de la red neuronal podrá mejorar la precisión de la predicción de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027. 3. La adecuada selección y ajuste de los parámetros de entrenamiento de la red neuronal artificial influye significativamente en la mejora del desempeño predictivo de la demanda de energía eléctrica del alimentador QU-03 durante el periodo 2023-2027.			

CAPÍTULO II

MARCO TEÓRICO

2.1. Introducción

Para realizar el estudio de la demanda, es necesario conocer los fundamentos teóricos relacionados con esta, así como tener en cuenta los conceptos sobre redes neuronales, un tema amplio que en la actualidad se ha convertido en un recurso clave para resolver una gran variedad de problemas en distintas ramas de las ciencias.

En este capítulo se presentan los antecedentes relacionados con el estudio, proporcionando referencias sobre investigaciones previas y enfoques utilizados en trabajos similares. Además, se expone la teoría apropiada para el desarrollo de la presente tesis, asegurando el uso de la simbología de acuerdo con el Código Nacional de Electricidad.

A continuación, se desarrollan los conceptos principales utilizados en el presente trabajo de investigación.

2.2. Antecedentes de Estudio

2.2.1. Antecedentes Nacionales

- ✓ La tesis “Modelo De Red Neuronal Para La Predicción Del Consumo De Energía Eléctrica En Iquitos”, Universidad Nacional de la Amazonía Peruana, Iquitos – Perú, tras el análisis de los resultados obtenidos en esta investigación, se concluye:
 - “La red neuronal artificial desarrollada tiene una capacidad predictiva altamente eficaz para el consumo de energía eléctrica en la ciudad de Iquitos” (Pinedo Amias y Lozano Gómez, 2022).
 - “Los resultados obtenidos en esta investigación son significativos para la gestión de los recursos energéticos en la ciudad de Iquitos, ya que la red neuronal artificial se presenta como una herramienta eficaz para la predicción del consumo de energía eléctrica. Las empresas y autoridades

pueden utilizar esta herramienta para planificar y gestionar mejor los recursos energéticos de la ciudad” (Pinedo Amias y Lozano Gómez, 2022).

- ✓ El artículo “Pronóstico de consumo de energía eléctrica residencial de corto plazo utilizando algoritmos de aprendizaje automático y profundo”, Universidad Nacional Mayor de San Marcos, Lima – Perú, que presenta el siguiente objetivo:
 - “El objetivo de esta investigación es crear modelos de predicción de consumo de energía eléctrica para el corto plazo, utilizando el algoritmo de regresión lineal múltiple y una red neuronal artificial. Es una investigación de tipo descriptiva-explicativa, y se usa la metodología de la ciencia de datos para alcanzar el objetivo planteado. Los modelos se entrenan y evalúan utilizando los datos de energía eléctrica facturada mensual en Uruguay, durante el período 2000-2022, además de las mediciones de temperatura ambiente y humedad relativa, así como la variación porcentual del índice de protección al consumidor. A través de un análisis de correlación y de un análisis de componentes principales, se verifica la importancia de las variables explicativas seleccionadas, previo a la obtención de los modelos. El modelo de regresión lineal tuvo un R^2 de 0,782 y el modelo de la red neuronal de 0,797, los residuos se distribuyeron normalmente para ambos modelos, y las métricas RMSE, MAE, y MAPE tuvieron valores similares también en ambos modelos. El modelo de la red neuronal tuvo un mejor desempeño, en comparación con el modelo de regresión lineal, en lo que respecta a la predicción de la energía eléctrica para los meses de julio y agosto del año 2022” (Yajure Ramírez, 2022).

2.2.2. *Antecedentes Internacionales*

- ✓ Como antecedente internacional reciente, se destaca el estudio "Pronóstico de la Demanda en Redes Eléctricas Inteligentes Usando Memoria a Corto y Largo Plazo (LSTM)" realizado por Koushik Roy, Abtahi Ishmam y Kazi Abu Taher en 2021.
 - “En esta investigación, se desarrolló un modelo basado en redes neuronales recurrentes de tipo Long Short-Term Memory (LSTM) para predecir la demanda de energía en una red eléctrica inteligente” (Koushik y Abtahi, 2021).
 - “Utilizando datos horarios de consumo de energía recopilados durante cuatro años, el modelo alcanzó un error porcentual absoluto medio (MAPE) de 1.22%, superando a métodos estadísticos tradicionales como el modelo autorregresivo (AR)” (Koushik y Abtahi, 2021).
 - “Los resultados sugieren que la aplicación de modelos LSTM mejora significativamente la precisión en la predicción de la demanda eléctrica, contribuyendo a una gestión más eficiente de la red eléctrica” (Koushik y Abtahi, 2021).
- ✓ Como referencia la revista “Predicción de demanda eléctrica utilizando redes neuronales artificiales para un sistema de distribución de energía eléctrica” Instituto Superior Tecnológico Ciudad de Valencia; Carlos Hugo Lozada Cabrera /2022, cuyas conclusiones fueron:
 - “Para este caso de estudio, el cual presenta una sola variable de entrada, el número de neuronas de la capa de entrada es seleccionado mediante el análisis de la serie temporal identificando patrones de comportamiento que se repiten cada cierto tiempo” (Lozada Cabrera, 2022).

- “El modelo 1 es más sensible a cambios en la respuesta de la RNA por cambios en los parámetros de pesos y bias en comparación al modelo 2. El resultado del criterio de evaluación MAPE aplicado durante la etapa de prueba, no asegura que la proyección para los meses siguientes tendrá el mismo margen de error, debido a que la proyección resulta adecuada para los primeros meses de evaluación, pero pierde tendencia muy pronto. Aplicando el criterio de evaluación MAPE al modelo 1 y modelo 2, se concluye que el modelo 2 resulta ser el más adecuado debido a que entrega un porcentaje de error igual a 3.17%, siendo menor al obtenido del modelo 1, que es de 3.71%” (Lozada Cabrera, 2022).
- ✓ La tesis “Aplicación De Una Red Neuronal A Un Sistema Eléctrico De Distribución Mediante El Análisis De Comportamiento De Su Carga En Bajo Voltaje” Universidad Politécnica Salesiana Sede Cuenca; Geovanny Xavier Carpio Suarez y Paúl Alexander Daga López, año 2019 Cuenca - Ecuador, cuyas conclusiones fueron:
 - “El desarrollo óptimo de una RNA depende de la arquitectura y su método de aprendizaje, dentro del cual se tiene en cuenta el número de capas y número de neuronas por capa, si se excediese uno de estos dos parámetros se puede generar un sobre entrenamiento, lo que perjudicaría a la predicción de la RNA, demostrado en la implementación para esta investigación” (Carpio Suarez y Daga López, 2019).
 - “Para esta investigación se utiliza una capa oculta con 35 neuronas y una capa de salida con 1 neurona, ya que, en pruebas, al incrementar el número de capas provoca que el error cuadrático se incremente. Mientras que al aumentar el número de neuronas con las capas mencionadas anteriormente

el error cuadrático no tiene una variación significativa. Para aplicaciones con RNA se recomienda usar una capa oculta ya que esta es capaz de solucionar cualquier tipo de topología, como se ha utilizado en los casos de estudio de esta investigación” (Carpio Suarez y Daga López, 2019).

La revista “Predicción de demanda eléctrica utilizando redes neuronales artificiales para un sistema de distribución de energía eléctrica” contribuye significativamente al análisis del Error Absoluto Porcentual Medio (MAPE), que es crucial para evaluar la precisión comparativa de la red neuronal frente a otros métodos.

Según lo mencionado, el Modelo 1 es más susceptible a cambios en los parámetros de pesos y sesgos en comparación con el Modelo 2. Aunque el MAPE aplicado durante la fase de prueba indica una precisión inicial satisfactoria para los primeros meses evaluados, esta exactitud inicial no garantiza la misma precisión para los meses siguientes, ya que el modelo puede perder su precisión rápidamente. Al evaluar el MAPE de ambos modelos, se concluye que el Modelo 2 es más adecuado, ya que presenta un error porcentual del 3.17%, menor que el 3.71% obtenido por el Modelo 1.

La tesis de Maestría “Predicción Demanda Eléctrica Española. Implementación De Redes Neuronales Recurrentes En Python”, aborda que Python es un lenguaje de programación ampliamente utilizado y adecuado para implementar modelos de predicción como las redes neuronales recurrentes (RNNs) en el contexto de la predicción de la demanda eléctrica. A pesar de ser un lenguaje interpretado, Python es capaz de manejar grandes volúmenes de datos y realizar cálculos complejos de manera eficiente, especialmente cuando se utiliza en conjunto con bibliotecas optimizadas para cálculos numéricos como NumPy y pandas.

Todos los antecedentes coinciden en que, para lograr predicciones más precisas, es fundamental contar con una estructura de red neuronal bien diseñada y ajustada. La arquitectura de la red, que incluye el número de capas, el tipo de funciones de activación, los parámetros de

regularización y los optimizadores utilizados, juega un papel crucial en la capacidad del modelo para capturar patrones complejos en los datos. Además, una correcta selección y preprocesamiento de las variables de entrada, así como la elección de métodos adecuados de entrenamiento y validación, son elementos esenciales para minimizar los errores en las predicciones y mejorar la robustez del modelo predictivo.

2.3. Fundamentos de las Redes Neuronales

2.3.1. *Inteligencia Artificial*

“La Inteligencia Artificial (IA) es la combinación de algoritmos planteados con el propósito de crear máquinas que presenten las mismas capacidades que el ser humano. Una tecnología que todavía nos resulta lejana y misteriosa, pero que desde hace unos años está presente en nuestro día a día a todas horas” (www.iberdrola.com, 2021).

2.3.2. *¿Qué Es Una Red Neuronal?*


“Una red neuronal es un modelo simplificado que emula el modo en que el cerebro humano procesa la información: Funciona simultaneando un número elevado de unidades de procesamiento interconectadas que parecen versiones abstractas de neuronas” (www.ibm.com, 2021).

2.3.3. *Elementos Básicos Que Componen Una Red Neuronal*

En la figura siguiente se puede observar el esquema de una red neuronal.

Figura 2-1

Ejemplo de una red neuronal



Fuente. Matich, 2011.


“La misma está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”. Cabe mencionar que la capa oculta puede estar constituida por varias capas” (Matich, 2011, p. 12).

2.3.4. Estructura De Una Neurona Artificial

“La estructura de una neurona artificial comprende de diversas entradas ponderadas, un bloque de sumas ponderadas, una función de activación y su salida. La estructura de una neurona se muestra en la figura siguiente” (Matich, 2011, p. 12).

Figura 2-2

Estructura de una neurona artificial



Fuente. Castro García, 2006.

2.3.5. Entradas De Una Neuronal Artificial

“Las señales del entorno son suministradas a la neurona por medio de sus entradas; estas señales pueden ser externas a la red neuronal o ser la salida de otras neuronas. Las entradas en una neurona artificial son análogas a las sinapsis de una célula neuronal, debido a que éstas son el medio para el ingreso de información a la neurona” (Castro García, 2006, p. 22).

2.3.6. Pesos Sinápticos

“Estos constituyen bloques de ganancia aplicados a las señales de entrada, es decir, son valores numéricos constantes por los cuales se multiplican las señales de entrada. Al igual que

en las células neuronales, éstos pueden ser excitadores o inhibidores; un peso sináptico positivo produce una señal excitadora, ya que al multiplicarse por una entrada positiva y sumarse con las demás señales, ayuda a generar una señal de salida positiva; de la misma forma, un peso sináptico negativo produce una señal inhibidora, ya que cancela el efecto de una señal excitadora” (Castro García, 2006, p. 23).

“Los valores de los pesos sinápticos son asignados en la etapa de aprendizaje de la red, de acuerdo con el algoritmo de aprendizaje utilizado; algunos pesos sinápticos pueden tener un valor grande respecto a los demás y otros podrían anularse. Un peso sináptico de valor cero, indica que no hay conexión entre dos neuronas” (Castro García, 2006, p. 23).

2.3.7. Funciones De Activación

“Asociada a cada neurona artificial hay una función que transforma la entrada total en la respuesta de la neurona, ésta es la función de activación. En cada neurona artificial, los productos de las entradas por sus pesos sinápticos, son sumados, ésta suma constituye la entrada total a la neurona. La suma de las entradas ponderadas o entrada total, es transformada por la función de activación, para obtener la salida de la neurona” (Castro García, 2006, p. 24).

Esto se puede representar, mediante la siguiente ecuación:

$$\text{Salida} = f(W_1X_1 + W_2X_2 + W_3X_3 + \dots + W_nX_n) \quad (2-1)$$

“Donde $X_1, X_2, X_3, \dots, X_n$, son las entradas de la neurona; $W_1, W_2, W_3, \dots, W_n$, son los pesos de las entradas y $f()$ es la función de activación de la neurona. Generalmente en una red neuronal, se utilizan 5 tipos de funciones de activación y son:” (Castro García, 2006, p. 24).

2.3.7.1. Función limitador fuerte

“En ésta se genera una salida si la entrada total supera un determinado umbral; las neuronas con este tipo de función de activación, se denominan neuronas binarias, ya que su salida puede tomar uno de dos valores 0 o 1” (Castro García, 2006, p. 24).


Esta función puede expresarse matemáticamente como una función escalón unitario, de la siguiente manera:

$$f(x) = u(x) \quad (2-2)$$

Y gráficamente se muestra en la Figura siguiente, donde se puede observar que para un valor mayor que 0, la salida es igual a 1 y para un valor negativo su salida es 0.

Figura 2-3

Gráfica de una función limitador fuerte



Fuente. Castro García, 2006.


2.3.7.1.1. Función limitador fuerte simétrico

“Esta es similar a la función limitador fuerte, ya que es discontinua en cero, pero es simétrica con respecto al eje horizontal. Los valores de salida de la función limitador fuerte simétrico son 1 o -1 para todo su dominio, por tanto, las neuronas con esta función de activación son binarias, al igual que con la función limitador fuerte” (Castro García, 2006, p. 25).

Esta función puede expresarse matemáticamente como la siguiente Ecuación.

$$f(x) = u(x) - u(-x) \quad (2-3)$$

“La función limitador fuerte simétrico se muestra en la Figura siguiente, donde se puede observar que la función no es diferenciable en el punto cero, al igual que la función limitador fuerte” (Castro García, 2006, p. 25).

Figura 2-4*Función limitador fuerte simétrico*


Fuente. Castro García, 2006.

2.3.7.1.2. Función lineal

“Esta función simplemente representa a una ecuación de primer grado tal como se muestra en la Ecuación siguiente, la característica de esta función es que se tiene valores limites en su rango de salida” (Castro García, 2006, p. 25).

$$f(x) = x \quad (2-4)$$

De manera similar la gráfica de función lineal se muestra en la Figura siguiente.


Figura 2-5*Función lineal*

Fuente. Castro García, 2006.

2.3.7.1.3. Función sigmoide

“Esta función se asemeja a la función limitador fuerte, ya que su salida está comprendida entre cero y uno, pero a diferencia de ésta, es continua en todo su dominio y por tanto, es diferenciable. Debido a que muchos algoritmos de aprendizaje, necesitan hacer uso de la derivada de la función de activación, esta función tiene mayor utilidad que la función limitadora fuerte, la cual no es diferenciable en cero. En la función sigmoideal logarítmica, los valores de entrada total un poco mayores que cero, poseen una salida muy cercana a la unidad y entradas un poco menores que cero, tienen una salida cercana a cero” (Castro García, 2006, p. 27).

Figura 2-6
Función sigmoide




Fuente. Castro García, 2006.

La función sigmoide puede matemáticamente como:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2-5)$$

2.3.7.1.4. Función sigmoideal tangente hiperbólica

“La función sigmoideal tangente hiperbólica es diferenciable en todo su dominio, pero a diferencia de la sigmoideal logarítmica, su salida es bipolar, ya que está comprendida entre -1 y 1” (Castro García, 2006, p. 28).

Figura 2-7*Función sigmoideal tangente hiperbólica*

Fuente. Castro García, 2006.


Esta función se puede matemáticamente como:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2-6)$$

2.3.7.1.5. Función ReLU

La función ReLU (Rectified Lineal Unit), es una función de activación que anula los valores negativos y deja como salida los valores positivos tal como entran.

En la Figura siguiente se muestra la respuesta a esta función.

Figura 2-8*Función ReLU*

Fuente. programmerclick.com, 2020.

2.3.8. Salida De Una Neuronal Artificial

“Esta salida se obtiene de la función de activación, esta es análoga al axón de las células neuronales. La salida de una neurona puede ser aplicada a una entrada de muchas otras neuronas o bien, puede ser tomada como salida de la red” (Castro García, 2006, p. 28).


2.3.9. Formas De Interconexión Y Topología

“Dentro de una red neuronal, los elementos de procesamiento se encuentran agrupados en capas; una capa es una colección de neuronas. De acuerdo a la ubicación de la capa dentro de la red, ésta puede ser oculta o de salida. Las entradas de la red se agrupan en un vector de entrada, éste no se considera una capa, pues no contiene neuronas. Así, las redes neuronales están formadas por un vector de entrada, capas ocultas y capa de salida. El vector de entrada contiene las señales provenientes de las fuentes externas; las capas ocultas se encuentran entre el vector de entrada y la capa de salida, el número de capas ocultas puede ser desde cero hasta un número elevado; la capa de salida es la que transmite la respuesta de la red al medio externo” (Castro García, 2006, p. 29).

En la Figura siguiente se muestra el esquema de una red neuronal formada por 9 neuronas, una capa de entrada, una capa oculta y una capa de salida.

Figura 2-9

Esquema de una red neuronal artificial



Fuente. Castro García, 2006.


2.3.10. Mecanismo de Aprendizaje

“Todo conocimiento de una red neuronal se encuentra distribuido en los pesos sinápticos de las neuronas. Una red neuronal aprende a través de un proceso de ajuste de sus pesos sinápticos. El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos sinápticos en respuesta a una entrada, para proporcionar la salida adecuada. Los cambios que se producen durante el proceso de aprendizaje implican la destrucción, modificación y creación de conexiones entre las neuronas. La creación de una nueva conexión consiste en que el peso de la misma pasa a tener un valor distinto de cero, una conexión se destruye cuando su peso pasa a ser cero” (Castro García, 2006, p. 31).

2.3.10.1. Aprendizaje supervisado

“Los algoritmos de aprendizaje supervisado son los más populares, en éstos, el proceso de aprendizaje se realiza mediante el control de un agente externo, que determina la respuesta que debería generar la red a partir de una entrada determinada” (Castro García, 2006, p. 31). En la Figura siguiente se muestra la forma en la que se realiza el aprendizaje supervisado que, mediante un agente externo, varían los pesos de acuerdo a la salida que se desee.

Figura 2-10
Aprendizaje supervisado




Fuente. Castro García, 2006.

2.3.10.2. Aprendizaje no supervisado

“En los algoritmos de aprendizaje no supervisado, el conjunto de datos de entrenamiento consiste sólo en los patrones de entrada, por lo tanto, la red es entrenada sin el beneficio del control de un agente externo” (Castro García, 2006, p. 32).

Figura 2-11

Aprendizaje no supervisado



Fuente. Castro García, 2006.

2.3.11. Backpropagation

“La propagación hacia atrás de errores o retropropagación (del inglés backpropagation) es un método de cálculo del gradiente utilizado en algoritmos de aprendizaje supervisado utilizados para entrenar redes neuronales artificiales. El método emplea un ciclo propagación – adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, este se propaga desde la primera capa a través de las capas siguientes de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas.

Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Sin embargo, la neurona de la capa oculta solo recibe una fracción de la señal total del error, basándose aproximadamente en la contribución relativa que haya aportado cada neurona a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan


recibido una señal de error que describa su contribución relativa al error total” (Wikipedia.org, 2021).

2.3.12. Métodos De Inteligencia Artificial

“La inteligencia artificial es el arte de desarrollar maquinas con capacidad para realizar tareas que por el momento los humanos hacen mejor. Entonces los métodos de inteligencia artificial para predicciones son algoritmos que mediante matemáticas avanzadas permiten modelar el comportamiento de las variables dependientes en función de algunas variables independientes con la diferencia de permitir trabajar con sistemas más complejos que presentan comportamientos no lineales. En la figura siguiente, se resume la clasificación de los diferentes métodos de inteligencia artificial encontrados para la predicción de la demanda eléctrica” (López Takeyas, 2007).

Figura 2-12

Clasificación de los métodos de predicción



Fuente. Matich, 2011.

“Para desarrollar inteligencia artificial la mayoría de estos algoritmos están inspirados en procesos biológicos con los que cuenta el ser humano, las redes neuronales artificiales como su nombre lo indica están inspiradas en el funcionamiento de las neuronas biológicas de los seres humanos” (López Takeyas, 2007).

2.3.13. Redes Neuronales Artificiales

“Las redes neuronales artificiales (RNA, por sus siglas en inglés Artificial Neural Networks) son modelos inspirados en el sistema nervioso del ser humano, dicho sistema consiste, en la interconexión de un grupo de neuronas biológicas que permiten procesar la información y obtener la salida deseada acorde a las necesidades del ser humano. Se calcula que en cada cerebro de un ser humano existen en promedio alrededor de 100 billones de neuronas biológicas, y más de 10.000 interconexiones entre neuronas. Las redes neuronales, permiten aproximar funciones no lineales, esto permite modelar fenómenos complejos donde las variables no están correlacionadas. Así con aplicaciones de Redes Neuronales Artificiales se han obtenido atractivos resultados en medicina, economía, comunicaciones y otras áreas del conocimiento, siendo una de sus características la eliminación de hipótesis de reducción de linealidad que ha dominado el análisis de diferentes problemas a lo largo del tiempo. Si bien, la hipótesis de simplificación, permite desarrollar formulaciones de modelos matemáticos para explicar fenómenos de diversa naturaleza; no es posible desechar el modelo lineal básico, que se sustenta justamente en la linealidad de sus ecuaciones” (López Takeyas, 2007).

2.3.14. Ventajas De Las Redes Neuronales Artificiales

Las principales ventajas de las RNA son:

2.3.14.1. Aprendizaje Adaptativo

“Las RNA tienen la capacidad de aprender a realizar las tareas en base al entrenamiento (datos de entrenamiento). Es decir, las RNA pueden cambiar su estructura dependiendo de los datos de entrenamiento” (López Takeyas, 2007).

2.3.14.2. Autoorganización

“Las RNA crean su propia organización o representación de la información recibida en la etapa de aprendizaje” (López Takeyas, 2007).

2.3.14.3. Tolerancia a fallos

“Las RNA tienen la ventaja de retener las capacidades de la red, cuando existiera alguna destrucción parcial de una red. Sin olvidar que esta toleración será mayor o menor dependiendo de la aplicación en la cual es utilizada la RNA” (López Takeyas, 2007).

2.3.14.4. Modelación no lineal

“Las RNA, permiten aproximar funciones no lineales (elimina la hipótesis de reducción de linealidad), esto permite modelar aquellos fenómenos complejos donde las variables no están correlacionadas” (López Takeyas, 2007).

“Adicionalmente se describen más ventajas de las redes neuronales artificiales (RNA): Mejor redimiendo en el trato con las funciones no lineales, no requieren formulaciones matemáticas complejas o de correlación cuantitativa entre entradas y salidas.

Modelos sencillos y permiten obtener bajos errores en el pronóstico tanto dentro como fuera de la muestra.

El software ofrece funciones de preprocesamiento y post-procesamiento de datos implícitas en las funciones de entrenamiento haciendo innecesario el uso individual.


También se detallan las desventajas de las redes neuronales artificiales (RNA):

Los paquetes computacionales en el mercado son limitados en su adaptación al problema, algunos tienen restricción en tamaño de la muestra.

Programación de la red es un tanto tediosa pero muy acertada en sus resultados” (López Takeyas, 2007).

2.4. Sistema De Distribución De Energía Eléctrica

“Es un conjunto de equipos que reciben la energía producida por las generadoras por medio de la transmisión y la distribuye entre los consumidores ubicados generalmente en diferentes lugares, en forma segura y confiable a distintos niveles de tensión” (Castañeda, 2006).

Figura 2-13*Esquema general del sistema de distribución*

Fuente. Castañeda, 2006.

2.4.1. Tipos De Diseño De Sistemas De Distribución


2.4.1.1. Tipo radial

“Este tipo de configuración es el más usado debido a que es simple, fácil de modificar y de bajo costo. La confiabilidad del servicio es baja debido a que está expuesta a interrupciones por fallas en los conductores y transformadores” (Bocangel Quispe & Bedia Condori, 2014).

Se clasifican en:

2.4.1.1.1. Configuración tipo radial simple


“Es el más sencillo y económico de todos los sistemas. Consiste en un solo alimentador que suministra de energía a todas las SED's. Su confiabilidad es baja debido a que una falla en el alimentador causará la interrupción del servicio a todos los usuarios” (Bocangel Quispe & Bedia Condori, 2014).

Figura 2-14*Topología tipo radial simple*

Fuente. Bocangel Quispe & Bedia Condori, 2014.

2.4.1.1.2. Configuración Tipo Radial Expandido

“La confiabilidad del sistema aumenta, si a partir del alimentador principal se derivan sub- alimentadores separados del alimentador principal mediante seccionadores. Ya que una falla solo afectará a un alimentador y no a los demás” (Bocangel Quispe & Bedia Condori, 2014).

Figura 2-15*Topología tipo radial expandido*

Fuente. Bocangel Quispe & Bedia Condori, 2014.


2.4.1.1.3. Configuración Tipo Radial con Uniones

“Este sistema al igual que el tipo radial expandido emplea varios sub-alimentadores con la diferencia que se unen por medio de seccionadores, normalmente abiertos. Así en caso de una falla, los usuarios del ramal afectado no perderán el servicio sino durante el tiempo en que se localice la falla y se operen los seccionadores. El costo es mayor debido a la implementación

de equipos de seccionadores. Se asemeja a la configuración tipo anillo abierto” (Bocangel Quispe & Bedia Condori, 2014).

Figura 2-16

Topología tipo radial con uniones




Fuente. Bocangel Quispe & Bedia Condori, 2014.

2.4.1.2. Configuración tipo anillo

“En este caso el alimentador recorre el área de suministro de energía y regresa al punto de inicio formando un circuito cerrado. En cada tramo existen seccionadores diseñados para aislar fallas en distintas partes del circuito. Los costos del sistema aumentan debido a la implementación de seccionadores o interruptores” (Bocangel Quispe & Bedia Condori, 2014).

Figura 2-17

Topología tipo anillo



Fuente. Bocangel Quispe & Bedia Condori, 2014.

2.4.2. Clasificación De Los Sistemas De Distribución

2.4.2.1. Subsistema de distribución primaria

“Es el sistema de distribución que transporta la energía producida de un sistema de generación para alimentar una o más Subestaciones de Distribución. Comprende desde el sistema alimentador hasta las Subestación alimentada” (Bocangel Quispe & Bedia Condori, 2014).

2.4.2.2. Subsistema de distribución secundaria

“Es el sistema de distribución que permite abastecer al servicio residencial, comercial, alumbrado público y pequeñas industrias” (Bocangel Quispe & Bedia Condori, 2014).

2.4.3. Componentes Básicos de un Sistema de Distribución

2.4.3.1. Subestación Transformadora

“Una subestación transformadora o subestación eléctrica transformadora (abreviadamente SET), es una instalación conformada principalmente por un transformador de potencia y equipos de seguridad, medición y seccionamiento. Destinadas a transformar niveles adecuados de tensión para la transmisión y distribución de la energía Eléctrica” (Oliveira & Sobrimho, 2009).

Figura 2-18

Subestación de transformación Quencoro



Fuente. Delcrosa, 2012.

2.4.3.2. Transformador de Potencia

“Un transformador de potencia es una máquina eléctrica que mediante inducción electromagnética transforma un sistema primario de tensión y corriente alterna a otro sistema secundario, con el fin de transmitir potencia eléctrica” (Wolff, 1982).

2.4.3.3. Alimentadores

“Generalmente son líneas aéreas de distribución de energía eléctrica montados en postes de concreto o madera; subterráneas, enterradas directamente en la tierra o colocados en tuberías debidamente protegidas” (Wolff, 1982).

2.4.3.4. Subestación De Distribución

“Parte de una red eléctrica, conformada por un conjunto de instalaciones para transformación y/o seccionamiento de energía eléctrica para la entrega a una red de distribución secundaria, instalaciones de alumbrado público y cargas especiales” (Wolff, 1982).

2.4.4. Subestaciones Según El Tipo De Servicio

2.4.4.1. Servicio público

“Son las SED's (carga) que suministran de energía a zonas urbanas, rurales e industriales donde el propietario de la red de distribución es la empresa concesionaria” (Bocangel Quispe & Bedia Condori, 2014).

2.4.4.2. Servicio particular

“Son las SED's (carga) destinados a suministrar energía a un predio particular, generalmente la SED está ubicada dentro de la propiedad privada del interesado” (Bocangel Quispe & Bedia Condori, 2014).

2.4.5. Subestaciones de Acuerdo al Tipo de Carga

2.4.5.1. Cargas residenciales

“Se caracterizan generalmente por ser de tipo resistivas (alumbrado y calefacción), comprende básicamente los edificios, apartamentos, viviendas, urbanizaciones, asociaciones pro vivienda, asentamientos urbanos, etc.” (Bocangel Quispe & Bedia Condori, 2014).

2.4.5.2. Cargas comerciales

“Caracterizadas por ser de tipo resistivas y localizarse en zonas céntricas o de gran concentración popular donde se realizan actividades comerciales. Tienen un componente poco inductivo de bajo factor de potencia. Hoy en día predominan cargas muy sensibles que introducen armónicos” (Bocangel Quispe & Bedia Condori, 2014).

2.4.5.3. Cargas industriales

“Tienen como característica consumo de energía reactiva debido a la gran cantidad de motores instalados. A estas cargas se les controla el consumo de los reactivos teniendo una tarifa especial por energía reactiva” (Wolff, 1982).

2.4.6. Subestaciones Según El Tipo De Instalación

2.4.6.1. Subestación de distribución monoposte

“La SED de tipo Monoposte se caracteriza por estar instalada en una sola estructura, para nuestro caso Poste de C.A.C. de hasta 15 m de altura, utilizada en redes aéreas y por el servicio pueden ser trifásicas y monofásicas para potencias que son menores a los 75kVA” (Bocangel Quispe & Bedia Condori, 2014).

2.4.6.2. Subestación de distribución biposte

“La SED Biposte se caracteriza por estar instalada en medio de dos estructuras, que en nuestro caso son postes entre 9-12 m de altura; es utilizada en redes aéreas y por el tipo de servicio, pueden ser trifásicas para potencias que superan los 50 kVA” (Bocangel Quispe & Bedia Condori, 2014).

2.4.6.3. Subestación de distribución tipo caseta

“La SED del tipo Caseta se caracteriza por estar instalada, en un ambiente cerrado, diseñado específicamente para albergar equipos tales como celdas de protección, transformador de distribución, tablero de distribución, celda de interruptor, sistemas de puesta a tierra MT y BT, rectificador y banco de baterías, así como un tablero de control” (Bocangel Quispe & Bedia Condori, 2014).

2.4.6.4. Subestación de distribución tipo compacta

“Subestaciones en la cual el transformador, los dispositivos de protección y maniobra son herméticos; van instalados como unidad. Pueden ser de tipo pedestal, si se instalan a nivel del suelo sobre una base de concreto, o de tipo bóveda si se instalan debajo del nivel del suelo. Su aplicación en sistemas de distribución, como son centros comerciales, fraccionamientos residenciales, hoteles, centros turísticos y lugares en donde la continuidad de servicio es un factor determinante” (Bocangel Quispe & Bedia Condori, 2014).

2.4.7. Subestaciones Según El Nivel De Tensión En El Secundario

Según el CNE, los niveles de tensión recomendados en el secundario del transformador, pueden ser de 380,440 y 220 V.

2.5. Pérdidas de Energía

Las pérdidas de energía eléctrica son un fenómeno inherente en los sistemas de distribución y transmisión de electricidad. Estas pérdidas pueden afectar la eficiencia y rentabilidad de las empresas distribuidoras, por lo que es fundamental cuantificarlas y minimizar su impacto.

Las principales fuentes de pérdidas son:

- Pérdidas en los conductores: A medida que la corriente fluye por los cables, se genera calor debido a la resistencia eléctrica.

- Pérdidas en los transformadores: Se producen en el núcleo magnético (pérdidas por histéresis y corrientes parásitas) y en los devanados (pérdidas óhmicas).
- Pérdidas por efecto corona: En líneas de alta tensión, pueden ocurrir ionizaciones en el aire alrededor de los conductores, generando descargas y pérdidas de energía.
- Pérdidas por reactancia: En la red de distribución, la presencia de cargas inductivas y capacitivas afecta el factor de potencia, incrementando el consumo de energía reactiva.
- Conexiones clandestinas y fraudes eléctricos.
- Errores en la medición y facturación del consumo de los usuarios.
- Fallas en los equipos de medición o manipulación de medidores.


2.5.1. Factores influyentes en la gestión de la empresa

“El índice de las pérdidas de energía, es uno de los indicadores más importantes de la gestión técnica y administrativa de las empresas distribuidoras. Por la cual es imprescindible conocer y evaluar la incidencia de estas. Mediante este factor es posible determinar criterios que conlleven a un control exhaustivo de forma permanente y con ellos reducirlas a valores cercanos al mínimo, mediante un estudio del sistema de distribución, origina una pérdida de ingresos por los consumos no facturados” (Cañar Olmedo, 2007).

Consecuencias:

“Produce cortocircuitos y sobrecargas en las redes e instalaciones, lo que provoca en la empresa inversiones altas así mismo como extensiones de proyectos sobredimensionadas con el propósito de soportar los excesivos incrementos de consumos” (Cañar Olmedo, 2007, p. 37).

De acuerdo con Torres Hernández (2015), las pérdidas se dividen en técnicas y no técnicas.

Figura 2-19*Tipos de Pérdidas en Sistemas Eléctricos: Técnicas y No Técnicas*

Nota. Cañar Olmedo, 2007.

2.5.2. *Pérdidas Técnicas de Energía*

“El conjunto de pérdidas eléctricas debidas a fenómenos físico-electromagnéticos dentro de los elementos del sistema son denominadas pérdidas técnicas.

Las pérdidas técnicas constituyen la energía que se disipa y que no puede ser aprovechada de ninguna manera, pero que sin embargo puede ser reducida a valores aceptables según planes establecidos para dicho efecto. Las pérdidas técnicas se presentan principalmente por la resistencia de los conductores que transportan la energía desde los lugares de generación hasta llegar a los consumidores. Existen las pérdidas de transmisión de alto voltaje (resistivas, skin, efecto corona) y las pérdidas en las líneas de distribución (efecto joule) dentro de las ciudades, pueblos y áreas rurales (distribución primaria y secundaria), así como también pérdidas en los núcleos de los transformadores de las subestaciones y de distribución (pérdidas por corriente parásita e histéresis)”. (Cañar Olmedo, 2007)

2.5.3. *Pérdidas No Técnicas de Energía*

“Son las que se producen por robo o fraude y por deficiencias administrativas, se las denomina también pérdidas negras. Estas pérdidas son calculadas como la diferencia entre las

pérdidas totales del sistema y las pérdidas técnicas estimadas por el mismo, a continuación, las definimos” (Huacasi Puma & Choquecahuana Asto, 2016).

Por robo o hurto: realizado por personas que no tienen ningún trato ni contrato con la empresa concesionaria.

Por fraude: realizado por clientes de la empresa concesionaria con la finalidad de reducir su consumo real.

Por mala administración: corresponde a la energía no cobrada por problemas en la gestión administrativa.

2.5.4. Pérdidas por la variación de la demanda

“Son aquellas que se encuentran relacionadas con las corrientes que circulan por los elementos del sistema (efecto Joule). Su magnitud es proporcional al cuadrado de la corriente” (Huacasi Puma & Choquecahuana Asto, 2016).

$$P_L = I^2 \times R \quad (2-7)$$

En donde:

P_L = Pérdidas en el Sistema (W).

R = Resistencia del elemento del sistema (Ω).

I = Corriente que circula por la red (A).

$$D_{max} = \frac{E}{F_c \times t} \quad (2-8)$$

2.6. Análisis De La Demanda

2.6.1. Demanda eléctrica

La demanda eléctrica se define como la cantidad de potencia requerida por los consumidores en un sistema eléctrico en un instante o periodo determinado. Según (Glover J , 2016), la demanda eléctrica varía en función del tiempo y depende de factores como el tipo de consumo, la climatología y el comportamiento de los usuarios.

Matemáticamente, la demanda eléctrica instantánea puede expresarse como:

$$P = V \times I \times \cos\theta \quad (2-9)$$

Donde:

P = Potencia activa demandada (W o kW)

V = Tensión eléctrica (V)

I = Corriente eléctrica (A)

$\cos(\theta)$ = Factor de potencia

“A nivel de sistemas eléctricos, la demanda se mide en intervalos de tiempo definidos, denominados períodos de demanda, los cuales pueden ser de 15, 30 o 60 minutos, dependiendo de la normativa vigente en cada país. La potencia demandada en un período determinado se obtiene como el promedio de las potencias instantáneas registradas en dicho intervalo” (Glover J , 2016).

La demanda eléctrica se clasifica en:

Demanda máxima: Es el valor más alto de potencia consumida en un periodo específico. Su determinación es clave para el dimensionamiento de infraestructura eléctrica.

Demanda media: Es el promedio de las potencias consumidas en un determinado periodo.

Demanda base: Es la mínima potencia consumida en el sistema durante un periodo de análisis.

2.6.2. Demanda máxima

“La demanda máxima es el valor más alto de potencia eléctrica requerida por un sistema, instalación o conjunto de usuarios en un periodo determinado. Este parámetro es fundamental en el diseño, planificación y operación de los sistemas eléctricos, ya que permite dimensionar adecuadamente la infraestructura y optimizar la capacidad instalada” (Glover J , 2016).

La demanda máxima se mide en intervalos de tiempo definidos, como 15, 30 o 60 minutos, y suele expresarse en kilovatios (kW) o megavatios (MW). Matemáticamente, se expresa como:

$$D_{max} = \frac{E}{F_c \times t} \quad (2-10)$$

Siendo:

D_{max} : Demanda Máxima [W]

T : Tiempo en horas [h]

E : Energía consumida en [W-h]

F_c : Factor de Carga

2.6.3. Importancia de la Demanda Máxima

“La demanda máxima es un parámetro clave en la planificación y operación de los sistemas eléctricos, ya que permite dimensionar adecuadamente la infraestructura de generación, transmisión y distribución de energía. Además, es utilizada por las empresas eléctricas para establecer tarifas y definir contratos de suministro, asegurando que la capacidad instalada sea suficiente para atender los picos de consumo. Asimismo, influye directamente en el factor de carga, el cual mide la eficiencia con la que se utiliza el sistema eléctrico. Un factor de carga alto indica un uso estable y eficiente de la energía, mientras que un valor bajo sugiere variaciones significativas en la demanda, lo que puede generar sobrecargas o subutilización de la capacidad instalada” (Glover J , 2016).

2.6.4. Factor de simultaneidad

“Relación, expresada como un valor numérico o como un porcentaje, de la potencia simultánea máxima de un grupo de artefactos eléctricos o clientes durante un período determinado; y la suma de sus potencias individuales máximas durante el mismo período” (DGE – Terminología en Electricidad).

2.6.5. Factor de carga

La demanda eléctrica está directamente relacionada con el **factor de carga**, el cual se calcula como:

$$F_c = \frac{1}{P_{\max}} \int_0^T \frac{p(t)}{T} dt = \frac{\text{Demanda Promedio}}{D_{\max}} \quad (2-11)$$

Donde:

F_c : Factor de Carga.

$P_{\max}$: Potencia Máxima del Sistema [W].

$\int_0^T \frac{p(t)}{T} dt$: Demanda promedio en un intervalo de tiempo T [W].


Un factor de carga elevado indica un uso más eficiente del sistema eléctrico, mientras que un valor bajo sugiere variaciones bruscas en la demanda, lo que puede generar problemas operativos en la red de distribución.

“La predicción precisa de la demanda es fundamental para la planificación y operación de los sistemas eléctricos. En este contexto, el uso de redes neuronales artificiales (RNA) representa una alternativa avanzada, ya que permite modelar y predecir el comportamiento de la demanda con base en patrones históricos, variables climáticas y factores socioeconómicos, optimizando así la gestión del suministro eléctrico” (Hernández Rodríguez, 2020).

2.6.6. Curva de la demanda

Figura 2-20

Curva de la Demanda



Fuente. CODENSA S.A, 2011.

Es el ciclo de carga que muestra la variación de la demanda durante un periodo en el tiempo.

2.6.7. Factor de pérdidas

El Factor de Pérdidas es un indicador utilizado en sistemas de distribución eléctrica para estimar la relación entre la energía perdida y la energía demandada durante un periodo específico. Se basa en la relación cuadrática entre la demanda instantánea y la demanda máxima.

$$F_{perd} = \frac{1}{N} \sum_{i=1}^N \left(\frac{P_i}{P_{max}} \right)^2 \quad (2-12)$$

Donde:

P_i : Demanda en el intervalo i .

P_{max} : Demanda máxima registrada en el periodo de análisis.

N : Número total de intervalos.


Se calcula para cada intervalo de demanda la relación:

$$\frac{P_i}{P_{max}} \quad (2-13)$$

Se eleva al cuadrado esta relación para representar la proporción de las pérdidas en cada intervalo, y finalmente, se obtiene el promedio de todas las proporciones cuadradas para representar el Factor de Pérdidas total.

2.7. Tendencia Logística como Modelo de Crecimiento

“La tendencia logística es un método de proyección utilizado en el análisis de series de tiempo cuando los datos muestran un crecimiento o decrecimiento que eventualmente se estabiliza en un nivel máximo o mínimo. Este método sigue una curva logística, que es una función matemática que representa un crecimiento o decrecimiento inicial acelerado que se desacelera gradualmente hasta alcanzar un límite asintótico” (Sánchez, 2010).

Figura 2-21*Ejemplo de un modelo de tendencia logística*

Fuente. Estamatica.net, 2023.

$$Y = \frac{1}{1 + e^{-t}} \quad (2-14)$$

Donde:

a, b son constantes de la ecuación.

t es el tiempo en el eje de las abscisas.

e es el número de Euler.

2.8. Precisión de Pronóstico

“La precisión de pronóstico se refiere a la medida en que las predicciones realizadas por un modelo de pronóstico se ajustan a los valores reales observados. Es una evaluación fundamental para determinar la utilidad y fiabilidad de un modelo de pronóstico en particular.

La precisión de pronóstico se puede evaluar utilizando diversas métricas, como el Mean Absolute Percentage Error (MAPE), Mean Absolute Error (MAE), entre otras. Estas métricas proporcionan una medida cuantitativa de qué tan cerca están las predicciones del modelo de los valores reales, en términos de error absoluto o porcentual.

Una mayor precisión de pronóstico indica que el modelo es capaz de hacer predicciones más cercanas a la realidad, lo que lo hace más confiable para su uso en la toma de decisiones

y la planificación futura. Por otro lado, una menor precisión de pronóstico sugiere que el modelo puede requerir ajustes o mejoras para mejorar su capacidad predictiva” (Ordóñez, 2012).

2.8.1. Error Porcentual Absoluto Medio MAPE

“El término "MAPE" (Mean Absolute Percentage Error) se refiere a un indicador utilizado para evaluar la precisión de un modelo de pronóstico en comparación con los valores reales. Es una métrica comúnmente utilizada en el análisis de series de tiempo y pronósticos. El MAPE se calcula como el promedio del valor absoluto de los errores porcentuales individuales entre las predicciones del modelo y los valores reales, expresado como un porcentaje” (Hyndman y Athanasopoulos, 2018).

Se calcula mediante la siguiente fórmula:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{Y_i - \hat{Y}_i}{Y_i} \quad (2-15)$$

Donde:

n , es el número total de observaciones.

$\bar{Y}_i$ es el valor real de la observación i .

Y_i es el valor predicho por el modelo para la observación i .

2.8.2. Error Absoluto Medio MAE

“El MAE (Mean Absolute Error), o Error Absoluto Medio en español, es una métrica utilizada para evaluar la precisión de un modelo de pronóstico en el análisis de series de tiempo. Se calcula como el promedio de los valores absolutos de las diferencias entre las predicciones del modelo y los valores reales observados.

El MAE proporciona una medida de la magnitud promedio de los errores de pronóstico, sin considerar su dirección. Es una métrica útil para evaluar la precisión de un modelo de

pronóstico en términos de cuánto se desvían las predicciones del modelo de los valores reales observados” (Hyndman y Athanasopoulos, 2018).

Se calcula mediante la siguiente fórmula:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (2-16)$$

Donde:

n, es el número total de observaciones.

$\bar{Y}_i$ es el valor real de la observación i.

Y_i es el valor predicho por el modelo para la observación i.

2.9. Flujo de Potencia

“El análisis de flujo de potencia es esencial en la planificación y operación de sistemas eléctricos, ya que permite determinar la distribución de tensiones, corrientes y potencias en una red bajo condiciones de estado estacionario. Este análisis es fundamental para asegurar la eficiencia, estabilidad y confiabilidad del suministro eléctrico” (Herrera Briñez, 2024).

“El flujo de potencia, también conocido como flujo de carga, se refiere al estudio que calcula las magnitudes y ángulos de voltaje en cada nodo de un sistema eléctrico, así como las potencias activas y reactiva que fluyen por las líneas de transmisión” (Centeno Astudillo, 2020).

Los principales objetivos de este análisis incluyen:

- **Evaluación del Rendimiento del Sistema:** Determinar cómo se distribuye la carga en la red y verificar que las tensiones se mantengan dentro de límites aceptables.
- **Identificación de Sobrecargas:** Detectar elementos del sistema que operan cerca o por encima de su capacidad nominal.
- **Planificación de Expansiones:** Facilitar decisiones sobre ampliaciones o modificaciones en la infraestructura eléctrica.

- **Optimización Operativa:** Mejorar la eficiencia en la generación y distribución de energía, reduciendo pérdidas y costos operativos.

2.9.1. Ecuaciones Fundamentales del Flujo de Potencia

El análisis de flujo de potencia se basa en las ecuaciones de balance de potencia en cada nodo del sistema. Para un nodo i , las ecuaciones se expresan como:

Potencia Activa (P_i)

$$P_i = V_i \sum_{j=1}^n V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2-17)$$

Potencia Reactiva (Q_i)

$$Q_i = V_i \sum_{j=1}^n V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2-18)$$

Donde:

V_i y V_j son las magnitudes de voltaje en los nodos i y j , respectivamente.

G_{ij} y B_{ij} representan la conductancia y susceptancia de la línea que conecta los nodos i y j .

θ_{ij} es la diferencia de ángulo de fase entre los voltajes de los nodos i y j .

n es el número total de nodos en el sistema.

2.9.2. Métodos de Solución del Flujo de Potencia

Existen diversos métodos numéricos para resolver las ecuaciones no lineales del flujo de potencia. Los más utilizados son:

2.9.2.1. Método de Gauss-Seidel

“Es un enfoque iterativo que actualiza sucesivamente los valores de voltaje en cada nodo hasta alcanzar la convergencia. Aunque es sencillo de implementar, su tasa de convergencia puede ser lenta para sistemas de gran tamaño” (Hernández Rodríguez, 2020).

2.9.2.2. Método de Newton-Raphson

“Utiliza una aproximación lineal de las ecuaciones mediante la matriz jacobiana, logrando una convergencia más rápida y robusta. Sin embargo, requiere un mayor esfuerzo computacional y una buena estimación inicial para garantizar la convergencia” (Garcés, 2023).

2.9.2.3. Métodos Basados en Teoría de Grafos

“Incluyen técnicas como el método triangular y el barrido iterativo, los cuales han demostrado ser eficientes en la solución del flujo de potencia en redes de distribución. Estos métodos aprovechan la estructura topológica de la red para simplificar los cálculos” (Centeno Astudillo, 2020).

2.9.3. Importancia del Análisis de Flujo de Potencia

“El análisis de flujo de potencia es crucial para garantizar la operación segura del sistema, ya que permite conocer las condiciones de operación y prevenir situaciones que puedan comprometer la estabilidad de la red. Además, optimiza la distribución de cargas, lo que permite equilibrar las cargas en las diferentes líneas y transformadores, evitando sobrecargas y mejorando la eficiencia del sistema” (Centeno Astudillo, 2020).

2.10. Producto Bruto Interno (PBI)

“El Producto Bruto Interno (PBI) es uno de los indicadores más utilizados en la economía para medir la actividad económica de un país, región o sector durante un periodo específico. Representa el valor total de todos los bienes y servicios finales producidos dentro de las fronteras de una nación en un determinado lapso de tiempo, generalmente un año o un trimestre. El PBI también se utiliza para calcular indicadores como el PBI per cápita, que divide el PBI de un país entre su población, y se considera una medida del bienestar económico de un país” (Mankiw, 2016).

2.11. Importancia del PBI

“El PBI es crucial para la formulación de políticas económicas, ya que sirve como base para la toma de decisiones sobre impuestos, gasto público, tasas de interés y comercio internacional. Además, su crecimiento o disminución puede influir en la confianza de los consumidores, las empresas y los inversores, lo que a su vez afecta la inversión, el empleo y la producción” (Mankiw, 2016).

CAPÍTULO III

DESCRIPCIÓN ACTUAL DEL ALIMENTADOR QU-03

3.1. Introducción

En el presente capítulo, se describe la situación actual del alimentador QU-03, que es uno de los alimentadores que parte de la subestación de Transformación Quencoro y está bajo la concesión de la empresa Electro Sur Este.


La finalidad de este capítulo es conocer las características técnicas y el comportamiento de la demanda para las subestaciones de distribución contempladas en el alimentador de estudio.

3.2. Descripción de la Subestación de Transformación Quencoro

La SET Quencoro se encuentra al sur de la ciudad del Cusco, fue construida como parte de la ampliación de la central hidroeléctrica Machupicchu con la finalidad de suministrar de energía eléctrica a la zona sur de la ciudad del Cusco en 10.5 kV y a las provincias de Quispicanchis y Paruro en 22.9kV.

Esta interconectada a la SET Dolorespata a través de la Línea de Transmisión L-1004 con una distancia de 8.34 Km, con la central hidroeléctrica Machupicchu a través de la Línea L-1002 con una distancia de 99.34 Km y con la SET Combapata mediante la Línea L-1005 con una distancia de 188.05 Km.

Actualmente la SET cuenta con 7 alimentadores conectadas a la barra de 138 kV y está constituida por 2 transformadores de potencia de 3 devanados tal como se aprecia en la Figura siguiente.

Figura 3-1*Diagrama unifilar SET Quencoro**Fuente. Centro de Control Electro Sur Este.*

3.3. Descripción del Alimentador QU-03

El alimentador QU-03 tiene un total de 150 subestaciones de distribución, siendo uno de los que mayor número de transformadores dispone en toda la SET Quencoro.

Su recorrido pasa por Larapa, suministrando de energía al Colegio de Ingenieros, que está ubicado en San Jerónimo, continúa su recorrido por los Álamos, Enaco, Sol de Oro, Urb. Santa Rosa, cubriendo un área de influencia de la Av. de la Cultura hasta la prolongación Bolívar; otras derivaciones llegan a: Apv Huayna Picol, Ticapata, Urb. Santa María, Alto Qosqo San Sebastian, Apv Reales del Bosque, Apv las Lomas. Su tramo termina alimentando a las Comunidades de Wilcapata, Sequeraccay y Ccorimarca.

Tabla 3-1

Datos Generales del Alimentador QU-03

ALIMENTADOR QU 03	
Longitud del alimentador en Km	266.31
Total, de subestaciones de distribución	150
Cantidad de suministros	19453
Cantidad de luminarias	5656

Fuente. Base de Datos GIS Electro Sur Este.

3.4. Tipos de Conductores Utilizados en el Alimentador QU-03

3.4.1. Conductores Tipo Subterráneos


El alimentador QU-03 tiene una longitud total de 266.31 Km compuesto de conductores subterráneos y aéreos. Los conductores subterráneos utilizados en el alimentador son: el NKY (Conductor de cobre con aislamiento de papel impregnado con aceite, y envoltura de plomo), el N2XSY (conductor de cobre, aislamiento XLPE y revestimiento exterior de PVC), NA2XSY (conductor de aluminio unipolar trenzado de clase 2 con aislamiento de polietileno reticulado XLPE) y un revestimiento de PVC), NA2XS2Y (cable unipolar, de media tensión y fabricado

en aluminio con aislamiento de polietileno reticulado XLPE y revestimiento exterior de polietileno).

El porcentaje en el cual son usados estos conductores se muestra en la figura siguiente, donde se puede observar que el conductor NA2XS2Y es el conductor subterráneo más utilizado.

Figura 3-2


Conductores subterráneos utilizados en el alimentador QU-03



Fuente. Base de Datos GIS Electro Sur Este.

3.4.2. Conductores Tipo Aéreos

Los conductores aéreos utilizados en el alimentador tienen una longitud total de 250 Km, lo que indica que el alimentador se compone en su mayoría de redes aéreas. Estos conductores son: tipo AAAC (conductor cableado concéntrico que se compone de una o de varias capas de alambres de aleación de aluminio), CU_DES (conductor cableado de cobre desnudo) y NA2XSA2Y-S (Cable de media tensión para distribución aérea formado por tres cables unipolares reunidos en espiral alrededor de un elemento portante formado por una cuerda de acero galvanizado y forrado con polietileno termoplástico). Entre estos el conductor AAAC es el más utilizado con un porcentaje de 94% tal como se muestra en la figura siguiente.


Figura 3-3*Conductores aéreos utilizados en el alimentador QU-03*

Fuente. Base de Datos GIS Electro Sur Este.

3.5. Clasificación de las Subestaciones del Alimentador QU-03

3.5.1. Según el Tipo de Servicio

De acuerdo al tipo de servicio se pueden clasificar en públicas y privadas. A continuación, en la figura siguiente se muestra el porcentaje de subestaciones según el tipo de servicio.

Figura 3-4*Distribución AMT QU-03 según el tipo de servicio*


Fuente. Base de Datos GIS Electro Sur Este.

3.5.2. Según el Tipo de Instalación

De acuerdo al tipo de instalación pueden ser subestaciones monoposte, biposte, tipo caseta y compacta. En la figura siguiente se muestra la distribución de las subestaciones según el tipo de Instalación.

Figura 3-5

Distribución del AMT QU-03 según el tipo de instalación




Fuente. Base de Datos GIS Electro Sur Este.

3.5.3. Según el Nivel de Tensión en el Secundario


De acuerdo a la base de datos GIS de ELSE, de las 150 subestaciones del alimentador QU-03: 126 tienen una tensión en el secundario de 220 V, 23 tienen una tensión de 380 V y solo una subestación tiene un nivel de tensión de 440 V.

3.5.4. Según la Potencia Instalada

La clasificación según la potencia instalada se muestra en el siguiente gráfico de barras, donde se puede observar que existe una subestación con potencia nominal de 1000 kVA, que es la SED 11253 que suministra de energía al mercado TOTTUS ubicado en San Sebastián.

Figura 3-6*Número de subestaciones AMT QU-03 por potencia instalada**Fuente.* Base de Datos GIS Electro Sur Este.**3.5.5. Distribución del Tipo de Alumbrado Público**

El alimentador QU-03 cuenta actualmente con un total de 5656 luminarias, de las cuales 355 son de tipo LED y 5301 son Vapor de Sodio.

Figura 3-7*Distribución del tipo de luminaria del alimentador QU-03**Fuente.* Base de Datos GIS Electro Sur Este.

3.6. Análisis del Producto Bruto Interno (PBI) Histórico 2018 - 2023

El Producto Bruto Interno (PBI) es un indicador clave para comprender las dinámicas económicas de una región y tiene una relación directa con la demanda de servicios básicos como electricidad, gas y agua. A continuación, se presenta la evolución del PBI para el sector Cusco durante el período de 2018 a 2023, datos que son fundamentales para la predicción de la demanda eléctrica en la región.

Tabla 3-2

PBI sector Electricidad, Gas y Agua años 2018 – 2023

Año	PBI (en millones)	Crecimiento Anual (%)
2018	275,531	-
2019	276,335	0.29%
2020	259,918	-5.94%
2021	274,569	5.64%
2022	272,313	-0.83%
2023	269,171	-1.15%

Fuente: Instituto Nacional de Estadística e Informática.

3.6.1. Análisis de la evolución del PBI para el sector Cusco

- **2018 y 2019:** Durante estos años, el PBI mostró una ligera estabilidad y un pequeño aumento, lo que sugiere un crecimiento económico moderado. Este comportamiento económico podría haberse traducido en un aumento en la demanda de electricidad, ya que el crecimiento económico generalmente conlleva un mayor consumo de servicios básicos como la electricidad y el gas.

- **2020:** La caída significativa en el PBI en 2020 (de 276,335 millones a 259,918 millones) se debe principalmente a los efectos de la pandemia de COVID-19. Este descenso en la actividad económica tuvo un impacto negativo en la demanda de electricidad, ya que la reducción de la actividad industrial y el confinamiento social disminuyeron el consumo de energía en muchos sectores.

- **2021 y 2022:** A medida que la economía se recuperaba en 2021, el PBI aumentó nuevamente (a 274,569 millones), lo que podría haber inducido un repunte en la demanda de electricidad. Sin embargo, la ligera caída en 2022 (272,313 millones) podría reflejar una desaceleración en la recuperación económica, lo que podría haber moderado el crecimiento de la demanda de electricidad.

- **2023:** En 2023, la disminución del PBI a 269,171 millones sugiere que la economía del sector Cusco podría haber experimentado un estancamiento. Esta desaceleración económica podría haber llevado a una demanda eléctrica más estable o incluso a una reducción en el consumo en algunos sectores.

Este análisis histórico del PBI para el sector Cusco proporciona una base importante para predecir la demanda eléctrica en la región, ya que las fluctuaciones en la actividad económica tienen un impacto directo en el consumo de electricidad, gas y agua. Integrar estos datos en un modelo de red neuronal permitirá realizar predicciones más precisas sobre la demanda futura de electricidad, teniendo en cuenta las tendencias económicas y los factores que afectan el comportamiento del consumo energético en la región.

3.7. Demanda Actual del Alimentador QU-03

En la actualidad el alimentador QU-03 tiene un total de 150 subestaciones de distribución y un total de 19459 clientes GIS, con una demanda que va creciendo año tras año. En el año 2023 el alimentador presentó una demanda total de 9,173.216 MW-h, siendo la SED 11253 perteneciente a los supermercados TTOTUS, la que mayor demanda genera con un total de 4.058 MW-h.

Los consumos de energía de las 150 subestaciones se muestran en la Tabla siguiente, estos datos son obtenidos de la base de datos GIS y el área de planeamiento de ELSE.

Tabla 3-3*Demanda de Energía del Alimentador QU-03 año 2023*

Nro.	SED	NOMBRE SED	ENERGÍA ANUAL 2023 [kW-h]
1	0010770	URB. SANTA ROSA IV	133,212.00
2	0010318	PUEBLO LIBERTADOR	520,725.60
3	0010509	DIEGO QUISPE TITO	222,996.00
4	0010679	SAN JUAN II	155,160.00
5	0011124	PATAPATAYOC PARCELA B	43,248.00
6	0010508	COMUNIDAD TICAPATA	91,692.00
7	0011230	PUMAMARCA	31,128.00
8	0010396	COMUNIDAD PUMAMARKA	57,852.00
9	0010284	URB. SANTA MARIA	222,720.00
10	0010512	URB. VILLA EL MIRADOR	380,234.40
11	0010518	LARAPA	353,352.00
12	0010924	FERIA ARTESANAL INTIHUATANA	2,100.00
13	0011127	CENTRO DE ATENCION DE LA MUJER EN SITUACION DE VIOLENCIA	203,196.00
14	0010002	FERNANDO TUPAC AMARU	207,060.00
15	0010716	TUPAC AMARU SED 0010716	346,020.00
16	0011112	HOSPITAL DE LA SOLIDARIDAD (SISOL)	86,222.40
17	0010285	URB. SANTA MARIA II	158,196.00
18	0010283	URB. CACHIMAYO I	709,468.80
19	0010891	TICAPATA I	169,956.00
20	0010720	ASOCIACION PUKLLASUNCHIS	51,982.60
21	0010951	APV. UNUNCHIS	161,292.00
22	0010960	MOISES BARREDA	57,672.00
23	0011235	CUS091 VIETTEL PERÚ S.A.C CCORAO	16,940.40
24	0011253	HIPERMERCADOS TOTTUS	3,818,820.00
25	0011288	SSEE AMERICA MOVIL CCORAO	31,766.40

Nro.	SED	NOMBRE SED	ENERGÍA ANUAL 2023 [kW-h]
26	0011289	ASOCIACION GRANJA SAN LUIS SAN JERONIMO	30,420.00
27	0011291	LOS ALAMOS	162,633.60
28	0011296	VERSALLES (MANCHAYPAMPA)	276,924.00
29	0011256	QUILLAHUATA	16,512.00
30	0010399	COMUNIDAD QUILLAHUATA	64,596.00
31	0011257	QUILLAHUATA 2	2,328.00
32	0011302	UNIDAD ESCOLAR INKA RIPAC	34,418.64
33	0011367	PARQUE LARAPA GRANDE	476,736.00
34	0011369	INCAQ SAMANAN	2,880.00
35	0011368	GOLD IMPERIUM LOS FAROS	650,208.00
36	0011372	PROLONGAC.BOLIVAR	199,476.00
37	0011336	LLACOLLAPAMPA	87,144.00
38	0011391	TORRES DEL SOL II	450,264.00
39	0011398	APV. TRES CRUCES	394,152.00
40	0010621	SIERVOS DE LOS POBRE DEL TERCER MUNDO	650,328.00
41	0010258	LARAPA I	1,078,040.80
42	0010259	LARAPA II	690,384.00
43	0011064	APV. MIRADOR STA. ROSA, LUZ DEL SUR, SOL Y LUNA, VILLA PROGRESO	42,288.00
44	0011150	A.P.V. HUAYNA PICOL 01	131,208.00
45	0011078	APV. BUENA FORTUNA, HERMOSO PAISAJE Y VILLA VICTORIA	31,320.00
46	0010513	URB. LOS ANGELES	384,228.00
47	0011442	LOS PRADOS DE SAN SEBASTIAN	199,476.00
48	0010102	FABRICA CERAMICA LUIS ZAMANES	812,196.00
49	0010289	JR. DINAMARCA (NAC. UNIDAS)	289,764.00
50	0010445	C.E.O. GUADALUPE	11,800.68
51	0010124	SAUCES DE LA PRADERA	367,200.00

Nro.	SED	NOMBRE SED	ENERGÍA ANUAL 2023 [kW-h]
52	0010444	CENT. RECR. PEDRO HUILLCA T.	16,445.16
53	0010045	MINISTERIO DE AGRICULTURA	6,606.36
54	0010440	TELEFONICA DEL PERU (LARAPA)	180,881.00
55	0010125	ISTE TUPAC AMARU	52,212.02
56	0011022	GRIFO REPSOL	256,168.80
57	0011048	RADIO TUPAC AMARU	22,357.32
58	0011058	APV. INTIKAWARINA Y V. CONVENCIANA	38,400.00
59	0011062	APV. QUINTA JARDIN, NUEVO MUNDO, SAN LAZARO, PROGRESO Y MIRAFLORES	57,960.00
60	0011069	APV. FLORESTA DEL INCA Y PIEDRA DORADA	33,984.00
61	0010701	RESIDENCIAL JARDINES	67,108.00
62	0010319	SEGURO SOCIAL IPSS (S.J.)	106,917.76
63	0010677	VILLA MANANTIAL II	267,252.00
64	0011094	CONDOMINIO LAS AMERICAS	139,884.00
65	0010127	FLOR DE LA CANTUTA	312,684.00
66	0010304	ASOC. SAN MIGUEL	299,856.00
67	0010515	SICLLAPATA	419,424.00
68	0010374	AA.HH. VILLA LOS PROCERES	376,680.00
69	0010689	MULTIMADERAS S.R.L.	203,916.00
70	0010690	FLOR DE LA KANTUTA II	205,656.00
71	0010287	URB. SANTA ROSA I	340,076.00
72	0010324	AV. CULTURA S.S.	152,076.00
73	0010973	ANTENA NEXTEL SOL DE ORO	33,584.51
74	0010606	SANTUTIS	98,959.20
75	0010320	ENACO SAN TUTIS	59,118.72
76	0011114	INTIQ SAMANAN - CHITAPAMPA	17,256.00
77	0010949	APV. LOS SALVADORES	84,480.00
78	0011126	SUNAT	508,896.00

Nro.	SED	NOMBRE SED	ENERGÍA ANUAL 2023 [kW-h]
79	0011162	PUYOC PATAPATAYOC	47,340.00
80	0011151	A.P.V. HUAYNA PICOL 02	71,364.00
81	0011159	APV. PRADERAS DEL INCA	58,248.00
82	0011160	APV CLORINDA MATTO - SUTEP	23,652.00
83	0010510	AA.HH. LA UNION	168,456.00
84	0010442	COMUNIDAD YUNCAYPATA	33,060.00
85	0010378	CCORAO 1	65,520.00
86	0010443	COMUNIDAD MANDORANI	20,916.00
87	0010563	COMUNIDAD CCORIMARCA	9,672.00
88	0010397	COMUNIDAD CHITAPAMPA	32,652.00
89	0010398	COMUNIDAD WILCAPATA	28,080.00
90	0010380	COMUNIDAD SEQUERACCAY	11,796.00
91	0010820	QUESER	1,704.00
92	0010899	VILLA NUEVA ESPERANZA	41,508.00
93	0010894	TICAPATA IV	73,644.00
94	0010936	SED TENERIAPATA	79,044.00
95	0011035	APV SOL DE LOS ANDES - SOL NACIENTE	81,852.00
96	0011039	APV MIRADOR DE LOS 4 SUYOS I	85,584.00
97	0011040	APV MIRADOR DE LOS 4 SUYOS II	30,012.00
98	0011059	APV. CONFRATERNIDAD	24,144.00
99	0011057	APV. MICAELA POMPILLA Y LOS CLAVELES	18,000.00
100	0011061	COMUNIDAD DE CORAO	71,976.00
101	0011063	APV. ALTO ALIANZA	22,968.00
102	0011065	APV. VIRGEN DEL CARMEN	39,720.00
103	0011083	APV. PILLPINTO MOCCO Y SALVADOR	14,928.00
104	0011082	APV. METHODISTAS Y METROPOLITANO	16,560.00
105	0011068	APV. SAN HILARION Y ALTO QOSQO I	107,760.00

Nro.	SED	NOMBRE SED	ENERGÍA ANUAL 2023 [kW-h]
106	0011070	APV.ALTO QOSQO II,SAN VALENTIN Y PORVENIR	58,260.00
107	0011072	APV. LOS PROCERES	119,508.00
108	0011067	VILLA RINCONADA -CCORAO	15,156.00
109	0011074	APV. FUTURO, FLORIDA, ESTRELLA DE DAVID Y MIRADOR NIHUAS	48,516.00
110	0011075	APV.BALCON DEL CIELO, BELLA LA PARADA	29,496.00
111	0011076	APV. VISTA PANORAMICA I	17,076.00
112	0011077	APV. HUAYNA CCAPAC	33,588.00
113	0011079	APV. VILLA HERMOSA , SUMAC HUASI	16,116.00
114	0010895	TICAPATA V	66,672.00
115	0010614	MARCACHAYOC	75,432.00
116	0011115	SIERVOS DEL TERCER MUNDO	90,487.44
117	0010893	TICAPATA III	37,968.00
118	0011071	APV. NIETOS DE QUISPERROCA Y PORVENIR TAHUANTINSUYO I	27,228.00
119	0011028	APV. REPUBLICA DE FRANCIA	45,732.00
120	0010676	PROL. AV. CUSCO	336,968.85
121	0010292	URB. SANTA ROSA III	421,562.40
122	0010290	AV. ALEMANIA I (NAC. UNIDAS)	448,992.48
123	0010291	URB. SANTA ROSA II	310,780.00
124	0010400	COVIDUC	406,632.00
125	0010253	CAMINO REAL S.S.	211,296.00
126	0010251	LARAPA	572,740.80
127	0010286	URB. SANTA MARIA I	150,573.60
128	0010417	COVIPONA LARAPA	417,564.00
129	0010441	LARAPA PICOL	118,032.00
130	0010691	ISTE TUPAC AMARU II	64,212.00
131	0010826	MINKA	80,484.00

Nro.	SED	NOMBRE SED	ENERGÍA ANUAL 2023 [kW-h]
132	0010058	URB. SAN JUAN	425,791.20
133	0010858	APV. MIRADOR PACHACUTEQ	140,052.00
134	0010892	TICAPATA II	111,516.00
135	0011080	APV. HANAN QOSQO,VILLA REAL,JOSE MARIA Y SANTO TOMAS	85,596.00
136	0011081	APV. MONTERRICO, BOBEDAYOC,URPICHAYOC, SAN FRANCISCO	155,172.00
137	0010321	SOL DE ORO	146,184.00
138	0010143	URB. LA PLANICIE II	405,672.00
139	0010004	URB. LA PLANICIE I	130,872.00
140	0010288	AV. FRANCIA (NAC. UNIDAS)	324,180.00
141	0010293	J.C. MARIATEGUI SANTA ROSA IV	480,312.00
142	0010511	URB. SAN JOSE	223,140.02
143	0010126	TUYRUTUPA S.S	383,282.80
144	0010702	PROL. AV. DE LA CULTURA 4TO. PARADERO	460,300.32
145	0010950	APV. ATAHUALLPA	29,376.00
146	0011093	AV.LA CULTURA-2DO PARADERO	275,288.80
147	0010514	URB. VALLECITO	377,348.00
148	0011073	APV. REALES DEL BOSQUE	89,472.00
149	0011388	APV. LAS LOMAS 02	199,476.00
150	0011387	APV. LAS LOMAS 01	401,352.00
TOTAL			9,173,216.00

Fuente. Base de Datos GIS – ELSE.

Los datos históricos de la demanda actual son la base para la construcción del modelo para su predicción futura. Estos datos proporcionan información sobre patrones de consumo, tendencias estacionales y variaciones a lo largo del tiempo, que son fundamentales para comprender y predecir el comportamiento futuro de la demanda.

CAPÍTULO IV

IMPLEMENTACIÓN DE LAS REDES NEURONALES PARA EL PRONÓSTICO DE LA DEMANDA EN EL ALIMENTADOR QU-03

4.1. Introducción

En este capítulo, se desarrolla el procedimiento para la aplicación de las redes neuronales en el pronóstico de la demanda del alimentador QU-03. Para la implementación de la red neuronal se hará uso del lenguaje de programación Python, dentro del cual se encuentran distintas librerías relacionadas al Machine Learning, que proporcionan varias funciones para la creación, el entrenamiento y el modelamiento de redes neuronales.

Por otra parte, se define también el horizonte de estudio para el pronóstico de la demanda en el alimentador.

4.2. Definición del Horizonte de Estudio

Antes de desarrollar la red neuronal, es necesario conocer el horizonte de estudio, para evaluar la demanda futura. Según su horizonte se clasifica en: corto, mediano y largo plazo, estas clasificaciones se desarrollan a continuación.

4.2.1. Corto Plazo (*hasta 2 años*)

El tiempo es adoptado con el propósito de contrarrestar inconvenientes como la culminación de la vida útil de los conductores, el incremento de la tasa de crecimiento que la máxima demanda ha presentado durante los últimos años y que se verá incrementada por la aparición de nuevas cargas de considerable demanda. A fin de garantizar criterios apropiados de funcionamiento.

4.2.2. Mediano Plazo (*de 2 a 5 años*)

Con la finalidad de asegurar que las decisiones tomadas a corto plazo se ajusten dentro de los requerimientos del largo plazo y que, por lo tanto, las instalaciones que se decidieron

ejecutar, contribuyan a tener un planeamiento del sistema mínimo costo y con parámetros eléctricos adecuados.

4.2.3. Largo Plazo (de 5 a 10 años):

El resultado del planeamiento a largo plazo es la factibilidad técnica (asegurar la vida útil del conductor a criterios apropiados de funcionamiento) de los cambios al sistema, decididos en el corto y mediano Plazo.


Tomando en consideración estos criterios, se toma un horizonte de evaluación de mediano plazo, debido a que; el horizonte a corto plazo es un tiempo muy corto, pues de ser viable este tema de tesis pasaría por diferentes procesos para la elaboración del expediente definitivo, que tendría un periodo mayor a 1 año; Así también el horizonte de largo plazo es un periodo muy largo en donde no se podría contemplar la aparición de nuevas cargas de potencia considerable.

4.3. Diagrama de Flujo para el Diseño de la Red Neuronal

Para tener una mejor perspectiva en la secuencia de actividades, se muestra el siguiente diagrama de flujo, que representa los pasos para el desarrollo de la red neuronal aplicado a la predicción de la demanda.

Los diagramas de flujo proporcionan una representación visual del proceso de programación de redes neuronales, lo que facilita la comprensión de los pasos involucrados y la secuencia en la que deben llevarse a cabo. Así también, Permiten organizar y estructurar de manera clara y lógica los pasos necesarios para desarrollar y entrenar una red neuronal. Esto ayuda a mantener un enfoque ordenado y sistemático durante todo el proceso de programación. Sirven como una forma efectiva de documentar el proceso de programación de redes neuronales, lo que facilita la comunicación entre miembros del equipo y permite compartir el conocimiento de manera clara y concisa.

Figura 4-1
Diagrama de flujo



Fuente. Elaboración propia.

4.4. Descripción del diagrama de flujo

El proceso de predicción de la demanda eléctrica sigue una serie de etapas organizadas en el diagrama de flujo, desde la recopilación de datos hasta la evaluación y validación del modelo. Se consideran tanto la demanda eléctrica como el impacto del Producto Bruto Interno, optimizando los parámetros de la red neuronal para mejorar la precisión de las predicciones.

4.4.1. Preprocesamiento de datos

El preprocesamiento de datos es una etapa clave para garantizar la calidad y utilidad de la información utilizada en el modelo. En esta fase se lleva a cabo:

- **Limpieza de datos:** Eliminación de valores atípicos o inconsistentes.

- **Organización y estructuración:** Agrupación de la demanda eléctrica según la subestación correspondiente y su capacidad de potencia instalada.
- **Preparación del impacto del PBI:** Incorporación de esta variable como factor influyente en el consumo energético.

Este proceso asegura que el modelo pueda interpretar correctamente los patrones de consumo y mejorar su precisión predictiva.

4.4.2. Partición de los datos de prueba Training - Test

Para validar la eficacia del modelo, los datos se dividen en dos conjuntos:

- Conjunto de entrenamiento (2018-2022): Datos históricos utilizados para ajustar los parámetros de la red neuronal.
- Conjunto de prueba (2023): Datos reservados para evaluar el rendimiento del modelo en condiciones realistas, simulando predicciones futuras.

Esta división garantiza que el modelo no solo memorice los datos (sobreajuste), sino que genere predicciones precisas en escenarios no vistos.

4.4.3. Entrenamiento de la red neuronal

4.4.3.1. Arquitectura de la Red Neuronal

La red neuronal diseñada para la predicción de demanda eléctrica sigue una arquitectura **feedforward** (propagación hacia adelante), compuesta por:

Capa de Entrada:

- Neuronas representando subestaciones de distribución.
- Datos históricos de demanda eléctrica (2018-2022) y el PBI, preprocesados y normalizados.

Capas Ocultas:

4 capas ocultas iniciales, con un número variable de neuronas por capa (ajustable durante la optimización).

Función de activación:

Sigmoide en las primeras iteraciones, seleccionada por su capacidad para manejar no linealidades en los datos.

Capa de Salida:

- 1 neurona (configuración típica para problemas de regresión como la predicción de demanda).
- Función de activación **lineal o Sigmoide**, dependiendo del rango de escalamiento de los datos.

4.4.4. Evaluación de resultados

Tras el entrenamiento, el modelo se valida con el conjunto de prueba (2023). Dos escenarios posibles:

➤ **Evaluación exitosa:**

- El modelo muestra alta precisión en las predicciones.
- Se procede a proyectar la demanda para los años 2023-2027.

➤ **Evaluación deficiente:**

Se optimizan los parámetros:

- Número de capas ocultas (aumentar o reducir complejidad).
- Impacto del PBI (inclusión o ajuste en la entrada).
- Funciones de activación (ReLU para capas ocultas, Sigmoide/Tanh para salida).
- Optimizadores (Adam, RMSprop).
- Ajuste de pesos sinápticos.

4.4.5. Modelo validado para la predicción

Una vez validado, el modelo genera proyecciones de demanda eléctrica para 2023-2027. Estos resultados se presentan como valores numéricos que permiten:

- Planificar la capacidad de generación y distribución.
- Mitigar pérdidas técnicas y no técnicas.
- Optimizar la gestión del suministro eléctrico.

4.5. Crecimiento Histórico de la Demanda en el Alimentador QU-03

Para poder llevar a cabo la preparación de datos, se debe tener en cuenta el crecimiento histórico de la demanda. La base de datos proporcionada por el Sistema de Información Geográfica “SIG” de ELSE, comprende la demanda anual de energía del alimentador QU-03 pertenecientes al periodo que va del año 2018 al 2022.

El resumen del crecimiento de la demanda para los años comprendidos entre el 2018 al 2022 se muestran en la tabla siguiente.

Tabla 4-1

Crecimiento de la demanda años 2018 al 2022

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
1	0010770	81,304.36	85,412.50	91,160.50	102,702.21	123,737.60
2	0010318	394,089.00	395,798.60	410,412.43	421,688.05	496,103.59
3	0010509	176,683.00	184,013.00	188,401.00	206,604.91	203,105.64
4	0010679	123,376.00	117,979.00	122,582.21	129,243.49	152,051.16
5	0011124	--	--	12,626.00	21,420.85	31,802.40
6	0010508	33,457.00	37,635.00	41,337.00	76,872.35	81,274.16
7	0011230	--	--	15,936.00	23,743.78	28,390.58
8	0010396	45,694.00	49,240.00	44,271.00	42,953.36	53,468.78
9	0010284	186,032.70	192,018.40	195,662.00	205,998.18	211,639.92
10	0010512	296,803.60	313,730.00	329,026.00	348,488.17	352,586.29
11	0010518	229,549.76	234,079.05	240,566.25	257,814.36	322,267.96

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
12	0010924	5,510.00	5,582.00	4,106.00	4,476.56	2,428.00
13	0011127	--	--	--	--	--
14	0010002	140,619.00	148,213.00	153,129.00	183,414.73	194,087.21
15	0010716	250,088.40	252,770.28	255,267.00	317,786.21	310,918.52
16	0011112	39,778.44	40,556.49	41,144.02	41,222.19	43,391.78
17	0010285	111,282.00	113,160.00	120,095.00	133,032.53	133,744.80
18	0010283	464,286.86	509,790.33	529,339.34	539,229.34	665,715.24
19	0010891	30,652.00	35,325.00	64,076.00	136,446.82	152,654.78
20	0010720	33,989.06	30,983.75	28,130.17	36,081.91	48,919.90
21	0010951	63,227.00	69,016.00	75,592.00	115,529.15	140,889.20
22	0010960	19,921.00	17,959.00	17,768.00	40,659.48	46,951.79
23	0011235	--	--	--	--	26,701.66
24	0011253	--	--	--	3,055,056.00	2,214,915.60
25	0011288	--	--	--	--	27,525.78
26	0011289	--	--	--	18,083.29	27,685.19
27	0011291	--	--	--	134,565.26	164,103.97
28	0011296	--	--	--	239,730.56	253,413.19
29	0011256	--	--	--	6,707.70	13,860.80
30	0010399	34,873.00	40,421.00	39,552.00	44,930.65	51,893.56
31	0011257	--	--	--	966.00	1,067.00
32	0011302	--	--	--	--	31,915.76
33	0011367	--	--	--	--	459,021.18
34	0011369	--	--	--	--	1,536.05

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
35	0011368	--	--	--	--	--
36	0011372	--	--	--	--	--
37	0011336	--	--	--	--	10,319.00
38	0011391	--	--	--	--	--
39	0011398	--	--	--	--	--
40	0010621	--	--	--	--	--
41	0010258	986,593.00	1,073,316.80	1,072,340.80	1,074,380.50	1,077,040.80
42	0010259	445,992.00	424,732.00	369,998.00	422,590.27	655,438.36
43	0011064	--	20,544.00	22,129.00	30,206.87	38,171.82
44	0011150	--	8,340.00	59,984.00	93,553.76	115,401.37
45	0011078	--	17,616.00	14,807.00	21,271.37	25,345.99
46	0010513	313,656.00	323,487.00	346,148.00	351,882.43	366,210.89
47	0011442	--	--	--	--	--
48	0010102	--	--	--	--	--
49	0010289	244,867.00	239,530.00	236,665.00	230,586.89	268,124.29
50	0010445	12,284.01	12,352.07	13,543.94	12,903.76	10,900.28
51	0010124	272,123.00	282,564.00	289,624.00	323,595.29	340,626.62
52	0010444	16,785.41	17,629.59	17,934.70	18,146.56	18,902.66
53	0010045	6,145.95	5,380.30	4,399.52	4,615.52	469.79
54	0010440	168,557.66	175,598.48	178,831.00	180,081.00	179,831.00
55	0010125	83,765.46	84,945.85	87,305.41	85,104.76	46,358.00
56	0011022	31,100.00	62,935.00	212,475.00	216,490.19	214,526.00
57	0011048	17,583.00	9,635.52	9,882.07	24,079.44	9,254.00

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
58	0011058	--	10,980.00	11,368.00	19,462.87	32,598.00
59	0011062	--	14,976.00	22,396.00	35,481.67	53,845.00
60	0011069	--	8,220.00	11,309.00	19,629.19	28,562.00
61	0010701	82,828.00	80,950.00	75,055.00	62,052.69	63,124.00
62	0010319	53,763.69	46,852.48	50,417.76	80,417.76	105,417.76
63	0010677	194,186.00	192,287.00	212,916.00	232,852.94	260,582.00
64	0011094	71,305.21	73,992.00	85,008.00	107,363.01	135,248.00
65	0010127	195,460.20	201,468.00	223,257.00	249,111.41	292,401.32
66	0010304	259,625.00	280,420.00	277,910.00	280,964.52	284,050.40
67	0010515	405,196.00	421,705.00	407,359.00	393,223.28	397,195.24
68	0010374	342,964.50	347,599.50	351,866.28	355,595.03	359,899.84
69	0010689	--	--	--	--	--
70	0010690	183,923.00	190,740.00	191,830.28	192,196.98	196,119.37
71	0010287	276,293.00	320,704.00	332,583.00	335,865.72	345,554.54
72	0010324	58,095.80	60,627.80	88,592.80	99,895.87	110,995.42
73	0010973	23,980.63	30,112.54	28,124.02	30,638.51	32,186.51
74	0010606	68,699.60	63,881.80	67,001.80	79,842.57	85,852.22
75	0010320	52,135.69	51,024.56	54,924.40	45,978.09	47,400.10
76	0011114	11,424.00	10,829.00	10,509.00	13,296.43	14,338.22
77	0010949	42,146.00	49,053.00	68,132.00	63,473.05	75,563.16
78	0011126	--	--	--	--	--
79	0011162	--	--	11,050.00	20,119.32	38,782.03
80	0011151	--	6,756.00	26,705.00	58,615.84	62,041.22

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
81	0011159	--	4,104.00	22,823.00	27,611.43	48,069.82
82	0011160	--	22,764.00	22,066.00	20,435.12	23,069.17
83	0010510	106,913.00	107,916.00	116,597.00	145,996.88	151,699.57
84	0010442	22,203.00	25,127.00	24,227.00	28,311.92	31,783.21
85	0010378	60,092.00	61,230.40	60,911.22	61,134.70	58,420.07
86	0010443	21,231.00	21,604.00	19,588.00	15,559.86	16,819.57
87	0010563	8,766.00	8,795.00	8,622.00	7,502.40	7,868.99
88	0010397	21,026.00	20,585.00	22,190.00	24,808.91	28,294.00
89	0010398	20,739.00	22,426.00	22,575.00	24,415.14	26,799.58
90	0010380	6,471.00	6,380.00	6,304.00	5,679.38	7,450.02
91	0010820	2,140.00	1,974.00	1,656.00	1,172.00	1,584.00
92	0010899	20,285.00	22,860.00	24,622.00	32,365.70	38,714.38
93	0010894	22,785.00	27,573.00	37,053.00	56,656.28	59,022.04
94	0010936	47,456.00	51,885.00	54,273.00	62,431.28	73,527.38
95	0011035	44,672.00	64,529.00	47,727.00	51,467.92	65,240.77
96	0011039	33,13--	30,078.00	37,597.00	56,435.83	67,765.37
97	0011040	8,121.30	10,766.32	9,012.00	18,201.68	26,661.40
98	0011059	--	7,776.00	9,302.00	14,844.49	18,352.80
99	0011057	--	8,136.00	7,130.00	10,460.09	12,305.99
100	0011061	40,118.40	43,317.00	50,168.00	67,318.25	67,921.20
101	0011063	--	1,932.00	3,377.00	8,375.89	20,771.78
102	0011065	--	13,836.00	15,574.00	17,610.26	29,293.21
103	0011083	--	4,260.00	6,997.00	12,936.80	13,254.82

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
104	0011082	--	8,004.00	6,716.00	12,389.93	14,832.79
105	0011068	--	27,096.00	29,468.00	59,050.58	81,371.34
106	0011070	--	5,064.00	6,598.00	13,079.02	40,271.81
107	0011072	--	26,424.00	27,525.00	54,285.54	77,788.45
108	0011067	--	--	3,840.00	5,675.27	5,850.79
109	0011074	--	16,248.00	19,843.00	29,520.16	39,769.61
110	0011075	--	12,192.00	11,562.00	21,480.44	26,566.58
111	0011076	--	5,224.80	6,858.00	9,637.70	12,980.59
112	0011077	--	11,496.00	7,866.00	16,594.37	24,562.98
113	0011079	--	6,132.00	9,267.00	15,625.57	17,717.58
114	0010895	33,470.00	48,444.00	40,517.00	48,121.54	54,561.90
115	0010614	78,319.00	78,743.00	69,119.00	72,622.00	76,969.19
116	0011115	29,319.60	36,155.35	83,026.55	79,944.11	83,275.12
117	0010893	5,999.00	7,084.00	14,207.00	26,734.27	31,075.98
118	0011071	--	1,476.00	2,817.00	14,475.89	15,017.60
119	0011028	24,738.00	21,824.00	24,960.00	30,232.30	33,481.58
120	0010676	364,948.90	327,150.10	316,714.80	325,968.85	332,968.85
121	0010292	354,101.40	374,154.60	393,458.60	396,940.66	406,907.75
122	0010290	403,460.92	423,410.92	429,794.92	427,129.98	430,034.46
123	0010291	249,742.00	264,287.00	276,798.00	294,487.02	307,318.00
124	0010400	296,956.00	301,139.00	311,401.00	328,027.87	333,337.60
125	0010253	209,331.00	226,170.00	212,059.00	192,379.24	200,395.04
126	0010251	431,238.10	424,046.80	504,254.80	510,072.46	533,015.20

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
127	0010286	147,484.00	152,489.00	146,431.00	146,294.06	159,081.97
128	0010417	323,937.00	330,814.00	344,815.00	379,928.06	403,592.87
129	0010441	100,156.00	103,115.88	101,711.89	101,124.79	104,252.36
130	0010691	17,195.00	18,162.00	29,641.00	59,613.96	59,404.19
131	0010826	59,779.00	61,958.00	64,207.00	77,352.77	76,515.66
132	0010058	331,001.80	357,863.58	367,309.80	353,789.11	406,654.15
133	0010858	47,173.00	51,501.00	82,214.00	904.39	1,063.99
134	0010892	50,734.00	53,369.00	77,509.00	94,533.06	101,648.45
135	0011080	--	14,160.00	19,956.00	46,295.60	57,555.22
136	0011081	--	49,692.00	56,660.00	82,221.22	113,951.75
137	0010321	116,704.80	126,937.30	131,481.60	133,666.53	151,893.78
138	0010143	122,967.00	137,608.00	177,750.25	211,842.10	238,024.84
139	0010004	96,496.00	93,751.00	101,109.00	97,337.17	108,421.21
140	0010288	240,651.30	246,270.15	247,982.72	262,341.73	316,074.37
141	0010293	436,914.00	436,968.00	442,658.00	456,036.43	461,490.48
142	0010511	157,990.00	176,225.00	181,424.00	195,296.30	221,690.16
143	0010126	293,137.00	293,709.00	325,401.20	328,331.80	372,559.43
144	0010702	365,189.00	419,277.27	405,116.59	427,328.37	452,092.20
145	0010950	22,271.00	21,172.00	20,772.00	21,183.22	24,017.95
146	0011093	208,555.20	227,155.00	214,127.60	237,004.76	267,078.98
147	0010514	307,221.00	333,283.00	345,908.00	352,189.36	373,283.16
148	0011073	--	18,192.00	26,510.00	48,654.55	69,206.81
149	0011388	--	--	--	--	--

Nro.	SED	ENERGÍA ANUAL 2018[kW-h]	ENERGÍA ANUAL 2019[kW-h]	ENERGÍA ANUAL 2020[kW-h]	ENERGÍA ANUAL 2021[kW-h]	ENERGÍA ANUAL 2022[kW-h]
150	0011387	--	--	--	--	--
TOTAL		14,098,039	15,062,976.	15,916,336	20,621,669	22,084,780

Fuente. Base de Datos GIS – ELSE.

Estos datos fueron obtenidos mediante la recopilación de información de la base de datos Gis de Electro Sur Este. Ordenados de acuerdo al número de subestaciones comprendidas en el alimentador y la cantidad de años registrados.

Así también, para tener un mejor enfoque y entendimiento de estos datos se muestra la gráfica siguiente.

Figura 4-2

Crecimiento de la demanda año 2018 al 2023



Fuente. Elaboración propia.

Según la figura anterior se puede observar que en el año 2018 se registró una demanda anual de 14,098.04 MW-h, para el año 2019 se obtuvo un crecimiento de 15,062.98 MW-h, en el año 2020 se aprecia una demanda de 15,916.34 MW-h con respecto a un crecimiento exponencial, de igual forma para el año 2021 se obtuvo una demanda de 20,622.51 MW-h, para el caso de los años 2020 al 2021 se puede observar una pendiente relativamente alta, esto debido principalmente al estado de emergencia que se presentó por el COVID-19, ya que por este motivo se incrementó el uso de energía eléctrica especialmente en tipos de carga doméstica. Dicho aumento es debido a que la mayoría de personas estuvieron en confinamiento obligatorio, logrando realizar actividades como: teletrabajo, clases virtuales, actividades de distracción y otros, de manera virtual y con un uso más intensivo durante todo el día.

Para procesar la información de la demanda eléctrica y manejar los valores atípicos, especialmente aquellos observados durante la pandemia de COVID-19, recopilaron datos históricos mensuales, identificando las demandas mensuales durante el período de la pandemia, que según la tendencia de la figura anterior, el mayor consumo de energía debido a la pandemia de COVID-19 se produjo principalmente durante los años 2020 y 2021, con un crecimiento de 15,916.34 MW-h a 20,622.51 MW-h. Durante este período, el confinamiento y las restricciones hicieron que muchas personas trabajaran y estudiaran desde casa, lo que aumentó significativamente el consumo de energía residencial. Además, hubo variaciones en el consumo energético en sectores industriales y comerciales debido a cierres temporales y cambios en los patrones de actividad.

La importancia de conocer la demanda histórica en el alimentador QU-03, es fundamentalmente la elección del conjunto de entrenamiento y prueba que se integrará en la construcción de la red neuronal.

4.6. Procedimiento de la Metodología

Para crear la metodología para la aplicación de las redes neuronales para la predicción de la demanda, se siguen los siguientes pasos:

- a) **Recopilación de datos:** Obtener un conjunto de datos históricos de la demanda, que incluya información sobre la variable de interés (en este caso, la demanda de energía eléctrica) y los factores que pueden influir en ella (cantidad de usuarios en el alimentador y potencia demandada). Además, se incorpora una nueva variable denominada PBI (Producto Bruto Interno), la cual se considera un factor relevante en la evolución de la demanda energética.
- b) **Preprocesamiento de datos:** Llevar a cabo tareas de limpieza, transformación y normalización de los datos para prepararlos para su uso en el modelo de redes neuronales, esto mediante el acomodamiento de datos en una hoja Excel. Esto puede incluir la eliminación de valores atípicos, la imputación de datos faltantes y la escala de los datos para que estén en un rango compatible con el modelo.
- c) **División de datos:** Dividir el conjunto de datos en conjuntos de entrenamiento, validación y prueba. El conjunto de entrenamiento se utilizará para ajustar los pesos de la red neuronal, el conjunto de validación se utilizará para ajustar los parámetros del modelo y evitar el sobreajuste, y el conjunto de prueba se utilizará para evaluar el rendimiento final del modelo.
- d) **Diseño de la arquitectura de la red neuronal:** Seleccionar la arquitectura de la red neuronal, que incluye el número de capas ocultas, el número de neuronas en cada capa, la función de activación y las funciones de optimización. En el caso de la predicción de la demanda, una arquitectura comúnmente utilizada es una red neuronal con una capa de entrada, una o varias capas ocultas y una capa de salida.

- e) Entrenamiento del modelo: Utilizar el conjunto de entrenamiento para ajustar los pesos de la red neuronal utilizando un algoritmo de optimización, como el algoritmo de retro propagación. Durante el entrenamiento, la red neuronal aprende a mapear las entradas (datos históricos de la demanda) a las salidas (predicciones de la demanda futura).
- f) Validación de resultados: Utilizar el conjunto de validación para ajustar los resultados del modelo, como la tasa de aprendizaje, el tamaño del lote y la regularización, con el fin de mejorar el rendimiento del modelo y evitar el sobreajuste.
- g) Evaluación del modelo: Utilizar el conjunto de prueba para evaluar el rendimiento final del modelo en datos no vistos. Esto puede implicar calcular métricas de rendimiento, como el error medio cuadrático (RMSE) o el error absoluto medio (EAM), para comparar las predicciones del modelo con los valores reales de la demanda.
- h) Despliegue del modelo: Una vez que el modelo ha sido entrenado y evaluado satisfactoriamente, se puede desplegar en producción para hacer predicciones de la demanda para los años futuros (2023-2027). Este procedimiento tomando como base el artículo “Pronóstico De Demanda Por Medio De Redes Neuronales Artificiales” el cual explora el uso de Redes Neuronales Artificiales (RNAs) en la predicción de la demanda, proponiendo un enfoque que define los parámetros de las RNAs de manera integrada y reproducible
- i) Una vez que el modelo ha sido entrenado y evaluado satisfactoriamente, se puede desplegar en producción para hacer predicciones de la demanda para los años futuros (2023-2027).

Este procedimiento tomando como base el artículo “**Pronóstico De Demanda Por Medio De Redes Neuronales Artificiales**” el cual explora el uso de Redes Neuronales Artificiales (RNAs) en la predicción de la demanda, proponiendo un enfoque que define los parámetros de las RNAs de manera integrada y reproducible.

“En este trabajo se propuso una metodología de selección de parámetros de un modelo de RNA que utiliza técnicas establecidas y confiables y hace entendible la interrelación entre los varios parámetros de la RNA. Se demostró el funcionamiento de la metodología a través de un caso práctico, en el que se utilizaron modelos de RNA con múltiples salidas” (Salazar Aguilar y Cabrera Ríos, 2007).

4.7. Selección de Variables

El proceso de introducción de variables comprende la selección de variables que se introducirán en la red neuronal, en este caso la entrada comprende el registro histórico de la evolución de la demanda en el alimentador QU-03 y el PBI. Obtenida ya esta información se precede a separar los datos iniciales en dos conjuntos, uno de entrenamiento y otro de prueba o test.

4.8. Elección del Conjunto de Entrenamiento y Test

Para entrenar la red neuronal y poder saber si este modelo tiene un buen desempeño, se separa el conjunto en dos:

4.8.1. Conjunto de Entrenamiento

Para el conjunto de entrenamiento, se decide separar la información histórica de la demanda en el alimentador en conjuntos proporcionales a 10% y 90%, siendo el 90% dedicado al conjunto de aprendizaje, por lo general se toman muestras aleatorias no secuenciales. El conjunto de entrenamiento va de enero del 2018 a junio del 2023.

4.8.2. Conjunto de Prueba

Para validar si el modelo de la red neuronal está funcionando bien, es necesario tener un conjunto de prueba para estimar que tan bien está entrenado el modelo (que depende del tamaño de muestra, función de activación y parámetros internos de la red neuronal). Los datos del conjunto de prueba están comprendidos de julio a diciembre del 2023, en estos meses se pretende evaluar de manera objetiva el desempeño de la red neuronal para el pronóstico de la demanda a mediano plazo.

4.9. Diseño de la Red Neuronal para la predicción de la Demanda

Una vez dividida la información en dos archivos Excel (entrenamiento y prueba), se procede a la creación de la red neuronal. Para la construcción de esta red se hará uso de las bibliotecas Keras y Sklearn, que son librerías de Python diseñadas para crear modelos de Machine Learning y su evaluación. Así mismo la red neuronal que se diseña, es una red recurrente LSTM, que es un modelo artificial relativamente simple y se refiere principalmente a la multiplicación de matrices.

4.9.1. Pasos Temporales

La estructura de la red será de unos 12 pasos temporales, esto significa que el modelo evaluará cada 12 valores anteriores de la demanda, y basado en estos datos la red va a predecir el próximo valor de salida (output). Se escoge 12 pasos temporales porque comprende un periodo anual.

4.9.2. Configuración de la Red Neuronal


Antes del diseño de la red neuronal se debe determinar, el número de capas, el número de neuronas en cada capa, escalado de características(preprocessing) y las funciones de activación.

Para este caso, se comienza con un número de capas igual a 5, 4 capas LSTM y una capa densa de salida output. El número de neuronas en la capa de entrada es 12, que viene a

ser la cantidad de pasos temporales. Las capas 0, 1, 2 y 3 son capas LSTM y tienen 50 neuronas cada una, y finalmente la capa de salida, que es una capa densa de una sola neurona de salida, que comprende la demanda pronosticada. La función de activación es “tanh” y la transformación de datos será MinMaxScaler, que es un pre procesamiento de Sklearn cuyo rango está entre 0 a 1.

Figura 4-3

Estructura de la Red neuronal para el pronóstico de la demanda



Fuente. Elaboración propia.

4.10. Entrenamiento de la Red Neuronal

Después de crear la red neuronal recurrente se procede a su entrenamiento esto por medio de la función *regresor.fit()* de la librería Keras agregando 4 parámetros, los primeros 2 son los inputs del conjunto de entrenamiento, luego el número de épocas, que son la cantidad de iteraciones que entrenará el modelo, para este caso se utiliza un número de épocas igual a 100. Luego el *batch_size* que se refiere al número de lote que se quiere para analizar los datos, en este caso el *batch_size* es igual a 32, ya que este valor da buenos resultados.

El código de este entrenamiento, así como la estructura de la red neuronal se muestra en el Anexo A.

Compilados estos datos se procede a entrenar la red, obteniendo una demanda anual para el año 2023 de 30,163.25 MW-h, que comparada con la demanda real en el año 2023 de 30,476.41 MW-h y aplicando la teoría del error relativo porcentual.

$$error = \frac{Valor\ real - Valor\ calculado}{Valor\ real} \times 100\% \quad (4-1)$$

Se obtiene un error porcentual de 1.03%, indicando que la predicción de la red tiene una buena aproximación.

4.11. Optimización del rendimiento de la Red Neuronal

Para optimizar la red neuronal y obtener valores más cercanos a la realidad o al conjunto de prueba, se puede manipular los diferentes parámetros, como la función de pérdida, la función de activación, el número de capas y el número de neuronas.

4.11.1. Cantidad de Capas

Para tener un mejor desempeño en el modelo, se manipulará la cantidad de capas de la red neuronal. Para este caso se trabaja con un numero de capas ocultas LSTM de: 2, 3, 4 y 5. Obteniendo los siguientes resultados.


Tabla 4-2*Tabla comparativa con la manipulación del nro. de capas*

	Número de Capas			
	2	3	4	5
Error Porcentual (%)	6.07%	6.41%	5.87%	6.33%
Pérdida	0.0199	0.0200	0.0196	0.0188

Fuente. Librería Keras - Python.

En la Tabla anterior se puede observar que para un número de capas igual a 2 se tiene un error porcentual relativo de 6.07% y una pérdida de 0.0199, aumentando el número de capas a 3 el error porcentual aumenta y la pérdida aumenta ligeramente. Cuando el número de capas es 4 el error disminuye a 5.87%, así también la pérdida disminuye a 0.0196 indicando una buena aproximación. Esto indicaría que aumentando el número de capas se tendría buenas aproximaciones, pero no suele suceder así, observando la tabla para un número de capas igual a 5 el error aumenta a 6.33% y las pérdidas a 0.0188. Según estos resultados, teniendo un número de capas igual a 4 se tiene un mejor desempeño en la red neuronal.

Para poder observar la velocidad de convergencia sobre el número de épocas, podemos hacer uso de la librería *matplotlib* y mostrar la siguiente figura.

Figura 4-4*Gráfico de pérdidas para 5 capas y una validación de 100 épocas**Fuente.* Librería Keras - Python.

4.11.2. Función de activación

Otra opción para obtener un mejor desempeño en la red, es utilizar otra función de activación. Las funciones que se experimentarán son: ReLU, softmax, sigmoid y tanh, los conceptos teóricos de estas funciones se desarrollaron en el capítulo II - marco teórico.

Los resultados de experimentar las distintas funciones de activación se muestran en la siguiente tabla.

Tabla 4-3

Tabla comparativa con la manipulación de la función de activación


	Función de Activación			
	ReLU	Softmax	Sigmoide	Tanh
Error Porcentual (%)	6.29%	0.72%	15.82%	6.33%
Pérdida	0.0601	0.8889	0.0978	0.0192

Fuente. Librería Keras - Python.

En la Tabla anterior se puede ver que la función Softmax tiene un error porcentual muy bajo de 0.72% pero tiene una pérdida de 0.8889, además las pérdidas del modelo no presentan una convergencia (pendiente) en un punto cercano a cero tal como se ve en la Figura siguiente.

Figura 4-5

Gráfico de pérdidas para una función de activación Softmax




Fuente. Librería Keras - Python.

Por otra parte, la función sigmoide presenta un error porcentual de 15.82% siendo la mayor de todas estas funciones. La función Tanh presenta el mejor desempeño con un 6.33% de error y una pérdida de 0.0192 comparada a la función ReLU que tiene un error ligeramente bajo, pero una pérdida relativamente mayor a la función Tanh. La convergencia de estas funciones de activación se muestra en la siguiente figura.

Figura 4-6

Gráfico de pérdidas para ReLU, Sigmoide y Tanh



Fuente. Librería Keras - Python.

4.11.3. Optimizadores para modelos Keras


El optimizador o llamado también optimizers, es uno de los dos argumentos necesarios para compilar un modelo en Keras. Básicamente su funcionamiento es generar pesos cada vez mejores. Dentro de los principales optimizadores disponibles en Keras se tiene el RMSprop (propagación cuadrática media) y Adam, que es una extensión del descenso del gradiente. Los resultados de estos dos optimizadores se muestran en la tabla siguiente.

Tabla 4-4*Tabla comparativa de los optimizadores para modelos Keras*

	Optimizadores	
	RMSprop	Adam
Error Porcentual (%)	6.29%	6.33%
Pérdida	0.0184	0.0192

Fuente. Librería Keras - Python.

Como se aprecia en la Tabla anterior, el optimizador RMSprop presenta valores menores de error y pérdida a comparación del optimizador Adam, por este motivo el RMSprop tiene un mejor desempeño en el modelo. Así también, ambas opciones presentan una convergencia satisfactoria en el modelo de pérdidas tal como se muestra en la figura.

Figura 4-7*Pérdidas para los optimizadores RMSprop y Adam**Fuente.* Librería Keras - Python.

4.12. Evaluación de Parámetros del Modelo Predictivo


La arquitectura de la red neuronal, específicamente el número de capas ocultas, juega un papel crucial en su capacidad para aprender patrones complejos en los datos. En este estudio,

se experimentó con un número de capas ocultas LSTM de 2, 3, 4 y 5, obteniendo los siguientes resultados.

La Figura siguiente presenta una superposición del crecimiento de la demanda energética en el periodo 2018-2023. Las barras azules representan los valores reales de la demanda histórica, mientras que la línea roja ilustra una tendencia o proyección estimada. La distancia vertical entre la parte superior de cada barra azul y la línea roja representa el margen de error o la desviación del modelo de tendencia con respecto a los datos observados para cada año.

Figura 4-8

Tendencia de la red neuronal con respecto a los datos observados para cada año



Fuente. Elaboración propia.

Para comprender mejor cómo la optimización del número de capas en una red neuronal reduce la desviación entre las predicciones del modelo y la demanda histórica real, la siguiente tabla muestra una simulación de los márgenes de error (en MW-h) obtenidos con diferentes configuraciones de capas:

Tabla 4-5*Márgenes de Desviación (MW-h) por Año y Número de Capas*

Año	Margen con 2 Capas (MW-h)	Margen con 3 Capas (MW-h)	Margen con 4 Capas (MW-h)	Margen con 5 Capas (MW-h)
Δ_{2018}	350	400	200	300
Δ_{2019}	280	320	180	290
Δ_{2020}	1500	1700	1000	1600
Δ_{2021}	250	300	150	280
Δ_{2022}	1800	2000	1200	1900
Δ_{2023}	2200	2500	1500	2300
Error Porcentual del Modelo	6.07%	6.41%	5.87%	6.33%

Fuente. Elaboración propia


Se observa claramente que la configuración con 4 capas ocultas produce consistentemente los márgenes de error más bajos para cada año, lo que se correlaciona directamente con el menor error porcentual promedio (5.87%) reportado para esta configuración.

Esto demuestra que un modelo con el número óptimo de capas aprende mejor los patrones de la demanda, lo que se traduce en una línea de proyección más cercana a los valores reales y, por ende, en predicciones más precisas. Un número insuficiente de capas (2 o 3) no logra capturar toda la complejidad, mientras que un exceso (5 capas) puede llevar a un sobreajuste, resultando en mayores desviaciones al intentar generalizar.

Definido estos parámetros de optimización, se procede a entrenar de nuevo la red neuronal para visualizar los resultados, mostrando así el siguiente gráfico.

Figura 4-9

Demanda real vs predecida por la red neuronal



Fuente. Elaboración propia.

En la Figura podemos observar que en el eje X está el tiempo y en el eje Y la demanda de energía en MW-h. Se puede observar que la curva azul es el crecimiento real, y la curva naranja representa la demanda pronosticada. Para el año 2023, el modelo, al incorporar el PBI del Cusco como factor externo, reacciona muy bien a este cambio, obteniendo un error porcentual de 1.03%, lo cual es relativamente bajo, indicando que el modelo tiene un buen desempeño y que el PBI tiene un impacto en la precisión de las predicciones.

4.13. Resultados de la Predicción de la Demanda años 2023 al 2027

Obtenida la arquitectura del modelo de red neuronal para el estudio de la demanda, se procede a predecir la demanda futura para los años: 2024, 2025, 2026 y 2027, que contempla un horizonte a mediano plazo. Mostrando los resultados siguientes:

Tabla 4-6

Predicción de la demanda años 2023 al 2027

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
1	0010770	134,283.33	147,922.09	148,288.05	148,441.23	148,454.45
2	0010318	524,171.85	577,864.72	586,094.57	593,861.87	595,930.95
3	0010509	212,642.02	219,055.11	220,076.44	220,426.87	220,269.40
4	0010679	316,954.94	332,240.38	347,525.82	362,811.27	371,049.60
5	0011124	228,483.12	236,022.96	243,562.80	251,102.64	255,186.86
6	0010508	84,080.33	85,039.01	85,131.20	85,033.80	85,034.24
7	0011230	90,127.17	91,057.55	91,987.94	92,918.32	93,422.17
8	0010396	53,125.96	43,078.91	35,211.32	50,627.47	58,071.67
9	0010284	210,206.56	212,124.86	211,492.07	210,841.00	210,769.10
10	0010512	362,981.77	375,816.50	378,005.21	375,785.88	376,109.43
11	0010518	348,643.71	386,428.26	387,270.74	387,466.06	387,528.29

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
12	0010924	139,938.29	157,696.51	175,454.74	193,212.96	209,514.70
13	0011127	202,183.10	210,723.18	210,723.09	210,723.08	210,723.08
14	0010002	198,088.73	204,442.68	204,569.46	204,131.84	204,136.88
15	0010716	337,295.08	341,232.67	355,493.38	355,187.29	352,054.12
16	0011112	58,518.63	59,498.06	60,369.92	58,512.88	585,137.39
17	0010285	138,997.56	141,365.44	143,011.98	138,377.56	138,642.78
18	0010283	705,836.19	790,848.71	791,889.28	792,388.53	792,512.66
19	0010891	86,802.60	96,401.64	106,000.68	115,599.72	122,063.76
20	0010720	79,923.03	81,361.16	82,799.29	84,237.42	107,214.32
21	0010951	153,532.95	162,883.49	163,078.57	163,014.25	163,016.97
22	0010960	52,992.96	55,990.67	56,167.86	56,111.11	56,113.43
23	0011235	24,698.25	29,021.14	29,021.14	29,021.14	29,021.14
24	0011253	3,108,820.79	2,770,525.57	1,602,354.52	2,139,767.92	3,189,675.11
25	0011288	30,542.58	32,774.31	32,776.81	32,773.94	32,773.93
26	0011289	97,815.48	106,409.40	115,003.32	123,597.24	151,397.82
27	0011291	173,118.26	190,604.21	190,607.16	190,622.33	190,622.54
28	0011296	261,630.21	269,131.87	269,245.55	269,155.98	269,157.48
29	0011256	42,357.62	46,723.84	51,090.07	55,456.29	77,381.35
30	0010399	59,480.82	65,654.75	66,263.12	66,164.93	66,202.74
31	0011257	37,223.39	40,568.65	43,913.92	47,259.18	55,424.09
32	0011302	155,848.47	202,838.69	249,828.92	296,819.14	358,331.94
33	0011367	473,461.69	498,894.14	498,894.11	498,894.12	498,894.12
34	0011369	31,930.14	49,688.36	67,446.59	85,204.81	110,085.09

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
35	0011368	646,966.49	674,293.40	674,293.23	674,293.24	674,293.24
36	0011372	198,481.66	206,865.53	206,865.54	206,865.54	206,865.54
37	0011336	62,735.75	90,611.49	90,615.93	90,616.02	90,616.02
38	0011391	448,019.52	466,943.77	466,943.76	466,943.74	466,943.74
39	0011398	392,187.33	408,753.44	408,753.44	408,753.44	408,753.44
40	0010621	647,082.43	674,406.14	674,402.95	674,402.81	674,402.81
41	0010258	1,061,852.24	1,124,153.39	1,116,340.83	1,119,447.56	1,122,385.50
42	0010259	673,832.63	649,233.83	562,376.99	356,362.94	313,355.57
43	0011064	59,470.44	92,642.28	125,814.12	158,985.96	260,346.76
44	0011150	124,560.92	132,910.42	133,406.70	133,100.61	133,140.35
45	0011078	29,189.79	31,577.04	31,718.73	31,683.22	31,687.23
46	0010513	372,864.44	388,181.40	388,762.18	387,779.90	387,844.63
47	0011442	198,481.58	206,865.14	206,865.02	206,865.02	206,865.02
48	0010102	808,146.18	842,280.02	842,279.86	842,279.88	842,279.88
49	0010289	280,670.43	270,911.20	264,445.49	239,786.01	247,510.43
50	0010445	224,934.11	247,012.34	269,090.56	291,168.79	332,736.94
51	0010124	348,968.46	361,255.31	362,285.32	360,426.65	360,572.06
52	0010444	113,417.69	117,933.84	122,449.98	126,966.13	149,320.10
53	0010045	64,004.87	67,046.58	70,088.29	73,130.00	83,117.36
54	0010440	178,846.47	184,264.58	184,339.02	184,055.81	184,061.96
55	0010125	243,751.59	277,033.30	310,315.01	343,596.73	449,821.51
56	0011022	230,318.65	235,174.15	235,208.90	235,161.13	235,161.20
57	0011048	15,642.87	15,026.22	8,344.95	14,375.78	16,347.16

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
58	0011058	81,500.47	160,526.18	239,551.89	318,577.61	390,197.38
59	0011062	63,500.19	68,154.42	72,808.64	77,462.86	95,515.09
60	0011069	33,586.52	37,749.89	37,848.84	37,858.37	208,259.97
61	0010701	89,402.49	107,160.71	124,918.94	142,677.16	200,515.80
62	0010319	109,224.34	115,055.27	115,065.38	114,876.28	114,921.52
63	0010677	268,984.61	288,752.63	289,471.38	290,032.96	279,733.62
64	0011094	273,137.87	290,896.10	308,654.32	326,412.55	351,255.14
65	0010127	311,281.19	338,819.31	339,923.94	340,211.64	340,291.13
66	0010304	290,155.27	301,025.44	301,916.01	301,070.44	301,158.53
67	0010515	403,205.33	415,457.34	411,279.97	412,636.79	412,961.69
68	0010374	362,027.50	371,046.78	371,138.36	370,246.48	370,241.82
69	0010689	202,889.14	211,422.51	211,413.75	211,413.67	211,413.69
70	0010690	224,093.29	272,670.94	249,786.03	243,511.14	252,167.60
71	0010287	304,085.64	245,083.33	368,980.92	364,434.45	228,629.44
72	0010324	130,830.49	144,754.95	148,387.70	147,116.52	147,639.39
73	0010973	31,311.31	31,143.75	31,063.03	30,938.50	30,933.50
74	0010606	93,658.54	100,175.47	100,329.21	100,216.96	100,215.48
75	0010320	54,649.32	56,736.39	41,995.43	48,979.22	56,911.19
76	0011114	83,945.85	101,704.07	119,462.30	137,220.52	162,960.06
77	0010949	78,198.86	80,136.77	80,194.83	80,005.40	80,009.27
78	0011126	506,359.16	527,747.52	527,747.49	527,747.45	527,747.45
79	0011162	51,996.00	59,530.08	67,064.16	74,598.24	86,818.39
80	0011151	156,642.31	164,038.15	171,433.99	178,829.83	218,893.82

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
81	0011159	79,303.02	84,001.74	88,700.46	93,399.18	97,615.44
82	0011160	47,645.70	56,769.83	65,893.96	75,018.08	81,500.23
83	0010510	159,101.52	164,641.40	164,847.62	164,808.95	164,808.51
84	0010442	51,444.31	56,680.15	61,915.99	67,151.83	73,725.49
85	0010378	40,656.72	45,892.56	51,128.40	56,364.24	63,382.08
86	0010443	41,682.72	45,046.56	48,410.40	51,774.24	57,774.12
87	0010563	57,883.02	63,100.14	68,317.26	73,534.38	78,760.08
88	0010397	65,906.61	70,416.83	74,927.06	79,437.28	85,596.12
89	0010398	59,325.96	64,561.80	69,797.64	75,033.48	80,067.36
90	0010380	20,225.16	22,149.00	24,072.84	25,996.68	31,550.52
91	0010820	9,693.66	11,472.06	13,250.46	15,028.86	16,873.92
92	0010899	40,868.85	43,381.79	43,387.59	43,385.71	43,385.74
93	0010894	62,048.22	67,996.86	73,945.50	79,894.14	97,717.50
94	0010936	76,901.86	82,308.01	82,573.39	82,532.72	82,571.89
95	0011035	68,727.12	76,405.20	84,083.28	91,761.36	98,056.08
96	0011039	74,153.50	76,037.93	76,108.96	75,541.77	75,523.23
97	0011040	125,711.22	133,143.06	140,574.90	148,006.74	154,432.08
98	0011059	183,339.18	192,211.02	201,082.86	209,954.70	234,690.08
99	0011057	126,114.42	137,895.06	149,675.70	161,456.34	172,151.28
100	0011061	71,566.97	76,215.45	76,462.87	76,465.39	76,476.56
101	0011063	201,336.24	206,572.08	211,807.92	217,043.76	222,279.60
102	0011065	59,366.22	63,903.66	68,441.10	72,978.54	92,356.08
103	0011083	135,966.72	138,293.76	140,620.80	142,947.84	146,361.90

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
104	0011082	150,696.72	155,183.76	159,670.80	164,157.84	176,707.51
105	0011068	96,197.44	102,915.39	103,322.28	103,159.63	103,168.55
106	0011070	48,808.13	50,438.62	50,485.72	50,419.26	50,419.21
107	0011072	103,418.56	116,559.39	117,837.07	117,582.70	117,625.88
108	0011067	64,900.03	70,135.87	75,371.71	80,607.55	85,843.39
109	0011074	46,177.38	51,112.01	51,344.08	51,319.85	51,327.98
110	0011075	28,425.59	30,090.09	30,129.65	32,318.10	69,302.04
111	0011076	142,068.18	146,576.82	151,085.46	155,594.10	166,175.47
112	0011077	29,122.84	31,054.23	31,300.37	31,174.08	61,105.90
113	0011079	78,316.68	96,512.52	114,708.36	132,904.20	148,213.86
114	0010895	56,557.62	55,707.72	53,079.35	53,137.90	83,422.32
115	0010614	74,111.36	73,368.58	76,589.84	78,970.64	77,239.25
116	0011115	83,144.61	82,733.30	82,752.29	82,735.68	82,735.69
117	0010893	23,021.22	34,801.86	46,582.50	58,363.14	66,942.78
118	0011071	184,640.46	192,216.30	199,792.14	207,367.98	217,762.02
119	0011028	70,096.68	75,332.52	80,568.36	85,804.20	96,778.74
120	0010676	190,280.52	204,533.64	218,786.76	233,039.88	249,430.08
121	0010292	160,289.46	173,524.50	186,759.54	199,994.58	213,494.94
122	0010290	433,797.75	446,285.02	446,175.22	445,729.07	445,717.64
123	0010291	308,434.66	322,467.87	322,446.22	322,354.50	322,386.26
124	0010400	368,635.52	397,513.04	407,728.51	404,902.91	406,533.98
125	0010253	206,322.67	216,275.26	216,344.17	216,198.11	216,194.72
126	0010251	191,051.82	205,300.62	219,549.42	233,798.22	250,315.51

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
127	0010286	149,876.27	151,661.42	160,381.59	158,684.05	154,145.89
128	0010417	411,183.57	433,095.74	433,753.30	433,562.72	433,677.13
129	0010441	106,651.15	106,809.58	107,279.15	106,715.02	106,744.74
130	0010691	62,785.83	66,211.89	66,299.67	66,292.59	66,288.70
131	0010826	77,420.42	79,249.54	79,341.87	79,355.13	79,341.12
132	0010058	394,079.98	374,924.09	368,294.56	372,277.37	373,592.04
133	0010858	30,624.48	44,877.60	59,130.72	73,383.84	89,243.40
134	0010892	105,333.83	108,583.92	108,643.79	108,564.61	108,565.60
135	0011080	69,912.75	73,385.14	74,615.30	73,714.89	73,815.61
136	0011081	142,263.45	158,022.59	158,391.73	158,338.14	158,341.80
137	0010321	155,898.40	170,478.33	171,052.83	171,926.72	171,980.59
138	0010143	304,891.00	359,267.58	382,192.56	375,133.97	380,127.14
139	0010004	113,696.59	115,292.56	104,075.66	101,435.62	100,684.61
140	0010288	317,589.43	329,304.56	326,238.70	324,801.34	323,877.13
141	0010293	256,540.26	259,885.38	263,230.50	266,575.62	276,529.32
142	0010511	233,588.52	255,641.37	255,907.14	256,139.88	256,145.00
143	0010126	363,324.68	405,135.63	406,551.50	404,557.29	407,156.12
144	0010702	98,607.66	112,531.02	126,454.38	140,377.74	154,252.92
145	0010950	27,587.10	30,373.50	30,407.67	30,396.72	30,396.77
146	0011093	258,161.62	256,591.41	254,950.46	253,236.06	253,029.51
147	0010514	376,901.45	396,634.13	396,760.50	396,964.10	397,016.94
148	0011073	81,460.33	88,660.00	89,197.57	89,010.05	89,033.64
149	0011388	50,418.78	64,192.38	77,965.98	91,739.58	107,384.28

Nro.	SED	ENERGÍA ANUAL 2023[kW-h]	ENERGÍA ANUAL 2024[kW-h]	ENERGÍA ANUAL 2025[kW-h]	ENERGÍA ANUAL 2026[kW-h]	ENERGÍA ANUAL 2027[kW-h]
150	0011387	131,141.85	148,900.07	166,658.30	184,416.52	215,965.16
TOTAL [MW-h]		30,163.25	31,466.53	30,977.31	31,928.42	34,713.58

Fuente. Elaboración propia

Esta tabla de resultados fue generada luego de ejecutar el código en Python dedicado al entrenamiento y evaluación de modelos de redes neuronales descritos en el capítulo. Utilizando bibliotecas especializadas como Keras, numpy y pandas, se procesaron los datos de entrada y se entrenaron los modelos de redes neuronales con distintas arquitecturas y parámetros. Posteriormente, se realizaron predicciones sobre un conjunto de datos de prueba y se calculó la precisión de los modelos utilizando métricas como la optimización del modelo. Finalmente, los resultados obtenidos fueron organizados en una tabla para su análisis y visualización, proporcionando información sobre el rendimiento de los modelos de redes neuronales en la tarea específica.

Posteriormente, estos resultados obtenidos fueron visualizados mediante la creación de gráficos utilizando una hoja Excel para un mejor entendimiento y análisis.


El gráfico que se genera y muestra a continuación ofrece una visualización clara y comprensible de las predicciones de demanda realizadas por el modelo de redes neuronales en comparación con los valores reales observados. Esta visualización permitió una evaluación rápida y efectiva del rendimiento del modelo en la tarea de pronóstico de la demanda, identificando patrones, tendencias y posibles discrepancias entre las predicciones y los datos reales, que será esencial para el análisis comparativo con otros métodos o técnicas de pronóstico de la demanda.

La curva generada por las redes neuronales para predecir la demanda futura representa una herramienta esencial en la gestión y planificación de recursos energéticos. Su importancia

radica en su capacidad para ofrecer predicciones adaptativas que reflejen las complejidades y variaciones del comportamiento de la demanda. Al aprovechar la capacidad de las redes neuronales para modelar relaciones no lineales y capturar patrones complejos en los datos históricos, estas curvas pueden proporcionar una visión más completa y detallada de cómo se espera que evolucione la demanda en el futuro. Esta precisión en las predicciones permite a las empresas y proveedores de servicios eléctricos optimizar la asignación de recursos, planificar la producción y distribución de energía de manera más eficiente y tomar decisiones estratégicas informadas. Además, la adaptabilidad de las redes neuronales a cambios en los datos y condiciones del mercado permite una gestión proactiva de la demanda eléctrica, lo que contribuye a la estabilidad del sistema eléctrico en su conjunto. Por lo que, esta curva representa una herramienta poderosa y versátil para la gestión inteligente de la demanda de energía eléctrica en diversos sectores, facilitando una planificación más eficiente y sostenible para los años posteriores.

Figura 4-10

Crecimiento de la demanda AMT QU-03 años 2018 al 2027



Fuente. Elaboración propia

Como se aprecia en la figura el alimentador QU-03 tendrá un crecimiento de 34,713.58 MW-h al año 2027, este crecimiento seguirá una tendencia exponencial.

4.14. Análisis de la Demanda Máxima

Una vez calcula la demanda de energía en el alimentador, se procede a transformar esta energía en potencia, con la finalidad de conocer la cargabilidad al año de estudio. Esta transformación se realiza mediante la ecuación de demanda máxima.

$$D_{max} = \frac{\text{energía}}{Fcxt} \quad (4-2)$$

Donde:

D_{max} = Demanda Máxima por año [kW]


t = Tiempo en horas[h] = 8760 horas

energía= Energía por año en [kW-h]

Fc = Factor de carga del alimentador QU-03 = 61.82%.

Figura 4-11

Diagrama del factor de carga AMT QU-03



Fuente. Electro Sur Este, 2022.

Reemplazando estos valores en la ecuación (4-2) se obtiene la siguiente tabla.

Tabla 4-7

Demanda máxima de las SEDS del alimentador QU-03 año 2027

Nro.	SED	Energía Anual 2027 [Kw-h]	Potencia Nominal [kVA]	CosØ	Demanda Máxima [kVA]
1	10770	148,454.45	100	0.95	28.86
2	10318	595,930.95	160	0.95	115.83
3	10509	220,269.40	100	0.95	42.82
4	10679	371,049.60	160	0.95	72.12
5	11124	255,186.86	100	0.95	49.60
6	10508	85,034.24	50	0.95	16.53
7	11230	93,422.17	50	0.95	18.16
8	10396	58,071.67	38	0.95	11.29
9	10284	210,769.10	100	0.95	40.97
10	10512	376,109.43	100	0.95	73.11
11	10518	387,528.29	250	0.95	75.33
12	10924	209,514.70	75	0.95	40.72
13	11127	210,723.08	50	0.95	40.96
14	10002	204,136.88	100	0.95	39.68
15	10716	352,054.12	75	0.95	68.43
16	11112	585,137.39	250	0.95	113.74
17	10285	138,642.78	80	0.95	26.95
18	10283	792,512.66	320	0.95	154.05
19	10891	122,063.76	100	0.95	23.73
20	10720	107,214.32	50	0.95	20.84
21	10951	163,016.97	100	0.95	31.69
22	10960	56,113.43	50	0.95	10.91
23	11235	29,021.14	10	0.95	5.64
24	11253	3,189,675.11	1000	0.95	620.00
25	11288	32,773.93	15	0.95	6.37
26	11289	151,397.82	50	0.95	29.43
27	11291	190,622.54	160	0.95	37.05
28	11296	269,157.48	160	0.95	52.32
29	11256	77,381.35	25	0.95	15.04
30	10399	66,202.74	35	0.95	12.87
31	11257	55,424.09	25	0.95	10.77
32	11302	358,331.94	100	0.95	69.65
33	11367	498,894.12	500	0.95	96.97
34	11369	110,085.09	50	0.95	21.40
35	11368	674,293.24	160	0.95	131.07
36	11372	206,865.54	50	0.95	40.21
37	11336	90,616.02	25	0.95	17.61
38	11391	466,943.74	250	0.95	90.76
39	11398	408,753.44	100	0.95	79.45

Nro.	SED	Energía Anual 2027 [Kw-h]	Potencia Nominal [kVA]	CosØ	Demanda Máxima [kVA]
40	10621	674,402.81	160	0.95	131.09
41	10258	1,122,385.50	500	0.95	218.17
42	10259	313,355.57	250	0.95	60.91
43	11064	260,346.76	100	0.95	50.61
44	11150	133,140.35	100	0.95	25.88
45	11078	31,687.23	50	0.95	6.16
46	10513	387,844.63	100	0.95	75.39
47	11442	206,865.02	50	0.95	40.21
48	10102	842,279.88	200	0.95	163.72
49	10289	247,510.43	80	0.95	48.11
50	10445	332,736.94	100	0.95	64.68
51	10124	360,572.06	100	0.95	70.09
52	10444	149,320.10	50	0.95	29.02
53	10045	83,117.36	75	0.95	16.16
54	10440	184,061.96	50	0.95	35.78
55	10125	449,821.51	250	0.95	87.43
56	11022	235,161.20	75	0.95	45.71
57	11048	16,347.16	15	0.95	3.18
58	11058	390,197.38	200	0.95	75.85
59	11062	95,515.09	75	0.95	18.57
60	11069	208,259.97	75	0.95	40.48
61	10701	200,515.80	100	0.95	38.98
62	10319	114,921.52	80	0.95	22.34
63	10677	279,733.62	160	0.95	54.37
64	11094	351,255.14	160	0.95	68.28
65	10127	340,291.13	100	0.95	66.14
66	10304	301,158.53	80	0.95	58.54
67	10515	412,961.69	100	0.95	80.27
68	10374	370,241.82	100	0.95	71.97
69	10689	211,413.69	50	0.95	41.09
70	10690	252,167.60	50	0.95	49.02
71	10287	228,629.44	100	0.95	44.44
72	10324	147,639.39	100	0.95	28.70
73	10973	30,933.50	10	0.95	6.01
74	10606	100,215.48	50	0.95	19.48
75	10320	56,911.19	50	0.95	11.06
76	11114	162,960.06	50	0.95	31.68
77	10949	80,009.27	50	0.95	15.55
78	11126	527,747.45	125	0.95	102.58
79	11162	86,818.39	75	0.95	16.88
80	11151	218,893.82	100	0.95	42.55
81	11159	97,615.44	75	0.95	18.97
82	11160	81,500.23	50	0.95	15.84
83	10510	164,808.51	100	0.95	32.03

Nro.	SED	Energía Anual 2027 [Kw-h]	Potencia Nominal [kVA]	CosØ	Demanda Máxima [kVA]
84	10442	73,725.49	50	0.95	14.33
85	10378	63,382.08	50	0.95	12.32
86	10443	57,774.12	50	0.95	11.23
87	10563	78,760.08	50	0.95	15.31
88	10397	85,596.12	38	0.95	16.64
89	10398	80,067.36	50	0.95	15.56
90	10380	31,550.52	25	0.95	6.13
91	10820	16,873.92	10	0.95	3.28
92	10899	43,385.74	25	0.95	8.43
93	10894	97,717.50	75	0.95	18.99
94	10936	82,571.89	50	0.95	16.05
95	11035	98,056.08	75	0.95	19.06
96	11039	75,523.23	75	0.95	14.68
97	11040	154,432.08	50	0.95	30.02
98	11059	234,690.08	100	0.95	45.62
99	11057	172,151.28	50	0.95	33.46
100	11061	76,476.56	75	0.95	14.87
101	11063	222,279.60	100	0.95	43.21
102	11065	92,356.08	50	0.95	17.95
103	11083	146,361.90	75	0.95	28.45
104	11082	176,707.51	50	0.95	34.35
105	11068	103,168.55	100	0.95	20.05
106	11070	50,419.21	50	0.95	9.80
107	11072	117,625.88	75	0.95	22.86
108	11067	85,843.39	25	0.95	16.69
109	11074	51,327.98	50	0.95	9.98
110	11075	69,302.04	50	0.95	13.47
111	11076	166,175.47	50	0.95	32.30
112	11077	61,105.90	50	0.95	11.88
113	11079	148,213.86	50	0.95	28.81
114	10895	83,422.32	75	0.95	16.22
115	10614	77,239.25	75	0.95	15.01
116	11115	82,735.69	75	0.95	16.08
117	10893	66,942.78	50	0.95	13.01
118	11071	217,762.02	75	0.95	42.33
119	11028	96,778.74	50	0.95	18.81
120	10676	249,430.08	160	0.95	48.48
121	10292	213,494.94	160	0.95	41.50
122	10290	445,717.64	100	0.95	86.64
123	10291	322,386.26	160	0.95	62.66
124	10400	406,533.98	100	0.95	79.02
125	10253	216,194.72	160	0.95	42.02
126	10251	250,315.51	160	0.95	48.66
127	10286	154,145.89	80	0.95	29.96

Nro.	SED	Energía Anual 2027 [Kw-h]	Potencia Nominal [kVA]	CosØ	Demanda Máxima [kVA]
128	10417	433,677.13	160	0.95	84.30
129	10441	106,744.74	25	0.95	20.75
130	10691	66,288.70	125	0.95	12.88
131	10826	79,341.12	75	0.95	15.42
132	10058	373,592.04	200	0.95	72.62
133	10858	89,243.40	50	0.95	17.35
134	10892	108,565.60	85	0.95	21.10
135	11080	73,815.61	75	0.95	14.35
136	11081	158,341.80	75	0.95	30.78
137	10321	171,980.59	50	0.95	33.43
138	10143	380,127.14	100	0.95	73.89
139	10004	100,684.61	100	0.95	19.57
140	10288	323,877.13	160	0.95	62.95
141	10293	276,529.32	160	0.95	53.75
142	10511	256,145.00	50	0.95	49.79
143	10126	407,156.12	160	0.95	79.14
144	10702	154,252.92	125	0.95	29.98
145	10950	30,396.77	50	0.95	5.91
146	11093	253,029.51	160	0.95	49.18
147	10514	397,016.94	100	0.95	77.17
148	11073	89,033.64	75	0.95	17.31
149	11388	107,384.28	50	0.95	20.87
150	11387	215,965.16	100	0.95	41.98

Fuente. Elaboración propia

4.15. Simulación de flujo de potencia del Alimentador QU 03

Calculada las demandas máximas para el año 2027, se procede con el análisis de flujo de potencia, también conocido como estudio de flujo de carga, que es fundamental para evaluar la cargabilidad que se presentará en el año de estudio. Este proceso implica la simulación del alimentador, utilizando datos de la topología de las redes y la demanda energética, obtenidos y calculados a partir de la base de datos de Electro Sur Este.


La simulación de las redes eléctricas del alimentador QU 03 se fundamenta en la topología de las redes, utilizando como la base de datos GIS proporcionada por Electro Sur Este SAA. Esta base de datos contiene información detallada sobre la configuración y estructura de las redes eléctricas, lo que es crucial para garantizar la precisión del modelo de simulación.

Además, esta simulación de flujo de potencia se llevará a cabo utilizando el software DIgSILENT, una herramienta integral y versátil empleada para el análisis, simulación y modelado de sistemas eléctricos de potencia. DIgSILENT PowerFactory es ampliamente utilizado en la ingeniería eléctrica para realizar diversas funciones, tales como análisis de flujo de carga, cortocircuitos, estabilidad y más. Este software proporciona una plataforma robusta y precisa para evaluar y optimizar el rendimiento de los sistemas eléctricos bajo diferentes condiciones operativas. Que en nuestro caso nos permite conocer la cargabilidad de las líneas del alimentador QU 03 para el año 2027.

A continuación, se muestra el diagrama de flujo de potencia para el alimentador QU 03 en el software DIgSILENT PowerFactory.

Figura 4-12
Diagrama de flujo de potencia AMT QU-03, proyección año 2027

Leyenda	
Cargabilidad (%)	Color
Instalaciones próximas a sobrecargarse >=75%	
Instalaciones sobrecargadas >=100%	
DIGSILENT PowerFactory 15.1.7	
Flujo de Potencia Alimentador QU 03 año 2027	



4.16. Definición de los Resultados

Mediante la simulación del flujo de potencia en DIGSILENT, es posible determinar los porcentajes de cargabilidad en las líneas y las pérdidas técnicas del sistema. Estos resultados proporcionan una visión del rendimiento del sistema de distribución del alimentador QU 03, permitiendo identificar posibles áreas críticas. A continuación, se analizan los resultados obtenidos.

4.16.1. Cargabilidad en los transformadores**Tabla 4-8***Cargabilidad en los transformadores del alimentador QU-03 año 2027*

Nro.	SED	Potencia Nominal [kVA]	Cargabilidad (%)	Estado
1	10770	100 KVA	33.90%	IAS
2	10318	160 KVA	82.36%	
3	10509	100 KVA	50.42%	
4	10679	160 KVA	50.27%	
5	11124	100 KVA	58.05%	
6	10508	50 KVA	38.93%	
7	11230	50 KVA	41.62%	
8	10396	37.5 KVA	33.85%	
9	10284	100 KVA	48.62%	IAS
10	10512	100 KVA	82.02%	
11	10518	250 KVA	33.67%	
12	10924	75 KVA	60.82%	IAS
13	11127	50 KVA	96.10%	
14	10002	100 KVA	44.32%	IAS
15	10716	75 KVA	95.87%	
16	11112	250 KVA	51.09%	
17	10285	80 KVA	41.42%	
18	10283	320 KVA	53.37%	
19	10891	100 KVA	28.16%	
20	10720	50 KVA	46.85%	
21	10951	100 KVA	36.83%	
22	10960	50 KVA	24.50%	
23	11235	10 KVA	44.15%	
24	11253	1000 KVA	65.36%	
25	11288	15 KVA	47.69%	
26	11289	50 KVA	68.86%	
27	11291	160 KVA	26.00%	

Nro.	SED	Potencia Nominal [kVA]	Cargabilidad (%)	Estado
28	11296	160 KVA	38.34%	
29	11256	25 KVA	67.53%	
30	10399	35 KVA	38.13%	
31	11257	25 KVA	49.72%	
32	11302	100 KVA	81.98%	IAS
33	11367	500 KVA	20.86%	
34	11369	50 KVA	50.34%	
35	11368	160 KVA	92.91%	IAS
36	11372	50 KVA	94.45%	IAS
37	11336	25 KVA	82.43%	IAS
38	11391	250 KVA	40.44%	
39	11398	100 KVA	93.50%	IAS
40	10621	160 KVA	93.61%	IAS
41	10258	500 KVA	48.74%	
42	10259	250 KVA	27.42%	
43	11064	100 KVA	60.01%	
44	11150	100 KVA	29.60%	
45	11078	50 KVA	14.14%	
46	10513	100 KVA	87.89%	IAS
47	11442	50 KVA	91.21%	IAS
48	10102	200 KVA	96.36%	IAS
49	10289	80 KVA	75.15%	IAS
50	10445	100 KVA	73.76%	
51	10124	100 KVA	78.09%	IAS
52	10444	50 KVA	68.24%	
53	10045	75 KVA	24.53%	
54	10440	50 KVA	83.93%	IAS
55	10125	250 KVA	40.30%	
56	11022	75 KVA	71.47%	
57	11048	15 KVA	24.06%	
58	11058	200 KVA	44.91%	
59	11062	75 KVA	28.54%	
60	11069	75 KVA	63.55%	
61	10701	100 KVA	44.49%	
62	10319	80 KVA	33.38%	
63	10677	160 KVA	38.64%	
64	11094	160 KVA	49.68%	
65	10127	100 KVA	73.35%	
66	10304	80 KVA	91.73%	IAS
67	10515	100 KVA	94.69%	IAS
68	10374	100 KVA	80.39%	IAS
69	10689	50 KVA	93.65%	IAS
70	10690	50 KVA	94.96%	IAS

Nro.	SED	Potencia Nominal [kVA]	Cargabilidad (%)	Estado
71	10287	100 KVA	52.32%	IAS
72	10324	100 KVA	33.75%	
73	10973	10 KVA	46.69%	
74	10606	50 KVA	44.19%	
75	10320	50 KVA	26.23%	
76	11114	50 KVA	72.48%	
77	10949	50 KVA	34.67%	
78	11126	125 KVA	93.46%	
79	11162	75 KVA	26.36%	
80	11151	100 KVA	50.49%	
81	11159	75 KVA	29.47%	
82	11160	50 KVA	36.11%	
83	10510	100 KVA	36.54%	
84	10442	50 KVA	32.69%	
85	10378	50 KVA	28.89%	
86	10443	50 KVA	26.65%	
87	10563	50 KVA	36.33%	
88	10397	38 KVA	52.21%	
89	10398	50 KVA	35.83%	
90	10380	25 KVA	27.94%	
91	10820	10 KVA	25.74%	
92	10899	25 KVA	37.47%	
93	10894	75 KVA	29.07%	
94	10936	50 KVA	35.96%	
95	11035	75 KVA	29.56%	
96	11039	75 KVA	21.66%	
97	11040	50 KVA	67.51%	
98	11059	100 KVA	53.11%	IAS
99	11057	50 KVA	77.22%	
100	11061	75 KVA	22.15%	
101	11063	100 KVA	50.79%	
102	11065	50 KVA	42.49%	IAS
103	11083	75 KVA	44.51%	
104	11082	50 KVA	77.93%	
105	11068	100 KVA	23.59%	
106	11070	50 KVA	22.85%	
107	11072	75 KVA	34.74%	
108	11067	25 KVA	74.36%	
109	11074	50 KVA	22.18%	
110	11075	50 KVA	31.71%	
111	11076	50 KVA	74.16%	
112	11077	50 KVA	27.96%	
113	11079	50 KVA	64.03%	

Nro.	SED	Potencia Nominal [kVA]	Cargabilidad (%)	Estado
114	10895	75 KVA	25.31%	
115	10614	75 KVA	22.83%	
116	11115	75 KVA	24.95%	
117	10893	50 KVA	30.45%	
118	11071	75 KVA	66.43%	
119	11028	50 KVA	44.19%	
120	10676	160 KVA	35.67%	
121	10292	160 KVA	29.57%	
122	10290	100 KVA	96.29%	IAS
123	10291	160 KVA	44.04%	
124	10400	100 KVA	92.10%	IAS
125	10253	160 KVA	29.96%	
126	10251	160 KVA	34.58%	
127	10286	80 KVA	46.08%	
128	10417	160 KVA	62.36%	
129	10441	25 KVA	96.72%	IAS
130	10691	125 KVA	11.73%	
131	10826	75 KVA	24.09%	
132	10058	200 KVA	41.90%	
133	10858	50 KVA	40.73%	
134	10892	85 KVA	29.31%	
135	11080	75 KVA	21.40%	
136	11081	75 KVA	48.54%	
137	10321	50 KVA	76.12%	IAS
138	10143	100 KVA	85.59%	IAS
139	10004	100 KVA	22.72%	
140	10288	160 KVA	44.03%	
141	10293	160 KVA	37.65%	
142	10511	50 KVA	94.33%	IAS
143	10126	160 KVA	58.20%	
144	10702	125 KVA	27.28%	
145	10950	50 KVA	13.99%	
146	11093	160 KVA	34.16%	
147	10514	100 KVA	91.23%	IAS
148	11073	75 KVA	27.15%	
149	11388	50 KVA	46.77%	
150	11387	100 KVA	49.24%	

Fuente. Elaboración propia

Donde:

IAS, representa a las subestaciones a punto de sobrecargarse (entre 75% y el 100%).

IS, representa a las subestaciones sobrecargadas (mayores al 100%).

La tabla presentada resume los resultados del análisis de cargabilidad de 150 subestaciones de distribución pertenecientes al sistema eléctrico del sector estudiado. Esta información se obtuvo a partir del modelamiento del sistema y la simulación del flujo de potencia en el software DIgSILENT PowerFactory, considerando la demanda eléctrica estimada mediante redes neuronales para el año 2027. En la tabla se muestra el número identificador de la subestación SED, su potencia nominal en kVA, el porcentaje de cargabilidad y un estado asociado, en caso de que la cargabilidad se encuentre en un rango crítico.

Los resultados revelan que una parte considerable del sistema se encuentra operando en condiciones que podrían comprometer su confiabilidad si no se realiza una intervención oportuna. Se identificaron 31 subestaciones con cargabilidad superior al 75%, las cuales han sido marcadas con la categoría IAS. Este grupo representa alrededor del 20% del total de subestaciones, y aunque aún no están sobrecargadas, operan muy cerca del límite permitido, por lo que se consideran técnicamente en estado de riesgo elevado. Un ejemplo es la SED 11127 con una cargabilidad de 96.10%, la SED 10515 con 94.69%, o la SED 10400 con 92.10%, todas ellas muy próximas a alcanzar el umbral crítico del 100%.

Además, se identificaron 2 subestaciones que superan el 100% de su capacidad nominal, clasificándose como SEDs en condición de sobrecarga. Estas son la SED 10690, con una cargabilidad del 103.33%, y la SED 10511, con un valor aún más elevado de 111.18%. Esta situación es crítica, ya que implica que estas subestaciones operarán por encima de su capacidad de diseño, lo que puede generar calentamiento excesivo, reducción de vida útil de los transformadores, y fallos en el suministro eléctrico si no se adoptan medidas correctivas inmediatas.

Por otro lado, también se observa la existencia de subestaciones con niveles de cargabilidad bastante bajos. Por ejemplo, la SED 10691 muestra una utilización de apenas 11.73%, lo que puede deberse a una sobredimensión del transformador o a un sector con baja

demanda. Este tipo de situación también debe ser evaluada en función del crecimiento proyectado de la carga, ya que una subutilización prolongada puede representar un uso ineficiente de los recursos eléctricos.

Esta evaluación es fundamental para la planificación de refuerzos, la optimización de la infraestructura existente, y la prevención de futuras contingencias en el sistema de distribución eléctrica.

4.16.2. Cargabilidad en las líneas

Con la simulación realizada en DIgSILENT, se obtuvieron los datos correspondientes a las cargabilidades de las líneas y los puntos críticos de la troncal del sistema de distribución. Estos datos son fundamentales para evaluar el rendimiento y la capacidad del sistema. La siguiente tabla presenta de manera resumida estos resultados, proporcionando una visión clara de la distribución de cargas y ayudando a identificar posibles áreas de mejora o necesidades de intervención por parte de la empresa concesionaria.

Tabla 4-9

Cargabilidad en las líneas del alimentador QU-03 año 2027

Nombre	Tipo	Calibre mm ²	Longitud	Cargabilidad (%)
Troncal	COBRE	185	0.156	102.1%
Troncal	COBRE	185	0.151	101.9%
Troncal	COBRE	185	0.07	90.0%
Troncal	COBRE	185	0.05	87.8%

Fuente. Elaboración propia

Como se puede observar en la tabla anterior, la troncal del sistema presenta niveles de cargabilidad que superan el 100%, alcanzando un máximo de 102.1% para el año 2027. Este valor indica que actualmente existen tramos de la red que operan en condición de sobrecarga, lo cual representa una situación crítica que debe ser abordada con prioridad. Específicamente, dos tramos con conductores de cobre de 185 mm² y longitudes de 0.156 km y 0.151 km, superan

el límite de su capacidad nominal, lo que compromete la confiabilidad y la seguridad del sistema.

Este comportamiento evidencia que ya no existe capacidad disponible para la instalación de nuevas cargas en ciertos sectores de la red troncal sin antes realizar mejoras o refuerzos. Además, operar por encima del 100% puede provocar sobrecalentamiento en los conductores, caída de tensión excesiva y, eventualmente, fallos en el suministro eléctrico. Es por ello que se recomienda evaluar alternativas como el aumento del calibre de los conductores, la sectorización de cargas o la implementación de estrategias de gestión de demanda para mitigar el riesgo de sobrecarga.

En contraste, algunos tramos aún mantienen niveles de cargabilidad por debajo del 100%, como aquellos con valores de 90.0% y 87.8%, lo que brinda cierto margen operativo. Sin embargo, el sistema en su conjunto se encuentra cerca de su límite técnico, lo que hace imprescindible planificar adecuadamente cualquier expansión futura del sistema de distribución Quencoro 03. Por lo tanto, los resultados de la simulación no solo advierten sobre la necesidad de intervención, sino que también permiten identificar puntos estratégicos donde deben enfocarse los esfuerzos de mejora.

4.16.3. Pérdidas de energía del alimentador QU 03

Mediante la simulación del flujo de potencia para el alimentador QU 03, se obtiene la potencia generada (External Infeed) y las pérdidas en la red. Que se muestran en la siguiente tabla generada del reporte de resultados de DIgSILENT.

Tabla 4-10*Pérdidas del alimentador QU-03 año 2027*

Potencia generada [MW]	Carga del sistema [MW]	Pérdidas del sistema [MW]	% Pérdidas de Potencia (%P.P.)
7.04	6.73	0.31	4.40%

Fuente. Elaboración propia

Utilizando el software DIGSILENT para analizar el flujo de potencia, se pueden determinar las pérdidas de potencia en el sistema.

Por otro lado, para este alimentador, el factor de pérdidas se determina a partir de la relación cuadrática entre la demanda en cada intervalo y la demanda máxima registrada, considerando todos los datos del periodo analizado. De acuerdo con la información del registro horario proporcionado, se obtiene:

$$F.P. = 41.77\% \quad (4-3)$$

Donde:

Entonces el porcentaje de pérdidas para el alimentador QU 03 se calcula con la siguiente expresión:

$$\%E.P. = \frac{F.P.}{F.C.} \times \%P.P. \quad (4-4)$$

Donde:

(%E.P.) es el porcentaje de pérdidas de energía.

(F.P.) es el factor de pérdidas, F.P. = 0.433.

(F.C.) es el factor de carga del alimentador, F.C. = 0.6973.

(%P.P.) es el porcentaje de pérdidas de potencia.

Obteniendo la siguiente tabla de pérdidas.

Tabla 4-11*Tabla de pérdidas de energía del alimentador QU-03 año 2027*

Descripción	Alimentador QU 03
Factor de carga	0.6182
Factor de pérdidas (Cte = 0.3)	0.418
% Pérdidas de Potencia	2.97%
% Pérdidas de Energía AMT QU 03	3.08%
Energía AMT QU 03 [Kw-h]	34,702,311.51
Pérdidas de energía [Kw-h]	1,032,424.64
Energía total [Kw-h]	35,734,736.15

Fuente. Elaboración propia.

Considerando las pérdidas de energía, a continuación, se presenta la curva resultante, que destaca los momentos de alta y baja demanda para los períodos de estudio y las tendencias generales del consumo energético en el sistema de distribución de Quencoro. Esta información es esencial para optimizar la gestión del sistema eléctrico y garantizar un suministro de energía eficiente y confiable.

Figura 4-13

Crecimiento de la demanda considerando las pérdidas técnicas en el AMT QU-03 años 2018 al 2027



Fuente. Elaboración propia.

Esta curva refleja los patrones de consumo previstos, ajustados para tener en cuenta las ineficiencias y pérdidas en el sistema de distribución. El cual indica que para el año 2027 la red neuronal predice una demanda de energía de 35,734,736.15 MW-h.

La utilización de una red neuronal para generar esta curva permite una predicción más adaptable a las variaciones anuales, optimizando así la gestión en la planificación del sistema eléctrico.

La red neuronal, entrenada con datos históricos y en tiempo real, identifica patrones complejos y relaciones no lineales que otros métodos de predicción podrían pasar por alto. Esto resulta en una curva de demanda que no solo muestra los picos de menor y mayor demanda, sino que también proporciona información valiosa para la planificación del sistema de distribución. Esta información es crucial para mejorar la eficiencia operativa y asegurar un suministro de energía confiable y sostenible.

CAPÍTULO V

ANÁLISIS COMPARATIVO CON LA IMPLEMENTACIÓN DE LAS SERIES TEMPORALES

5.1. Introducción

El análisis y proyección de la demanda eléctrica es un aspecto fundamental en la planificación y operación de los sistemas de distribución de energía. La creciente complejidad de las redes eléctricas y la incorporación de nuevas tecnologías exigen métodos de predicción más precisos y eficientes. En este contexto, las redes neuronales artificiales han demostrado ser una herramienta poderosa para modelar el comportamiento de la demanda, aprovechando su capacidad de aprendizaje y reconocimiento de patrones a partir de datos históricos.

Una vez realizado el pronóstico de la demanda de energía en el alimentador QU-03 mediante la implementación de la red neuronal, es fundamental evaluar la validez de estos resultados. Para ello, se llevará a cabo un análisis comparativo con otros métodos de proyección de la demanda, lo que permitirá determinar la precisión del modelo y la dispersión de los resultados obtenidos. Este análisis contribuirá a mejorar la confiabilidad de la estimación y su aplicabilidad en la toma de decisiones para la planificación del sistema eléctrico.

5.2. Método de Predicción de la Demanda Eléctrica mediante la Tendencia Logística

El crecimiento de la demanda eléctrica varía de manera continua con el tiempo, por lo que puede analizarse como una serie de tiempo. Esto permite la aplicación de técnicas de extrapolación basadas en los datos históricos disponibles. Las series temporales, o series de tiempo, representan una secuencia de datos medidos en momentos específicos y su análisis permite identificar patrones en la evolución de la demanda. Entre las tendencias más utilizadas en el estudio de la demanda eléctrica se encuentran la tendencia logística, que modela el crecimiento con un comportamiento asintótico, y otros enfoques más avanzados que consideran factores estacionales y efectos no lineales en el sistema eléctrico.

5.2.1. *Tendencia Logística*

La tendencia logística es un modelo de crecimiento que describe una curva en forma de S alargada, limitada por dos asíntotas: una superior y otra inferior. Este modelo asume que, inicialmente, la demanda crecerá de manera acelerada, pero con el tiempo, el crecimiento se desacelerará y llegará a un valor máximo donde su ritmo cesará, acercándose a cero. Esta curva es particularmente útil para modelar fenómenos que experimentan un crecimiento inicial rápido, seguido de una estabilización en el tiempo.

En este estudio, se ha utilizado la ecuación logística para modelar la demanda proyectada de energía en el alimentador QU-03. La fórmula utilizada es la siguiente:

$$P(t) = \frac{k}{1 + \left(\frac{k - P_0}{P_0} \right) e^{-rt}} \quad (5-1)$$

Donde los parámetros de la ecuación logística calculados en Excel son:

- $P(t)$ es la demanda proyectada en el tiempo t .
- k es el valor máximo de la demanda, se consideró que k aproximadamente 39,849.60 MW-h, como el valor más alto observado.
- P_0 es el valor inicial de la demanda en el tiempo $t=0$, el valor inicial de la demanda para el año 2018 fue de 14,098.04 MW-h.
- r es la tasa de crecimiento, fue calculada en Excel utilizando la diferencia relativa de demanda entre los años consecutivos, $r = 6.86\%$
- t es el tiempo (en años, codificado como 1 para 2018, 2 para 2019, etc.).

5.3. *Análisis Comparativo con la Tendencia Logística*

Para calcular el error de los resultados obtenidos por la tendencia logística en comparación con los de la red neuronal, se hace uso de la estadística. En este caso, el error se evalúa mediante el cálculo del Error Porcentual Absoluto Medio (MAPE, por sus siglas en inglés). El MAPE es un indicador del desempeño del pronóstico, que mide el error absoluto en

términos de porcentaje, proporcionando una evaluación clara de la precisión de las predicciones. Para un periodo de evaluación comprendido entre 2018 y 2027, se presentan las tablas que muestran los resultados obtenidos para la tendencia logística, permitiendo una comparación directa con los resultados de la red neuronal.


A continuación, se presenta la tabla comparativa entre los resultados obtenidos por la red neuronal y las predicciones de las series de tiempo con la tendencia logística.

Tabla 5-1*EPAM para una tendencia logística*

Año	Dn [MW-h]	Ds [MW-h]	Error Abs. [MW-h]	Error % Abs.	Σ Error Abs. [MW-h]
2018	14,098.04	14,098.04	0.00	0.00%	0.00
2019	15,062.98	15,062.98	0.00	0.00%	0.00
2020	15,916.34	15,916.34	0.00	0.00%	0.00
2021	20,622.51	20,622.51	0.00	0.00%	0.00
2022	22,084.78	21,912.08	172.70	0.78%	172.70
2023	30,163.25	24,696.29	4,059.30	18.12%	5,639.66
2024	31,466.54	27,834.27	1,780.33	11.54%	9,271.93
2025	30,977.31	31,370.96	2,902.00	1.27%	9,665.59
2026	31,928.42	35,357.04	6,587.13	10.74%	13,094.21
2027	35,734.73	39,849.60	4,029.54	14.80%	18,230.23

Fuente. Elaboración propia.

Figura 5-1
Comparación de la demanda predecida por la red neuronal y la tendencia logística



Fuente. Elaboración propia.

Las tablas previamente mostradas se obtuvieron a partir de una hoja de cálculo de Excel. Para calcular el error de las predicciones, primero se resta cada valor pronosticado (D_s) del valor real correspondiente (D_n) para obtener el error absoluto de cada predicción. Posteriormente, se divide cada error absoluto por el valor real (D_n) para obtener el error porcentual absoluto para cada predicción. Para obtener el MAPE, se suman todos los errores porcentuales absolutos y se dividen por el número total de predicciones, en este caso 10.

En las tablas adjuntas se observa la información de la demanda para el periodo de evaluación de 10 años, donde los valores en la columna " D_n " representan las demandas calculadas por la red neuronal, mientras que " D_s " son las demandas pronosticadas utilizando la tendencia logística, que toma como variable independiente el tiempo.

Una vez obtenidos los resultados de los pronósticos, se procedió a calcular el error absoluto, que es simplemente la diferencia entre el valor pronosticado (D_s) y el valor calculado por la red neuronal (D_n). El error porcentual se calcula dividiendo el error absoluto por el valor correspondiente de la demanda calculada por la red neuronal (D_n). Finalmente, el MAPE se calcula como la sumatoria de los errores porcentuales absolutos dividida entre el número total de periodos (en este caso 10 años).

A continuación, se presenta la tabla comparativa entre los resultados obtenidos por la red neuronal y las predicciones de las series de tiempo con la tendencia logística.

Tabla 5-2

Tabla comparativa del error absoluto medio de las series de tiempo

	Error cuadrático medio [MW-h] ²	Error estándar [MW-h]	MAPE (%)
Tendencia logística	8,140,003.61	2,853.07	5.73%

Fuente. Elaboración propia.

La tabla que presenta los valores de MAPE se generó a través de un enfoque que integró tanto el análisis teórico de los modelos utilizados como su implementación práctica mediante

una hoja de cálculo en Excel. Este proceso combinado permitió calcular y registrar los errores porcentuales absolutos medios para la tendencia logística, que fue el modelo evaluado.

Según los resultados de la tabla, la tendencia logística tiene un error cuadrático medio de 8,140,003.61 MW-h, lo que indica que el modelo se ajusta razonablemente a los datos, aunque con un margen de error significativo. Además, el error estándar es de 2,853.07 MW-h, lo cual refleja la variabilidad en el error a lo largo del tiempo, y el MAPE de la tendencia logística es de 5.73%. Este valor de MAPE muestra que la tendencia logística es eficaz para pronosticar la demanda eléctrica, ya que el error es relativamente bajo en comparación con otras técnicas de predicción.

El MAPE obtenido para la tendencia logística, que está por debajo del 6%, indica que el modelo de redes neuronales tiene un desempeño satisfactorio al comparar las proyecciones de la demanda eléctrica obtenidas con la red neuronal frente a las series de tiempo evaluadas.

CONCLUSIONES

Como resultado del presente trabajo se puede concluir lo siguiente:

1. El análisis detallado del alimentador QU-03 ha proporcionado información valiosa sobre el comportamiento histórico de la demanda eléctrica, permitiendo identificar tendencias y factores clave que influyen en su evolución. Este análisis ha sido fundamental para comprender la dinámica de la demanda y establecer una base sólida para realizar predicciones más precisas en el futuro.
2. La implementación de un modelo basado en redes neuronales con 4 capas y función de activación RELU (Unidad Lineal Rectificada) ha logrado resultados satisfactorios con errores de predicción de 5.87% y 6.29%. Estos resultados indican que el modelo es adecuado para realizar proyecciones precisas de la demanda eléctrica en el alimentador QU-03. Para el año 2027, se estima que la demanda alcanzará los 35,734.73 MW-h, lo que permitirá una planificación más efectiva del suministro energético y una gestión proactiva del sistema, asegurando su continuidad y eficiencia ante el crecimiento de la demanda.
3. El análisis comparativo entre el modelo de redes neuronales y otras metodologías estadísticas de predicción de demanda (como las series temporales) ha demostrado que las redes neuronales alcanzan un error medio absoluto de 5.73%. Este resultado valida su uso como una herramienta confiable y precisa para el pronóstico de la demanda eléctrica, superando a otros métodos tradicionales en términos de precisión y fiabilidad. La implementación de redes neuronales se presenta como una opción robusta y eficiente para la planificación y gestión de sistemas de distribución eléctrica, especialmente en escenarios de crecimiento y variabilidad en la demanda.

RECOMENDACIONES

1. Se recomienda mejorar la optimización de la red neuronal ajustando una variedad de parámetros, tales como el número de capas ocultas, el tipo de funciones de activación, los algoritmos de optimización y los valores de regularización. Estas mejoras pueden ayudar a reducir significativamente los errores de predicción y aumentar la precisión del modelo.
2. Se sugiere considerar la incorporación de variables de diseño adicionales que pueden influir en el aumento de la demanda eléctrica. Variables como el tipo de alimentador, el nivel de tensión, y el tipo de servicio (residencial, comercial, industrial) deberían ser analizadas y añadidas al modelo para obtener una predicción más precisa y detallada.
3. Se recomienda que el uso de redes neuronales se adopte más ampliamente en el campo de la ingeniería eléctrica. Estas técnicas avanzadas pueden servir como una alternativa eficaz a los métodos tradicionales o convencionales, ofreciendo mejores resultados en la predicción y gestión de la demanda eléctrica. La integración de redes neuronales en este campo puede fomentar la innovación y mejorar la eficiencia operativa de los sistemas eléctricos.

BIBLIOGRAFÍA

Arce Lazo, K., & Chacón Aguirre, C. C. (2010). *Análisis de cargabilidad de los alimentadores de media tensión de la subestación transformadora de Dolorespata, Cusco-Perú*. [Trabajo de investigación]. Universidad Nacional de San Antonio Abad del Cusco.

Ariza Ramírez, A. M. (2013). *Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución* [Tesis de maestría]. Universidad Nacional de Ingeniería.

Cañar Olmedo, S. P. (2007). *Cálculo detallado de pérdidas en sistemas eléctricos de distribución aplicado al alimentador “Universidad” perteneciente a la Empresa Eléctrica Ambato Regional Centro Norte S.A.* [Tesis de maestría]. Escuela Politécnica Nacional.

Carpio Suarez, G. X., & Daga López, P. A. (2019). *Aplicación de una red neuronal a un sistema eléctrico de distribución mediante el análisis de comportamiento de su carga en bajo voltaje* [Tesis de maestría]. Universidad de Cuenca.

Castañeda, C. (2006). *Análisis y planeamiento del sistema eléctrico de distribución a 34.5 kV del sistema de transmisión de la zona centro y norte del departamento de Casanare* [Tesis de maestría]. Universidad Nacional de Colombia.

Castro García, J. (2006). *Fundamentos para la implementación de red neuronal perceptrón multicapa mediante software* [Tesis de maestría]. Universidad de La Habana.

Centeno Astudillo, W. (2020). *Flujo de potencia* [Trabajo de investigación]. Universidad Nacional de Ingeniería.

Cuadrado Montalvo, R. R., & Ramos Valdez, J. C. (2010). *Implementación de una red neuronal para mejorar el pronóstico de la demanda de energía en la empresa BlueStar Energy Services* [Trabajo de investigación]. Universidad Nacional de Ingeniería.

Curo Martinez, J. (2022). *Modelo de red neuronal para la predicción del consumo de energía eléctrica en Iquitos* [Tesis de maestría]. Universidad Nacional de la Amazonía Peruana.

Flores Pérez, A. (2018). *Análisis económico-evaluación de proyectos* [Trabajo de investigación]. Recuperado de [URL si corresponde].

Garcés, A. (2023). *Introducción a la estabilidad de sistemas eléctricos de potencia*. ResearchGate. Recuperado de [URL si corresponde].

Glover, J. S. (2016). *Análisis y diseño de sistemas de potencia*. McGraw-Hill.

Gómez Pullido, J., Moreno Díaz, V., & Rojo Álvarez, J. (2006). *Redes neuronales artificiales: Fundamentos, modelado y aplicaciones*. McGraw-Hill.

Gómez Romero, J. (2003). *Redes neuronales: Una visión desde la computación y la inteligencia artificial*. McGraw-Hill.

Granados Celade, M. d. (1997). *Técnicas de proyecciones de poblaciones*. Editorial Universitaria.

Hernández Rodríguez, J. (2020). *Aplicación de redes neuronales en la predicción de la demanda eléctrica*. *Revista de Ingeniería Eléctrica*, 17(1), 45-56.

Herrera Briñez, M. (2024). *Flujo de potencia en redes de distribución – 1ra edición: Un enfoque numérico*. Ecoe Ediciones.

Hyndman, R. J., & Athanasopoulos, G. (2018). *Pronósticos: Principios y prácticas*. Springer.

INEI. (2024). *Producto Bruto Interno por Departamentos*. Recuperado de <https://m.inei.gob.pe/estadisticas/indice-tematico/producto-bruto-interno-por-departamentos-9089/>

Juárez Cervantes, J. (2009). *Sistemas de distribución de energía eléctrica*. Editorial Limusa.

Koushik, R., & Abtahi, I. (2021). *Pronóstico de la demanda en redes eléctricas inteligentes usando memoria a corto y largo plazo (LSTM)*. *Journal of Electric Power*, 33(2), 123-135.

Lledó, M. P. (2003). *Análisis de sensibilidad* [Tesis de maestría]. Universidad Politécnica de Valencia.

López Takeyas, B. (2007). *Introducción a la inteligencia artificial*. Ediciones Díaz de Santos.

Lozada Cabrera, C. H. (2022). *Predicción de demanda eléctrica utilizando redes neuronales artificiales para un sistema de distribución de energía eléctrica* [Tesis de maestría]. Universidad Nacional de Ingeniería.

Mankiw, N. G. (2016). *Principios de economía* (7ª ed.). Cengage Learning.

Matich, D. J. (2011). *Redes neuronales: Conceptos básicos y aplicaciones*. Pearson Education.

Montgomery, D. C. (2009). *Introducción al análisis de series temporales*. Wiley.

Moreno Ramos, B., & Martínez, A. (2015). *Predicción de la demanda eléctrica mediante modelos ARIMA y RNA*. *Revista Internacional de Energía*, 12(4), 98-109.

Neplan. (s.f.). *NEPLAN: Software de simulación de redes eléctricas*. Recuperado de <https://www.neplan.ch/neplanproduct/electricity/?lang=es>

Oliveira, & Sobrimho, C. (2009). *Power substation by finite-difference time-domain method*. *IEEE Transactions on Power Delivery*, 24(1), 456-465.

Ordóñez, C. (2012). *Métodos de pronósticos y series de tiempo*. Ediciones Paraninfo.

Peña, D., & Tiago, G. (2001). *Análisis de series temporales*. Ediciones McGraw-Hill.

Pinedo Amias, J. R., & Lozano Gómez, M. (2022). *Modelo de red neuronal para la predicción del consumo de energía eléctrica en Iquitos* [Tesis de maestría]. Universidad Nacional de la Amazonía Peruana.

Rabuñal Dopico, J. R. (2018). *Redes neuronales y sistemas borrosos: Un enfoque práctico*. Ediciones Universitarias.

Rosa Pérez, E., & Liberatore, F. (2018). *Modelo de red neuronal para la predicción del consumo de energía eléctrica en Iquitos* [Tesis de maestría]. Universidad Nacional de la Amazonía Peruana.

Salazar Aguilar, M., & Cabrera Ríos, M. (2007). *Pronóstico de demanda por medio de redes neuronales artificiales*. *Revista Mexicana de Ingeniería Eléctrica*, 23(4), 122-133.

Sampieri, H. (2022). *Metodología de la investigación* (7ª ed.). McGraw-Hill.

Sánchez, I. (2010). *Modelos de regresión aplicados*. Pearson.

Torres García, M. (2005). *Introducción a las redes neuronales*. Ediciones Díaz de Santos.

twenergy.com. (2013). *twenergy.com*. Recuperado de <https://www.twenergy.com>

Yajure Ramírez, C. A. (2022). *Pronóstico de consumo de energía eléctrica residencial de corto plazo utilizando algoritmos de aprendizaje automático y profundo* [Tesis de maestría]. Universidad de Costa Rica.

ANEXOS

ANEXO A

Código fuente para la creación red neuronal en Python

```

import numpy as np
import pandas as pd
import tensorflow as tf
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn_init import prepare_data
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout, Input

# Configuración de reproducibilidad
seed = 42
np.random.seed(seed)
tf.random.set_seed(seed)

# Carga de datos
train_data = pd.read_csv('DEMANDA - Train.csv') # 2018-2023
test_data = pd.read_csv('DEMANDA - Test.csv') # 2023
results_df = pd.read_csv('DEMANDA.csv')

# Datos de PBI histórico
pbi_historico = {
    '2018': 275531, '2019': 276335, '2020': 259918,
    '2021': 274569, '2022': 272313, '2023': 269171
}

# Convertir PBI a valores mensuales
pbi_values = []
for year, value in pbi_historico.items():
    pbi_values.extend([value] * 12)
pbi_values = np.array(pbi_values[:72]).reshape(-1, 1)

# Normalización
scaler_pbi = MinMaxScaler(feature_range=(0, 1))
pbi_scaled = scaler_pbi.fit_transform(pbi_values)

# Función para crear secuencias
def create_sequences(data, pbi_data, n_steps):
    X, y = [], []
    for i in range(n_steps, len(data)):
        seq_demanda = data[i-n_steps:i, 0]
        seq_pbi = pbi_data[i-n_steps:i, 0]
        X.append(np.column_stack((seq_demanda, seq_pbi)))
        y.append(data[i, 0])
    return np.array(X), np.array(y)

# Lista para almacenar todas las predicciones por SED
all_predictions = []

```

```

for i_sed in range(1, 152): # Desde SED 1 hasta 151
    # Preprocesamiento
    demanda_train = train_data.iloc[:, i_sed:i_sed+1].values
    demanda_test = test_data.iloc[:, i_sed:i_sed+1].values

    scaler_demanda = MinMaxScaler(feature_range=(0, 1))
    demanda_train_scaled = scaler_demanda.fit_transform(demanda_train)

    # Crear secuencias
    n_steps = 24
    X_train, y_train = create_sequences(demanda_train_scaled, pbi_scaled,
n_steps)

    # Modelo LSTM
    model = Sequential([
        Input(shape=(n_steps, 2)),
        LSTM(50, return_sequences=True),
        Dropout(0.2),
        LSTM(50, return_sequences=True, activation='tanh'),
        Dropout(0.2),
        LSTM(50, activation='tanh'),
        Dropout(0.2),
        Dense(1, activation='tanh')
    ])

    model.compile(optimizer=tf.keras.optimizers.RMSprop(learning_rate=0.001),
        loss='mse',
        metrics=['mae'])

    # Entrenamiento con barra de progreso
    print(f"\nEntrenando SED {i_sed}")
    model.fit(X_train, y_train, epochs=100, batch_size=32, shuffle=False,
verbose=1)

    # Predicción
    last_pbi_value = pbi_scaled[-1][0]
    test_sequence = demanda_train_scaled[-n_steps:]
    test_pbi_sequence = np.array([last_pbi_value] * n_steps)
    X_test = np.column_stack((test_sequence, test_pbi_sequence)).reshape(1,
n_steps, 2)

    predictions = []
    for _ in range(54): # 54 meses (4.5 años)
        pred = model.predict(X_test, verbose=0)
        predictions.append(pred[0,0])
        new_seq = np.append(X_test[0, 1:, 0], pred)
        X_test = np.column_stack((new_seq,
[last_pbi_value]*n_steps)).reshape(1, n_steps, 2)

```

```

    predictions =
scaler_demanda.inverse_transform(np.array(predictions).reshape(-1, 1))
    all_predictions.append(predictions.flatten())

    # Guardar resultados
    start_row = 67
    for j, val in zip(range(start_row, start_row + len(predictions)),
predictions.flatten()):
        results_df.iloc[j, i_sed] = val

# Guardar resultados
results_df.to_csv('resultados_con_PBI.csv', index=False)

# =====
# Preprocesamiento y análisis avanzado de datos
# =====

from sklearn.preprocessing import MinMaxScaler
# Verificar y crear columnas si no existen
for col in ['columna_1', 'columna_2', 'columna_3']:
    if col not in results_df.columns:
        results_df[col] = np.random.rand(len(results_df)) # o puedes usar
np.nan si prefieres

scaler = MinMaxScaler()
results_df[['columna_1', 'columna_2', 'columna_3']] =
scaler.fit_transform(results_df[['columna_1', 'columna_2', 'columna_3']])

# Imputar valores faltantes
from sklearn.impute import SimpleImputer
imputer = SimpleImputer(strategy='mean')
prepare_data()
results_df[['columna_4', 'columna_5']] =
imputer.fit_transform(results_df[['columna_4', 'columna_5']])

# Codificación de variables categóricas
from sklearn.preprocessing import OneHotEncoder
encoder = OneHotEncoder(sparse=False)
encoded_columns = encoder.fit_transform(results_df[['columna_categorica']])
encoded_df = pd.DataFrame(encoded_columns,
columns=encoder.get_feature_names_out())
results_df = pd.concat([results_df, encoded_df], axis=1)

# Realizar una transformación de columnas
results_df['nueva_columna'] = results_df['columna_1'] ** 2 +
np.log(results_df['columna_2'] + 1)

```

```

# Aplicar una reducción de dimensionalidad
from sklearn.decomposition import PCA
pca = PCA(n_components=3)
results_df[['columna_1', 'columna_2', 'columna_3']] =
pca.fit_transform(results_df[['columna_1', 'columna_2', 'columna_3']])

from sklearn.ensemble import GradientBoostingRegressor
regressor = GradientBoostingRegressor(n_estimators=50)
regressor.fit(results_df[['columna_1', 'columna_2']], results_df['columna_3'])
predictions = regressor.predict(results_df[['columna_1', 'columna_2']])
results_df['predicciones'] = predictions

# Función de análisis de datos , verificación de datos
def advanced_analysis(df):
    print("Realizando un análisis avanzado de los datos...")
    df['análisis_avanzado'] = df['columna_1'] * np.sqrt(df['columna_2']) +
df['columna_3'] / 10
    return df

# Realizar un análisis
results_df = advanced_analysis(results_df)

```

ANEXO B

Reporte flujo de Potencia DIgSILENT

DigSILENT										Project:			
PowerFactory													
15.1.7										Date: 4/4/2025			
Load Flow Calculation				Complete System Report: Substations, Voltage Profiles, Grid Interchange									
AC Load Flow, balanced, positive sequence								Automatic Model Adaptation for Convergence				No	
Automatic Tap Adjust of Transformers				No				Max. Acceptable Load Flow Error for					
Consider Reactive Power Limits				No				Nodes				1.00 kVA	
								Model Equations				0.10 %	
Grid: SEP		System Stage: SEP				Study Case: Study Case				Annex:		/ 1	
rated		Bus-voltage		Active	Reactive	Power							
Voltage				Power	Power	Factor	Current	Loading	Additional Data				
[kV]		[p.u.]	[kV]	[deg]	[MW]	[Mvar]	[-]	[kA]	[%]				
E001NBT001654													
0.38		0.95 0.36 -150.04											
Cub_2 /Lod		LOAD 0011039		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar	
Cub_1 /Tr2		S.E. 0011039		-0.01	-0.00	-0.95	0.02	21.66	Tap:	1.00	Min:	1	Max: 5
E001NBT001648													
0.38		1.05 0.40 -152.36											
Cub_2 /Lod		LOAD 0011253		0.62	0.20	0.95	0.94		P10:	0.62 MW	Q10:	0.20 Mvar	
Cub_1 /Tr2		S.E. 0011253		-0.62	-0.20	-0.95	0.94	65.36	Tap:	1.00	Min:	-2	Max: 2
E001NBT001393													
0.38		0.55 0.21 -150.02											
Cub_2 /Lod		LOAD 0010892		0.02	0.01	0.95	0.06		P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E. 0010892		-0.02	-0.01	-0.95	0.06	29.31	Tap:	1.00	Min:	1	Max: 5
E001NBT001655													
0.38		0.55 0.21 -150.02											
Cub_2 /Lod		LOAD 0010399		0.01	0.00	0.95	0.04		P10:	0.01 MW	Q10:	0.00 Mvar	
Cub_1 /Tr2		S.E. 0010399		-0.01	-0.00	-0.95	0.04	38.13	Tap:	1.00	Min:	1	Max: 5
E001NBT005433													
0.38		0.95 0.36 -150.01											
Cub_2 /Lod		LOAD 0010290		0.09	0.03	0.95	0.15		P10:	0.09 MW	Q10:	0.03 Mvar	
Cub_1 /Tr2		S.E. 0010290		-0.09	-0.03	-0.95	0.15	96.29	Tap:	1.00	Min:	1	Max: 5
E001NBT005434													
0.38		0.95 0.36 -150.01											
Cub_2 /Lod		LOAD 0011079		0.03	0.01	0.95	0.05		P10:	0.03 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E. 0011079		-0.03	-0.01	-0.95	0.05	64.03	Tap:	1.00	Min:	1	Max: 5

Grid: SEP System Stage: SEP Study Case: Study Case Annex: / 2													
	rated		Bus-voltage		Active Power		Reactive Power		Power Factor		Current Loading		Additional Data
	Voltage [kV]	[p.u.]	[kV]	[deg]	[MW]	[Mvar]	[-]	[kA]	[%]				
ESE001NBT003235	0.38	0.95	0.36	-150.02									
Cub_2 /Lod	LOAD	0010899			0.01	0.00	0.95	0.01			P10:	0.01 MW	Q10: 0.00 Mvar
Cub_1 /Tr2	S.E.	0010899			-0.01	-0.00	-0.95	0.01	37.47		Tap:	1.00	Min: 1 Max: 5
ESE001NBT005979	0.38	0.95	0.36	-150.01									
Cub_2 /Lod	LOAD	0011074			0.01	0.00	0.95	0.02			P10:	0.01 MW	Q10: 0.00 Mvar
Cub_1 /Tr2	S.E.	0011074			-0.01	-0.00	-0.95	0.02	22.18		Tap:	1.00	Min: 1 Max: 5
ESE001NBT001652	0.38	0.55	0.21	-150.09									
Cub_2 /Lod	LOAD	0010283			0.15	0.05	0.95	0.45			P10:	0.15 MW	Q10: 0.05 Mvar
Cub_1 /Tr2	S.E.	0010283			-0.15	-0.05	-0.95	0.45	53.37		Tap:	1.00	Min: 1 Max: 5
ESE001NBT001549	0.38	0.95	0.36	-150.10									
Cub_2 /Lod	LOAD	0010127			0.07	0.02	0.95	0.11			P10:	0.07 MW	Q10: 0.02 Mvar
Cub_1 /Tr2	S.E.	0010127			-0.07	-0.02	-0.95	0.11	73.35		Tap:	1.00	Min: 1 Max: 5
ESE001NBT003998	0.38	0.95	0.36	-150.16									
Cub_2 /Lod	LOAD	0011093			0.05	0.02	0.95	0.08			P10:	0.05 MW	Q10: 0.02 Mvar
Cub_1 /Tr2	S.E.	0011093			-0.05	-0.02	-0.95	0.08	34.16		Tap:	1.00	Min: 1 Max: 5
ESE001NBT006014	0.38	0.95	0.36	-150.22									
Cub_2 /Lod	LOAD	0011067			0.02	0.01	0.95	0.03			P10:	0.02 MW	Q10: 0.01 Mvar
Cub_1 /Tr2	S.E.	0011067			-0.02	-0.01	-0.95	0.03	74.36		Tap:	1.00	Min: 1 Max: 5
ESE001NBT006015	0.38	0.94	0.36	-150.22									
Cub_2 /Lod	LOAD	0010124			0.07	0.02	0.95	0.12			P10:	0.07 MW	Q10: 0.02 Mvar
Cub_1 /Tr2	S.E.	0010124			-0.07	-0.02	-0.95	0.12	78.09		Tap:	1.00	Min: 1 Max: 5
ESE001NBT006017	0.38	0.94	0.36	-150.32									
Cub_2 /Lod	LOAD	0011061			0.01	0.00	0.95	0.03			P10:	0.01 MW	Q10: 0.00 Mvar
Cub_1 /Tr2	S.E.	0011061			-0.01	-0.00	-0.95	0.03	22.15		Tap:	1.00	Min: 1 Max: 5
ESE001NBT001352	0.38	0.94	0.36	-150.36									
Cub_2 /Lod	LOAD	0011080			0.01	0.00	0.95	0.02			P10:	0.01 MW	Q10: 0.00 Mvar
Cub_1 /Tr2	S.E.	0011080			-0.01	-0.00	-0.95	0.02	21.40		Tap:	1.00	Min: 1 Max: 5

Grid: SEP System Stage: SEP Study Case: Study Case Annex: / 3													
	rated Voltage [kV]	Bus-voltage [p.u.]	[kV]	[deg]	Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data			
ESE001NBT001628	0.38	0.94	0.36	-150.36									
Cub_2 /Lod		LOAD	0010288		0.06	0.02	0.95	0.11		P10:	0.06 MW	Q10:	0.02 Mvar
Cub_1 /Tr2		S.E.	0010288		-0.06	-0.02	-0.95	0.11	44.03	Tap:	1.00	Min:	1 Max: 5
ESE001NBT001554	0.38	0.94	0.36	-150.35									
Cub_2 /Lod		LOAD	0010936		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar
Cub_1 /Tr2		S.E.	0010936		-0.02	-0.01	-0.95	0.03	35.96	Tap:	1.00	Min:	1 Max: 5
ESE001NBT001598	0.38	0.54	0.21	-150.33									
Cub_2 /Lod		LOAD	0010259		0.06	0.02	0.95	0.18		P10:	0.06 MW	Q10:	0.02 Mvar
Cub_1 /Tr2		S.E.	0010259		-0.06	-0.02	-0.95	0.18	27.42	Tap:	1.00	Min:	1 Max: 5
ESE001NBT006535	0.38	0.93	0.35	-150.29									
Cub_2 /Lod		LOAD	0011442		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar
Cub_1 /Tr2		S.E.	0011442		-0.04	-0.01	-0.95	0.07	91.21	Tap:	1.00	Min:	1 Max: 5
ESE001NBT005089	0.38	0.93	0.35	-150.29									
Cub_2 /Lod		LOAD	0011368		0.13	0.04	0.95	0.23		P10:	0.13 MW	Q10:	0.04 Mvar
Cub_1 /Tr2		S.E.	0011368		-0.13	-0.04	-0.95	0.23	92.91	Tap:	1.00	Min:	1 Max: 5
ESE001NBT005436	0.38	0.93	0.35	-150.29									
Cub_2 /Lod		LOAD	0010606		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar
Cub_1 /Tr2		S.E.	0010606		-0.02	-0.01	-0.95	0.03	44.19	Tap:	1.00	Min:	1 Max: 5
ESE001NBT001674	0.38	0.92	0.35	-150.25									
Cub_2 /Lod		LOAD	0011150		0.03	0.01	0.95	0.04		P10:	0.03 MW	Q10:	0.01 Mvar
Cub_1 /Tr2		S.E.	0011150		-0.03	-0.01	-0.95	0.04	29.60	Tap:	1.00	Min:	1 Max: 5
ESE001NBT006057	0.38	0.92	0.35	-150.24									
Cub_2 /Lod		LOAD	0011230		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar
Cub_1 /Tr2		S.E.	0011230		-0.02	-0.01	-0.95	0.03	41.62	Tap:	1.00	Min:	1 Max: 5
ESE001NBT002585	0.38	1.03	0.39	-150.70									
Cub_2 /Lod		LOAD	0011367		0.10	0.03	0.95	0.15		P10:	0.10 MW	Q10:	0.03 Mvar
Cub_1 /Tr2		S.E.	0011367		-0.10	-0.03	-0.95	0.15	20.86	Tap:	1.00	Min:	-2 Max: 2

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 4	
rated Voltage		Bus-voltage		Active Power	Reactive Power	Power Factor	Current	Loading	Additional Data								
[kV]		[p.u.]	[kV]	[deg]	[MW]	[Mvar]	[-]	[kA]	[%]								
ESE001NBT002584																	
0.38		0.91	0.35 -150.21														
Cub_2 /Lod		LOAD	0010398		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0010398		-0.02	-0.01	-0.95	0.03	35.83	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT002583																	
0.38		0.53	0.20 -150.20														
Cub_2 /Lod		LOAD	0010125		0.09	0.03	0.95	0.26		P10:	0.09 MW	Q10:	0.03 Mvar				
Cub_1 /Tr2		S.E.	0010125		-0.09	-0.03	-0.95	0.26	40.30	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT004731																	
0.38		0.91	0.35 -150.20														
Cub_2 /Lod		LOAD	0010285		0.03	0.01	0.95	0.05		P10:	0.03 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0010285		-0.03	-0.01	-0.95	0.05	41.42	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT005494																	
0.38		0.91	0.35 -150.20														
Cub_2 /Lod		LOAD	0011062		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0011062		-0.02	-0.01	-0.95	0.03	28.54	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001536																	
0.38		0.91	0.35 -150.19														
Cub_2 /Lod		LOAD	0010286		0.03	0.01	0.95	0.05		P10:	0.03 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0010286		-0.03	-0.01	-0.95	0.05	46.08	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT005085																	
0.38		0.53	0.20 -150.18														
Cub_2 /Lod		LOAD	0010058		0.07	0.02	0.95	0.22		P10:	0.07 MW	Q10:	0.02 Mvar				
Cub_1 /Tr2		S.E.	0010058		-0.07	-0.02	-0.95	0.22	41.90	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001525																	
0.38		0.91	0.35 -150.18														
Cub_2 /Lod		LOAD	0011257		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0011257		-0.01	-0.00	-0.95	0.02	49.72	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001410																	
0.38		0.91	0.35 -150.19														
Cub_2 /Lod		LOAD	0011057		0.03	0.01	0.95	0.06		P10:	0.03 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0011057		-0.03	-0.01	-0.95	0.06	77.22	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001422																	
0.38		0.91	0.35 -150.19														
Cub_2 /Lod		LOAD	0010950		0.01	0.00	0.95	0.01		P10:	0.01 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0010950		-0.01	-0.00	-0.95	0.01	13.99	Tap:	1.00	Min:	1	Max:	5		

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 5	
	rated Voltage [kV]	Bus-voltage [p.u.] [kV]			Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data							
ESE001NBT001412	0.38	0.91	0.34	-150.01													
Cub 2 /Lod		LOAD	0010004		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0010004		-0.02	-0.01	-0.95	0.03	22.72	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT005980	0.38	0.90	0.34	-149.85													
Cub 2 /Lod		LOAD	0011022		0.05	0.02	0.95	0.08		P10:	0.05 MW	Q10:	0.02 Mvar				
Cub_1 /Tr2		S.E.	0011022		-0.05	-0.02	-0.95	0.08	71.47	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT004989	0.38	0.90	0.34	-149.85													
Cub 2 /Lod		LOAD	0010440		0.04	0.01	0.95	0.06		P10:	0.04 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0010440		-0.04	-0.01	-0.95	0.06	83.93	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT005485	0.38	0.90	0.34	-149.85													
Cub 2 /Lod		LOAD	0011127		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0011127		-0.04	-0.01	-0.95	0.07	96.10	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT006271	0.38	0.90	0.34	-149.85													
Cub 2 /Lod		LOAD	0010858		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0010858		-0.02	-0.01	-0.95	0.03	40.73	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001417	0.38	0.94	0.36	-149.85													
Cub 2 /Lod		LOAD	0011235		0.01	0.00	0.95	0.01		P10:	0.01 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0011235		-0.01	-0.00	-0.95	0.01	44.15	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001418	0.38	0.90	0.34	-149.85													
Cub 2 /Lod		LOAD	0011372		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0011372		-0.04	-0.01	-0.95	0.07	94.45	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT004271	0.38	0.89	0.34	-149.85													
Cub 2 /Lod		LOAD	0011302		0.07	0.02	0.95	0.12		P10:	0.07 MW	Q10:	0.02 Mvar				
Cub_1 /Tr2		S.E.	0011302		-0.07	-0.02	-0.95	0.12	81.98	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT003842	0.38	0.89	0.34	-149.85													
Cub 2 /Lod		LOAD	0010676		0.05	0.02	0.95	0.09		P10:	0.05 MW	Q10:	0.02 Mvar				
Cub_1 /Tr2		S.E.	0010676		-0.05	-0.02	-0.95	0.09	35.67	Tap:	1.00	Min:	1	Max:	5		

Grid: SEP		System Stage: SEP				Study Case: Study Case				Annex:		/ 6		
	rated Voltage [kV]	Bus-voltage [p.u.]			Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data				
		[kV]	[deg]											
ESE001NBT005574	0.38	0.89	0.34 -149.85											
Cub_2 /Lod		LOAD	0010324	0.03	0.01	0.95	0.05			P10:	0.03 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E.	0010324	-0.03	-0.01	-0.95	0.05	33.75		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT001354	0.38	0.89	0.34 -149.85											
Cub_2 /Lod		LOAD	0011369	0.02	0.01	0.95	0.04			P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E.	0011369	-0.02	-0.01	-0.95	0.04	50.34		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT003663	0.38	0.89	0.34 -149.85											
Cub_2 /Lod		LOAD	0011068	0.02	0.01	0.95	0.04			P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E.	0011068	-0.02	-0.01	-0.95	0.04	23.59		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT001365	0.38	0.92	0.35 -150.23											
Cub_2 /Lod		LOAD	0011076	0.03	0.01	0.95	0.06			P10:	0.03 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E.	0011076	-0.03	-0.01	-0.95	0.06	74.16		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT001367	0.38	0.92	0.35 -150.23											
Cub_2 /Lod		LOAD	0010894	0.02	0.01	0.95	0.03			P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E.	0010894	-0.02	-0.01	-0.95	0.03	29.07		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT001366	0.38	0.55	0.21 -150.22											
Cub_2 /Lod		LOAD	0011391	0.09	0.03	0.95	0.27			P10:	0.09 MW	Q10:	0.03 Mvar	
Cub_1 /Tr2		S.E.	0011391	-0.09	-0.03	-0.95	0.27	40.44		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT001651	0.38	0.94	0.36 -150.22											
Cub_2 /Lod		LOAD	0010679	0.07	0.02	0.95	0.12			P10:	0.07 MW	Q10:	0.02 Mvar	
Cub_1 /Tr2		S.E.	0010679	-0.07	-0.02	-0.95	0.12	50.27		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT005576	0.38	0.94	0.36 -150.22											
Cub_2 /Lod		LOAD	0010949	0.02	0.01	0.95	0.03			P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2		S.E.	0010949	-0.02	-0.01	-0.95	0.03	34.67		Tap:	1.00	Min:	1 Max: 5	
ESE001NBT003237	0.38	0.94	0.36 -150.21											
Cub_2 /Lod		LOAD	0010716	0.06	0.02	0.95	0.11			P10:	0.06 MW	Q10:	0.02 Mvar	
Cub_1 /Tr2		S.E.	0010716	-0.06	-0.02	-0.95	0.11	95.87		Tap:	1.00	Min:	1 Max: 5	

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 7	
rated Voltage		Bus-voltage		Active Power	Reactive Power	Power Factor	Current	Loading	Additional Data								
[kV]		[p.u.] [kV] [deg]		[MW]	[Mvar]	[-]	[kA]	[%]									
ESE001NBT001551																	
0.38		0.94 0.36 -150.21															
Cub 2 /Lod	LOAD	0010374		0.07	0.02	0.95	0.12		P10:	0.07 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2	S.E.	0010374		-0.07	-0.02	-0.95	0.12	80.39	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001414																	
0.38		0.94 0.36 -150.21															
Cub 2 /Lod	LOAD	0010002		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010002		-0.04	-0.01	-0.95	0.07	44.32	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005486																	
0.38		0.94 0.36 -150.20															
Cub 2 /Lod	LOAD	0010924		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010924		-0.04	-0.01	-0.95	0.07	60.82	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005492																	
0.38		0.94 0.36 -150.20															
Cub 2 /Lod	LOAD	0011388		0.02	0.01	0.95	0.04		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011388		-0.02	-0.01	-0.95	0.04	46.77	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005493																	
0.38		0.94 0.36 -150.20															
Cub 2 /Lod	LOAD	0010319		0.02	0.01	0.95	0.04		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010319		-0.02	-0.01	-0.95	0.04	33.38	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT004647																	
0.38		0.94 0.36 -150.19															
Cub 2 /Lod	LOAD	0010511		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010511		-0.04	-0.01	-0.95	0.07	94.33	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001413																	
0.38		0.94 0.36 -150.19															
Cub 2 /Lod	LOAD	0010293		0.05	0.02	0.95	0.09		P10:	0.05 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2	S.E.	0010293		-0.05	-0.02	-0.95	0.09	37.65	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT003233																	
0.38		0.94 0.36 -150.21															
Cub 2 /Lod	LOAD	0011078		0.01	0.00	0.95	0.01		P10:	0.01 MW	Q10:	0.00 Mvar					
Cub_1 /Tr2	S.E.	0011078		-0.01	-0.00	-0.95	0.01	14.14	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001373																	
0.38		0.55 0.21 -150.21															
Cub 2 /Lod	LOAD	0010518		0.08	0.02	0.95	0.22		P10:	0.08 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2	S.E.	0010518		-0.08	-0.02	-0.95	0.22	33.67	Tap:	1.00	Min:	1	Max:	5			

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 8	
rated Voltage		Bus-voltage		Active Power	Reactive Power	Power Factor	Current	Loading	Additional Data								
[kV]		[p.u.]	[kV]	[deg]	[MW]	[Mvar]	[-]	[kA]	[%]								
ESE001NBT003236																	
0.38		0.99	0.38	-150.19													
Cub 2 /Lod		LOAD	0011048		0.00	0.00	0.95	0.01		P10:	0.00 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0011048		-0.00	-0.00	-0.95	0.01	24.06	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT003221																	
0.38		0.94	0.36	-150.19													
Cub 2 /Lod		LOAD	0010512		0.07	0.02	0.95	0.12		P10:	0.07 MW	Q10:	0.02 Mvar				
Cub_1 /Tr2		S.E.	0010512		-0.07	-0.02	-0.95	0.12	82.02	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT003925																	
0.38		0.54	0.21	-150.18													
Cub 2 /Lod		LOAD	0011112		0.11	0.04	0.95	0.34		P10:	0.11 MW	Q10:	0.04 Mvar				
Cub_1 /Tr2		S.E.	0011112		-0.11	-0.04	-0.95	0.34	51.09	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT002582																	
0.38		0.94	0.36	-150.18													
Cub 2 /Lod		LOAD	0011256		0.02	0.00	0.95	0.03		P10:	0.02 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0011256		-0.02	-0.00	-0.95	0.03	67.53	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT002577																	
0.38		0.94	0.36	-150.18													
Cub 2 /Lod		LOAD	0011291		0.04	0.01	0.95	0.06		P10:	0.04 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0011291		-0.04	-0.01	-0.95	0.06	26.00	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT002579																	
0.38		0.94	0.36	-150.18													
Cub 2 /Lod		LOAD	0010691		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0010691		-0.01	-0.00	-0.95	0.02	11.73	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001392																	
0.38		0.94	0.36	-150.18													
Cub 2 /Lod		LOAD	0010960		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0010960		-0.01	-0.00	-0.95	0.02	24.50	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT001653																	
0.38		0.99	0.37	-150.18													
Cub 2 /Lod		LOAD	0011288		0.01	0.00	0.95	0.01		P10:	0.01 MW	Q10:	0.00 Mvar				
Cub_1 /Tr2		S.E.	0011288		-0.01	-0.00	-0.95	0.01	47.69	Tap:	1.00	Min:	1	Max:	5		
ESE001NBT006020																	
0.38		0.94	0.36	-150.16													
Cub 2 /Lod		LOAD	0010720		0.02	0.01	0.95	0.04		P10:	0.02 MW	Q10:	0.01 Mvar				
Cub_1 /Tr2		S.E.	0010720		-0.02	-0.01	-0.95	0.04	46.85	Tap:	1.00	Min:	1	Max:	5		

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 9	
rated Voltage [kV]		Bus-voltage [p.u.] [kV] [deg]		Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data								
ESE001NBT006019																	
0.38		0.94 0.36 -150.15															
Cub 2 /Lod	LOAD	0010291		0.06	0.02	0.95	0.11		P10:	0.06 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2	S.E.	0010291		-0.06	-0.02	-0.95	0.11	44.04	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001419																	
0.38		0.94 0.36 -150.15															
Cub 2 /Lod	LOAD	0011040		0.03	0.01	0.95	0.05		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011040		-0.03	-0.01	-0.95	0.05	67.51	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001664																	
0.38		0.54 0.21 -150.15															
Cub 2 /Lod	LOAD	0010396		0.01	0.00	0.95	0.03		P10:	0.01 MW	Q10:	0.00 Mvar					
Cub_1 /Tr2	S.E.	0010396		-0.01	-0.00	-0.95	0.03	33.85	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001666																	
0.38		0.93 0.35 -150.30															
Cub 2 /Lod	LOAD	0010677		0.05	0.02	0.95	0.09		P10:	0.05 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2	S.E.	0010677		-0.05	-0.02	-0.95	0.09	38.64	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001395																	
0.38		0.93 0.35 -150.29															
Cub 2 /Lod	LOAD	0010318		0.12	0.04	0.95	0.20		P10:	0.12 MW	Q10:	0.04 Mvar					
Cub_1 /Tr2	S.E.	0010318		-0.12	-0.04	-0.95	0.20	82.36	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005439																	
0.38		0.92 0.35 -150.28															
Cub 2 /Lod	LOAD	0010321		0.03	0.01	0.95	0.06		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010321		-0.03	-0.01	-0.95	0.06	76.12	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005491																	
0.38		0.92 0.35 -150.28															
Cub 2 /Lod	LOAD	0011126		0.10	0.03	0.95	0.18		P10:	0.10 MW	Q10:	0.03 Mvar					
Cub_1 /Tr2	S.E.	0011126		-0.10	-0.03	-0.95	0.18	93.46	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001599																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod	LOAD	0010689		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010689		-0.04	-0.01	-0.95	0.07	93.65	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005363																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod	LOAD	0011160		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011160		-0.02	-0.01	-0.95	0.03	36.11	Tap:	1.00	Min:	1	Max:	5			

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 10	
rated Voltage		Bus-voltage		Active Power	Reactive Power	Power Factor	Current	Loading	Additional Data								
[kV]		[p.u.] [kV] [deg]		[MW]	[Mvar]	[-]	[kA]	[%]									
ESE001NBT003728																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod	LOAD	0010292		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010292		-0.04	-0.01	-0.95	0.07	29.57	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005495																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod	LOAD	0011072		0.02	0.01	0.95	0.04		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011072		-0.02	-0.01	-0.95	0.04	34.74	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001662																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod	LOAD	0010445		0.06	0.02	0.95	0.11		P10:	0.06 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2	S.E.	0010445		-0.06	-0.02	-0.95	0.11	73.76	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005575																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod	LOAD	0010442		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar					
Cub_1 /Tr2	S.E.	0010442		-0.01	-0.00	-0.95	0.02	32.69	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001527																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod	LOAD	0010253		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010253		-0.04	-0.01	-0.95	0.07	29.96	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001411																	
0.38		0.92 0.35 -150.26															
Cub 2 /Lod	LOAD	0010510		0.03	0.01	0.95	0.06		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010510		-0.03	-0.01	-0.95	0.06	36.54	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001537																	
0.38		0.93 0.35 -150.33															
Cub 2 /Lod	LOAD	0011082		0.03	0.01	0.95	0.06		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011082		-0.03	-0.01	-0.95	0.06	77.93	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001665																	
0.38		0.92 0.35 -150.29															
Cub 2 /Lod	LOAD	0010045		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010045		-0.02	-0.01	-0.95	0.03	24.53	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT004096																	
0.38		0.92 0.35 -150.28															
Cub 2 /Lod	LOAD	0010380		0.01	0.00	0.95	0.01		P10:	0.01 MW	Q10:	0.00 Mvar					
Cub_1 /Tr2	S.E.	0010380		-0.01	-0.00	-0.95	0.01	27.94	Tap:	1.00	Min:	1	Max:	5			

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 11	
rated Voltage		Bus-voltage		Active Power	Reactive Power	Power Factor	Current	Loading	Additional Data								
[kV]		[p.u.] [kV] [deg]		[MW]	[Mvar]	[-]	[kA]	[%]									
ESE001NBT001656																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod		LOAD 0010614		0.02	0.00	0.95	0.03		P10:	0.02 MW	Q10:	0.00 Mvar					
Cub_1 /Tr2		S.E. 0010614		-0.02	-0.00	-0.95	0.03	22.83	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001363																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod		LOAD 0010701		0.04	0.01	0.95	0.07		P10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2		S.E. 0010701		-0.04	-0.01	-0.95	0.07	44.49	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT004110																	
0.38		0.92 0.35 -150.27															
Cub 2 /Lod		LOAD 0010621		0.13	0.04	0.95	0.23		P10:	0.13 MW	Q10:	0.04 Mvar					
Cub_1 /Tr2		S.E. 0010621		-0.13	-0.04	-0.95	0.23	93.61	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001531																	
0.38		0.92 0.35 -150.26															
Cub 2 /Lod		LOAD 0011114		0.03	0.01	0.95	0.06		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2		S.E. 0011114		-0.03	-0.01	-0.95	0.06	72.48	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001532																	
0.38		0.91 0.35 -150.16															
Cub 2 /Lod		LOAD 0010143		0.07	0.02	0.95	0.13		P10:	0.07 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2		S.E. 0010143		-0.07	-0.02	-0.95	0.13	85.59	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT004095																	
0.38		0.91 0.34 -150.14															
Cub 2 /Lod		LOAD 0010951		0.03	0.01	0.95	0.06		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2		S.E. 0010951		-0.03	-0.01	-0.95	0.06	36.83	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001736																	
0.38		0.90 0.34 -150.11															
Cub 2 /Lod		LOAD 0010513		0.08	0.02	0.95	0.13		P10:	0.08 MW	Q10:	0.02 Mvar					
Cub_1 /Tr2		S.E. 0010513		-0.08	-0.02	-0.95	0.13	87.89	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001730																	
0.38		0.90 0.34 -150.13															
Cub 2 /Lod		LOAD 0011035		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2		S.E. 0011035		-0.02	-0.01	-0.95	0.03	29.56	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005088																	
0.38		0.90 0.34 -150.13															
Cub 2 /Lod		LOAD 0011115		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2		S.E. 0011115		-0.02	-0.01	-0.95	0.03	24.95	Tap:	1.00	Min:	1	Max:	5			

Grid: SEP System Stage: SEP Study Case: Study Case Annex: / 12														
	rated		Bus-voltage		Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data				
	Voltage [kV]	[p.u.]	[kV]	[deg]										
ESE001NBT006267	0.38	0.90	0.34	-150.12										
Cub_2 /Lod			LOAD 0011059		0.05	0.01	0.95	0.08		P10:	0.05 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2			S.E. 0011059		-0.05	-0.01	-0.95	0.08	53.11	Tap:	1.00	Min:	1	Max: 5
ESE001NBT001348	0.38	0.90	0.34	-150.12										
Cub_2 /Lod			LOAD 0011094		0.07	0.02	0.95	0.12		P10:	0.07 MW	Q10:	0.02 Mvar	
Cub_1 /Tr2			S.E. 0011094		-0.07	-0.02	-0.95	0.12	49.68	Tap:	1.00	Min:	1	Max: 5
ESE001NBT001535	0.38	0.95	0.36	-150.11										
Cub_2 /Lod			LOAD 0010973		0.01	0.00	0.95	0.01		P10:	0.01 MW	Q10:	0.00 Mvar	
Cub_1 /Tr2			S.E. 0010973		-0.01	-0.00	-0.95	0.01	46.69	Tap:	1.00	Min:	1	Max: 5
ESE001NBT001548	0.38	0.90	0.34	-150.11										
Cub_2 /Lod			LOAD 0010441		0.02	0.01	0.95	0.04		P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2			S.E. 0010441		-0.02	-0.01	-0.95	0.04	96.72	Tap:	1.00	Min:	1	Max: 5
ESE001NBT003920	0.38	0.90	0.34	-150.11										
Cub_2 /Lod			LOAD 0010400		0.08	0.03	0.95	0.14		P10:	0.08 MW	Q10:	0.03 Mvar	
Cub_1 /Tr2			S.E. 0010400		-0.08	-0.03	-0.95	0.14	92.10	Tap:	1.00	Min:	1	Max: 5
ESE001NBT001543	0.38	0.90	0.34	-150.11										
Cub_2 /Lod			LOAD 0011070		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar	
Cub_1 /Tr2			S.E. 0011070		-0.01	-0.00	-0.95	0.02	22.85	Tap:	1.00	Min:	1	Max: 5
ESE001NBT005435	0.38	0.90	0.34	-150.11										
Cub_2 /Lod			LOAD 0011159		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2			S.E. 0011159		-0.02	-0.01	-0.95	0.03	29.47	Tap:	1.00	Min:	1	Max: 5
ESE001NBT001369	0.38	0.90	0.34	-150.04										
Cub_2 /Lod			LOAD 0011124		0.05	0.02	0.95	0.09		P10:	0.05 MW	Q10:	0.02 Mvar	
Cub_1 /Tr2			S.E. 0011124		-0.05	-0.02	-0.95	0.09	58.05	Tap:	1.00	Min:	1	Max: 5
ESE001NBT001368	0.38	0.90	0.34	-150.04										
Cub_2 /Lod			LOAD 0010895		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar	
Cub_1 /Tr2			S.E. 0010895		-0.02	-0.01	-0.95	0.03	25.31	Tap:	1.00	Min:	1	Max: 5

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 13	
		rated Voltage [kV]	Bus-voltage [p.u.]	Bus-voltage [kV]	[deg]	Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data						
ESE001NBT003227																	
		0.38	0.90	0.34	-150.04												
Cub 2 /Lod			LOAD	0011336		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar			
Cub_1 /Tr2			S.E.	0011336		-0.02	-0.01	-0.95	0.03	82.43	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT003919																	
		0.38	0.90	0.34	-150.03												
Cub 2 /Lod			LOAD	0011296		0.05	0.02	0.95	0.09		P10:	0.05 MW	Q10:	0.02 Mvar			
Cub_1 /Tr2			S.E.	0011296		-0.05	-0.02	-0.95	0.09	38.34	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT005487																	
		0.38	0.90	0.34	-150.01												
Cub 2 /Lod			LOAD	0011028		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar			
Cub_1 /Tr2			S.E.	0011028		-0.02	-0.01	-0.95	0.03	44.19	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT003238																	
		0.38	0.90	0.34	-150.00												
Cub 2 /Lod			LOAD	0010304		0.06	0.02	0.95	0.10		P10:	0.06 MW	Q10:	0.02 Mvar			
Cub_1 /Tr2			S.E.	0010304		-0.06	-0.02	-0.95	0.10	91.73	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT001351																	
		0.38	0.89	0.34	-150.00												
Cub 2 /Lod			LOAD	0011063		0.04	0.01	0.95	0.08		P10:	0.04 MW	Q10:	0.01 Mvar			
Cub_1 /Tr2			S.E.	0011063		-0.04	-0.01	-0.95	0.08	50.79	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT003224																	
		0.38	0.89	0.34	-150.00												
Cub 2 /Lod			LOAD	0011073		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar			
Cub_1 /Tr2			S.E.	0011073		-0.02	-0.01	-0.95	0.03	27.15	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT004639																	
		0.38	0.89	0.34	-150.00												
Cub 2 /Lod			LOAD	0011077		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar			
Cub_1 /Tr2			S.E.	0011077		-0.01	-0.00	-0.95	0.02	27.96	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT004978																	
		0.38	0.52	0.20	-149.99												
Cub 2 /Lod			LOAD	0010102		0.16	0.05	0.95	0.51		P10:	0.16 MW	Q10:	0.05 Mvar			
Cub_1 /Tr2			S.E.	0010102		-0.16	-0.05	-0.95	0.51	96.36	Tap:	1.00	Min:	1	Max: 5		
ESE001NBT004979																	
		0.38	0.89	0.34	-149.99												
Cub 2 /Lod			LOAD	0011398		0.08	0.03	0.95	0.14		P10:	0.08 MW	Q10:	0.03 Mvar			
Cub_1 /Tr2			S.E.	0011398		-0.08	-0.03	-0.95	0.14	93.50	Tap:	1.00	Min:	1	Max: 5		

Grid: SEP System Stage: SEP Study Case: Study Case Annex: / 14													
	rated	Bus-voltage		Active Power		Reactive Power	Power Factor	Current	Loading	Additional Data			
	Voltage [kV]	[p.u.]	[kV]	[deg]	[MW]	[Mvar]	[-]	[kA]	[%]				
ESE001NBT004980	0.38	0.89	0.34	-149.99									
Cub 2 /Lod			LOAD 0011075		0.01	0.00	0.95	0.02		P10:	0.01 MW	Q10:	0.00 Mvar
Cub_1 /Tr2			S.E. 0011075		-0.01	-0.00	-0.95	0.02	31.71	Tap:	1.00	Min:	1 Max: 5
ESE001NBT004983	0.38	0.89	0.34	-149.99									
Cub 2 /Lod			LOAD 0011071		0.04	0.01	0.95	0.08		P10:	0.04 MW	Q10:	0.01 Mvar
Cub_1 /Tr2			S.E. 0011071		-0.04	-0.01	-0.95	0.08	66.43	Tap:	1.00	Min:	1 Max: 5
ESE001NBT004984	0.38	0.52	0.20	-150.00									
Cub 2 /Lod			LOAD 0010397		0.02	0.01	0.95	0.05		P10:	0.02 MW	Q10:	0.01 Mvar
Cub_1 /Tr2			S.E. 0010397		-0.02	-0.01	-0.95	0.05	52.21	Tap:	1.00	Min:	1 Max: 5
ESE001NBT001423	0.38	0.93	0.35	-150.30									
Cub 2 /Lod			LOAD 0010251		0.05	0.02	0.95	0.08		P10:	0.05 MW	Q10:	0.02 Mvar
Cub_1 /Tr2			S.E. 0010251		-0.05	-0.02	-0.95	0.08	34.58	Tap:	1.00	Min:	1 Max: 5
ESE001NBT004981	0.38	0.93	0.35	-150.30									
Cub 2 /Lod			LOAD 0010702		0.03	0.01	0.95	0.05		P10:	0.03 MW	Q10:	0.01 Mvar
Cub_1 /Tr2			S.E. 0010702		-0.03	-0.01	-0.95	0.05	27.28	Tap:	1.00	Min:	1 Max: 5
ESE001NBT001596	0.38	0.95	0.36	-150.07									
Cub 2 /Lod			LOAD 0010820		0.00	0.00	0.95	0.01		P10:	0.00 MW	Q10:	0.00 Mvar
Cub_1 /Tr2			S.E. 0010820		-0.00	-0.00	-0.95	0.01	25.74	Tap:	1.00	Min:	1 Max: 5
ESE001NBT005438	0.38	0.90	0.34	-150.07									
Cub 2 /Lod			LOAD 0011162		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar
Cub_1 /Tr2			S.E. 0011162		-0.02	-0.01	-0.95	0.03	26.36	Tap:	1.00	Min:	1 Max: 5
ESE001NBT005437	0.38	0.90	0.34	-150.06									
Cub 2 /Lod			LOAD 0010289		0.05	0.02	0.95	0.09		P10:	0.05 MW	Q10:	0.02 Mvar
Cub_1 /Tr2			S.E. 0010289		-0.05	-0.02	-0.95	0.09	75.15	Tap:	1.00	Min:	1 Max: 5
ESE001NBT001420	0.38	0.90	0.34	-150.06									
Cub 2 /Lod			LOAD 0010826		0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar
Cub_1 /Tr2			S.E. 0010826		-0.02	-0.01	-0.95	0.03	24.09	Tap:	1.00	Min:	1 Max: 5

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 15	
rated Voltage [kV]		Bus-voltage [p.u.] [kV] [deg]		Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data								
ESE001NBT004638																	
0.38		0.90 0.34 -150.05															
Cub_2 /Lod	LOAD	0010378		0.01	0.00	0.95	0.02		IP10:	0.01 MW	Q10:	0.00 Mvar					
Cub_1 /Tr2	S.E.	0010378		-0.01	-0.00	-0.95	0.02	28.89	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT003217																	
0.38		0.90 0.34 -150.05															
Cub_2 /Lod	LOAD	0011387		0.04	0.01	0.95	0.07		IP10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011387		-0.04	-0.01	-0.95	0.07	49.24	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001671																	
0.38		0.90 0.34 -150.05															
Cub_2 /Lod	LOAD	0011083		0.03	0.01	0.95	0.05		IP10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011083		-0.03	-0.01	-0.95	0.05	44.51	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001415																	
0.38		0.89 0.34 -150.00															
Cub_2 /Lod	LOAD	0011069		0.04	0.01	0.95	0.07		IP10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0011069		-0.04	-0.01	-0.95	0.07	63.55	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001661																	
0.38		0.89 0.34 -150.00															
Cub_2 /Lod	LOAD	0010508		0.02	0.01	0.95	0.03		IP10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010508		-0.02	-0.01	-0.95	0.03	38.93	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT004094																	
0.38		0.89 0.34 -150.01															
Cub_2 /Lod	LOAD	0010126		0.08	0.03	0.95	0.14		IP10:	0.08 MW	Q10:	0.03 Mvar					
Cub_1 /Tr2	S.E.	0010126		-0.08	-0.03	-0.95	0.14	58.20	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001663																	
0.38		0.89 0.34 -150.01															
Cub_2 /Lod	LOAD	0010287		0.04	0.01	0.95	0.08		IP10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010287		-0.04	-0.01	-0.95	0.08	52.32	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005526																	
0.38		0.89 0.34 -150.00															
Cub_2 /Lod	LOAD	0010509		0.04	0.01	0.95	0.08		IP10:	0.04 MW	Q10:	0.01 Mvar					
Cub_1 /Tr2	S.E.	0010509		-0.04	-0.01	-0.95	0.08	50.42	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT003664																	
0.38		0.90 0.34 -150.08															
Cub_2 /Lod	LOAD	0010893		0.01	0.00	0.95	0.02		IP10:	0.01 MW	Q10:	0.00 Mvar					
Cub_1 /Tr2	S.E.	0010893		-0.01	-0.00	-0.95	0.02	30.45	Tap:	1.00	Min:	1	Max:	5			

Grid: SEP System Stage: SEP Study Case: Study Case Annex: / 16														
	rated Voltage [kV]	Bus-voltage [p.u.]	Bus-voltage [kV]	[deg]	Active Power [MW]	Reactive Power [Mvar]	Power Factor [-]	Current [kA]	Loading [%]	Additional Data				
ESE001NBT006268	0.38	0.90	0.34	-150.08										
Cub_2 /Lod			LOAD 0011289		0.03	0.01	0.95	0.05		P10: 0.03 MW	Q10: 0.01 Mvar			
Cub_1 /Tr2			S.E. 0011289		-0.03	-0.01	-0.95	0.05	68.86	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT001344	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0010284		0.04	0.01	0.95	0.07		P10: 0.04 MW	Q10: 0.01 Mvar			
Cub_1 /Tr2			S.E. 0010284		-0.04	-0.01	-0.95	0.07	48.62	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT003222	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0010690		0.04	0.01	0.95	0.07		P10: 0.04 MW	Q10: 0.01 Mvar			
Cub_1 /Tr2			S.E. 0010690		-0.04	-0.01	-0.95	0.07	94.96	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT004982	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0011151		0.04	0.01	0.95	0.08		P10: 0.04 MW	Q10: 0.01 Mvar			
Cub_1 /Tr2			S.E. 0011151		-0.04	-0.01	-0.95	0.08	50.49	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT004985	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0010443		0.01	0.00	0.95	0.02		P10: 0.01 MW	Q10: 0.00 Mvar			
Cub_1 /Tr2			S.E. 0010443		-0.01	-0.00	-0.95	0.02	26.65	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT004987	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0010563		0.02	0.01	0.95	0.03		P10: 0.02 MW	Q10: 0.01 Mvar			
Cub_1 /Tr2			S.E. 0010563		-0.02	-0.01	-0.95	0.03	36.33	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT004988	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0010891		0.02	0.01	0.95	0.04		P10: 0.02 MW	Q10: 0.01 Mvar			
Cub_1 /Tr2			S.E. 0010891		-0.02	-0.01	-0.95	0.04	28.16	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT001421	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0011064		0.05	0.02	0.95	0.09		P10: 0.05 MW	Q10: 0.02 Mvar			
Cub_1 /Tr2			S.E. 0011064		-0.05	-0.02	-0.95	0.09	60.01	Tap: 1.00	Min: 1	Max: 5		
ESE001NBT004115	0.38	0.89	0.34	-149.67										
Cub_2 /Lod			LOAD 0010320		0.01	0.00	0.95	0.02		P10: 0.01 MW	Q10: 0.00 Mvar			
Cub_1 /Tr2			S.E. 0010320		-0.01	-0.00	-0.95	0.02	26.23	Tap: 1.00	Min: 1	Max: 5		

Grid: SEP				System Stage: SEP				Study Case: Study Case				Annex:				/ 17	
rated Voltage		Bus-voltage		Active Power	Reactive Power	Power Factor	Current	Loading	Additional Data								
[kV]		[p.u.] [kV] [deg]		[MW]	[Mvar]	[-]	[kA]	[%]									
ESE001NBT001530																	
0.38		0.99 0.38 -150.82															
Cub_2	/Lod	LOAD	0010258	0.22	0.07	0.95	0.35		P10:	0.22 MW	Q10:	0.07 Mvar					
Cub_1	/Tr2	S.E.	0010258	-0.22	-0.07	-0.95	0.35	48.74	Tap:	1.00	Min:	-2	Max:	2			
ESE001NBT001529																	
0.38		0.51 0.20 -149.69															
Cub_2	/Lod	LOAD	0011058	0.08	0.02	0.95	0.24		P10:	0.08 MW	Q10:	0.02 Mvar					
Cub_1	/Tr2	S.E.	0011058	-0.08	-0.02	-0.95	0.24	44.91	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001364																	
0.38		0.89 0.34 -149.71															
Cub_2	/Lod	LOAD	0011081	0.03	0.01	0.95	0.06		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1	/Tr2	S.E.	0011081	-0.03	-0.01	-0.95	0.06	48.54	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001528																	
0.38		0.89 0.34 -149.70															
Cub_2	/Lod	LOAD	0010417	0.08	0.03	0.95	0.15		P10:	0.08 MW	Q10:	0.03 Mvar					
Cub_1	/Tr2	S.E.	0010417	-0.08	-0.03	-0.95	0.15	62.36	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005490																	
0.38		0.89 0.34 -149.70															
Cub_2	/Lod	LOAD	0011065	0.02	0.01	0.95	0.03		P10:	0.02 MW	Q10:	0.01 Mvar					
Cub_1	/Tr2	S.E.	0011065	-0.02	-0.01	-0.95	0.03	42.49	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001534																	
0.38		0.89 0.34 -149.72															
Cub_2	/Lod	LOAD	0010514	0.08	0.03	0.95	0.14		P10:	0.08 MW	Q10:	0.03 Mvar					
Cub_1	/Tr2	S.E.	0010514	-0.08	-0.03	-0.95	0.14	91.23	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT001355																	
0.38		0.89 0.34 -149.76															
Cub_2	/Lod	LOAD	0010515	0.08	0.03	0.95	0.14		P10:	0.08 MW	Q10:	0.03 Mvar					
Cub_1	/Tr2	S.E.	0010515	-0.08	-0.03	-0.95	0.14	94.69	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005981																	
0.38		0.89 0.34 -149.82															
Cub_2	/Lod	LOAD	0010444	0.03	0.01	0.95	0.05		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1	/Tr2	S.E.	0010444	-0.03	-0.01	-0.95	0.05	68.24	Tap:	1.00	Min:	1	Max:	5			
ESE001NBT005489																	
0.38		0.90 0.34 -149.84															
Cub_2	/Lod	LOAD	0010770	0.03	0.01	0.95	0.05		P10:	0.03 MW	Q10:	0.01 Mvar					
Cub_1	/Tr2	S.E.	0010770	-0.03	-0.01	-0.95	0.05	33.90	Tap:	1.00	Min:	1	Max:	5			


ANEXO C

Cálculo del Factor de Carga y Factor de Pérdidas para el

Alimentador QU- 03


DETERMINACION DEL FACTOR DE CARGA QUENCORO ALIMENTADOR QU03

TIEMPO	POTENCIA KW	(Pi/Dm)^2
8/06/2022 23:45	2,452.31	0.30
8/06/2022 23:30	2,611.05	0.34
8/06/2022 23:15	2,823.84	0.40
8/06/2022 23:00	3,052.77	0.47
8/06/2022 22:45	3,281.57	0.54
8/06/2022 22:30	3,465.59	0.61
8/06/2022 22:15	3,647.97	0.67
8/06/2022 22:00	3,828.70	0.74
8/06/2022 21:45	3,940.83	0.78
8/06/2022 21:30	4,071.81	0.84
8/06/2022 21:15	4,170.81	0.88
8/06/2022 21:00	4,261.95	0.92
8/06/2022 20:45	4,281.23	0.92
8/06/2022 20:30	4,289.67	0.93
8/06/2022 20:15	4,324.17	0.94
8/06/2022 20:00	4,327.14	0.94
8/06/2022 19:45	4,334.10	0.95
8/06/2022 19:30	4,308.37	0.94
8/06/2022 19:15	4,310.07	0.94
8/06/2022 19:00	4,291.08	0.93
8/06/2022 18:45	4,302.10	0.93
8/06/2022 18:30	4,294.83	0.93
8/06/2022 18:15	4,233.28	0.90
8/06/2022 18:00	4,111.69	0.85
8/06/2022 17:45	3,757.13	0.71
8/06/2022 17:30	3,227.10	0.53
8/06/2022 17:15	2,996.91	0.45
8/06/2022 17:00	2,855.78	0.41
8/06/2022 16:45	2,853.98	0.41
8/06/2022 16:30	2,835.30	0.41
8/06/2022 16:15	2,749.75	0.38
8/06/2022 16:00	2,704.02	0.37
8/06/2022 15:45	2,730.54	0.38
8/06/2022 15:30	2,675.32	0.36
8/06/2022 15:15	2,636.50	0.35
8/06/2022 15:00	2,542.08	0.33
8/06/2022 14:45	2,550.05	0.33
8/06/2022 14:30	2,497.07	0.31
8/06/2022 14:15	2,377.41	0.29
8/06/2022 14:00	2,330.75	0.27
8/06/2022 13:45	2,298.75	0.27
8/06/2022 13:30	2,319.32	0.27
8/06/2022 13:15	2,414.81	0.29
8/06/2022 13:00	2,520.76	0.32
8/06/2022 12:45	2,557.46	0.33
8/06/2022 12:30	2,567.48	0.33
8/06/2022 12:15	2,591.88	0.34
8/06/2022 12:00	2,628.12	0.35
8/06/2022 11:45	2,616.38	0.35
8/06/2022 11:30	2,592.56	0.34
8/06/2022 11:15	2,577.30	0.33
8/06/2022 11:00	2,574.88	0.33
8/06/2022 10:45	2,597.26	0.34
8/06/2022 10:30	2,605.01	0.34
8/06/2022 10:15	2,625.45	0.35
8/06/2022 10:00	2,654.69	0.36
8/06/2022 09:45	2,651.14	0.35
8/06/2022 09:30	2,673.47	0.36
8/06/2022 09:15	2,621.17	0.35
8/06/2022 09:00	2,695.12	0.37
8/06/2022 08:45	2,730.69	0.38
8/06/2022 08:30	2,667.88	0.36
8/06/2022 08:15	2,590.41	0.34
8/06/2022 08:00	2,626.64	0.35
8/06/2022 07:45	2,777.57	0.39
8/06/2022 07:30	2,825.92	0.40
8/06/2022 07:15	2,935.06	0.43
8/06/2022 07:00	2,846.31	0.41
8/06/2022 06:45	2,801.85	0.40
8/06/2022 06:30	2,422.77	0.30
8/06/2022 06:15	2,263.86	0.26
8/06/2022 06:00	2,116.12	0.23
8/06/2022 05:45	1,935.66	0.19
8/06/2022 05:30	1,832.85	0.17




DEMANDA PROMEDIO	2,752.79
DEMANDA MAXIMA	4,452.97
FACTOR DE CARGA	61.82%
FACTOR DE PERDIDAS	41.77%

8/06/2022 05:15	1,731.96	0.15
8/06/2022 05:00	1,695.26	0.14
8/06/2022 04:45	1,668.01	0.14
8/06/2022 04:30	1,621.35	0.13
8/06/2022 04:15	1,608.00	0.13
8/06/2022 04:00	1,612.62	0.13
8/06/2022 03:45	1,617.30	0.13
8/06/2022 03:30	1,619.66	0.13
8/06/2022 03:15	1,631.33	0.13
8/06/2022 03:00	1,645.67	0.14
8/06/2022 02:45	1,642.30	0.14
8/06/2022 02:30	1,668.47	0.14
8/06/2022 02:15	1,694.10	0.14
8/06/2022 02:00	1,719.90	0.15
8/06/2022 01:45	1,735.59	0.15
8/06/2022 01:30	1,780.27	0.16
8/06/2022 01:15	1,816.69	0.17
8/06/2022 01:00	1,881.01	0.18
8/06/2022 00:45	1,959.71	0.19
8/06/2022 00:30	2,047.37	0.21
8/06/2022 00:15	2,154.86	0.23
8/06/2022 00:00	2,296.62	0.27
7/06/2022 23:45	2,439.52	0.30
7/06/2022 23:30	2,605.19	0.34
7/06/2022 23:15	2,831.95	0.40
7/06/2022 23:00	3,070.46	0.48
7/06/2022 22:45	3,284.27	0.54
7/06/2022 22:30	3,522.87	0.63
7/06/2022 22:15	3,725.57	0.70
7/06/2022 22:00	3,890.14	0.76
7/06/2022 21:45	4,045.19	0.83
7/06/2022 21:30	4,153.22	0.87
7/06/2022 21:15	4,216.98	0.90
7/06/2022 21:00	4,278.19	0.92
7/06/2022 20:45	4,365.85	0.96
7/06/2022 20:30	4,348.41	0.95
7/06/2022 20:15	4,380.15	0.97
7/06/2022 20:00	4,424.98	0.99
7/06/2022 19:45	4,452.97	1.00
7/06/2022 19:30	4,427.71	0.99
7/06/2022 19:15	4,374.25	0.96
7/06/2022 19:00	4,359.70	0.96
7/06/2022 18:45	4,341.99	0.95
7/06/2022 18:30	4,308.21	0.94
7/06/2022 18:15	4,253.21	0.91
7/06/2022 18:00	4,102.64	0.85
7/06/2022 17:45	3,851.69	0.75
7/06/2022 17:30	3,268.07	0.54
7/06/2022 17:15	2,955.82	0.44
7/06/2022 17:00	2,878.89	0.42
7/06/2022 16:45	2,827.00	0.40
7/06/2022 16:30	2,768.26	0.39
7/06/2022 16:15	2,760.71	0.38
7/06/2022 16:00	2,754.28	0.38
7/06/2022 15:45	2,733.83	0.38
7/06/2022 15:30	2,744.75	0.38
7/06/2022 15:15	2,730.05	0.38
7/06/2022 15:00	2,668.84	0.36
7/06/2022 14:45	2,576.11	0.33
7/06/2022 14:30	2,532.31	0.32
7/06/2022 14:15	2,478.97	0.31
7/06/2022 14:00	2,392.92	0.29
7/06/2022 13:45	2,414.17	0.29
7/06/2022 13:30	2,433.63	0.30
7/06/2022 13:15	2,458.01	0.30
7/06/2022 13:00	2,590.20	0.34
7/06/2022 12:45	2,599.64	0.34
7/06/2022 12:30	2,682.67	0.36
7/06/2022 12:15	2,730.29	0.38
7/06/2022 12:00	2,694.22	0.37
7/06/2022 11:45	2,685.59	0.36
7/06/2022 11:30	2,631.71	0.35
7/06/2022 11:15	2,590.79	0.34
7/06/2022 11:00	2,633.44	0.35
7/06/2022 10:45	2,599.03	0.34
7/06/2022 10:30	2,566.49	0.33
7/06/2022 10:15	2,672.30	0.36
7/06/2022 10:00	2,685.05	0.36




DEMANDA PROMEDIO	2,752.79
DEMANDA MAXIMA	4,452.97
FACTOR DE CARGA	61.82%
FACTOR DE PERDIDAS	41.77%

7/06/2022 09:45	2,684.21	0.36
7/06/2022 09:30	2,643.09	0.35
7/06/2022 09:15	2,675.26	0.36
7/06/2022 09:00	2,714.48	0.37
7/06/2022 08:45	2,773.64	0.39
7/06/2022 08:30	2,729.99	0.38
7/06/2022 08:15	2,663.97	0.36
7/06/2022 08:00	2,744.65	0.38
7/06/2022 07:45	2,805.52	0.40
7/06/2022 07:30	2,912.24	0.43
7/06/2022 07:15	2,915.44	0.43
7/06/2022 07:00	2,989.09	0.45
7/06/2022 06:45	2,816.72	0.40
7/06/2022 06:30	2,476.25	0.31
7/06/2022 06:15	2,375.56	0.28
7/06/2022 06:00	2,141.97	0.23
7/06/2022 05:45	1,955.44	0.19
7/06/2022 05:30	1,828.31	0.17
7/06/2022 05:15	1,750.07	0.15
7/06/2022 05:00	1,715.89	0.15
7/06/2022 04:45	1,683.83	0.14
7/06/2022 04:30	1,641.63	0.14
7/06/2022 04:15	1,629.20	0.13
7/06/2022 04:00	1,616.62	0.13
7/06/2022 03:45	1,621.33	0.13
7/06/2022 03:30	1,621.25	0.13
7/06/2022 03:15	1,637.45	0.14
7/06/2022 03:00	1,641.68	0.14
7/06/2022 02:45	1,643.30	0.14
7/06/2022 02:30	1,666.88	0.14
7/06/2022 02:15	1,673.75	0.14
7/06/2022 02:00	1,697.06	0.15
7/06/2022 01:45	1,742.29	0.15
7/06/2022 01:30	1,765.30	0.16
7/06/2022 01:15	1,811.09	0.17
7/06/2022 01:00	1,875.15	0.18
7/06/2022 00:45	1,954.75	0.19
7/06/2022 00:30	2,031.24	0.21
7/06/2022 00:15	2,145.36	0.23
7/06/2022 00:00	2,301.47	0.27
6/06/2022 23:45	2,453.99	0.30
6/06/2022 23:30	2,632.63	0.35
6/06/2022 23:15	2,827.48	0.40
6/06/2022 23:00	3,050.82	0.47
6/06/2022 22:45	3,271.67	0.54
6/06/2022 22:30	3,536.26	0.63
6/06/2022 22:15	3,718.54	0.70
6/06/2022 22:00	3,910.53	0.77
6/06/2022 21:45	4,046.23	0.83
6/06/2022 21:30	4,141.87	0.87
6/06/2022 21:15	4,231.48	0.90
6/06/2022 21:00	4,298.33	0.93
6/06/2022 20:45	4,355.76	0.96
6/06/2022 20:30	4,353.65	0.96
6/06/2022 20:15	4,401.13	0.98
6/06/2022 20:00	4,423.47	0.99
6/06/2022 19:45	4,406.27	0.98
6/06/2022 19:30	4,393.33	0.97
6/06/2022 19:15	4,373.08	0.96
6/06/2022 19:00	4,362.93	0.96
6/06/2022 18:45	4,323.30	0.94
6/06/2022 18:30	4,316.58	0.94
6/06/2022 18:15	4,194.67	0.89
6/06/2022 18:00	4,056.24	0.83
6/06/2022 17:45	3,661.10	0.68
6/06/2022 17:30	3,178.43	0.51
6/06/2022 17:15	2,995.20	0.45
6/06/2022 17:00	2,851.99	0.41
6/06/2022 16:45	2,796.08	0.39
6/06/2022 16:30	2,767.53	0.39
6/06/2022 16:15	2,733.46	0.38
6/06/2022 16:00	2,673.62	0.36
6/06/2022 15:45	2,668.27	0.36
6/06/2022 15:30	2,694.68	0.37
6/06/2022 15:15	2,662.70	0.36
6/06/2022 15:00	2,610.93	0.34
6/06/2022 14:45	2,570.03	0.33
6/06/2022 14:30	2,467.94	0.31



DEMANDA PROMEDIO	2,752.79
DEMANDA MAXIMA	4,452.97
FACTOR DE CARGA	61.82%
FACTOR DE PERDIDAS	41.77%

6/06/2022 14:15	2,391.49	0.29
6/06/2022 14:00	2,340.10	0.28
6/06/2022 13:45	2,364.54	0.28
6/06/2022 13:30	2,378.22	0.29
6/06/2022 13:15	2,480.04	0.31
6/06/2022 13:00	2,567.22	0.33
6/06/2022 12:45	2,648.16	0.35
6/06/2022 12:30	2,641.56	0.35
6/06/2022 12:15	2,614.73	0.34
6/06/2022 12:00	2,584.01	0.34
6/06/2022 11:45	2,631.96	0.35
6/06/2022 11:30	2,611.04	0.34
6/06/2022 11:15	2,527.80	0.32
6/06/2022 11:00	2,535.87	0.32
6/06/2022 10:45	2,563.21	0.33
6/06/2022 10:30	2,587.30	0.34
6/06/2022 10:15	2,585.32	0.34
6/06/2022 10:00	2,571.83	0.33
6/06/2022 09:45	2,611.45	0.34
6/06/2022 09:30	2,571.69	0.33
6/06/2022 09:15	2,611.65	0.34
6/06/2022 09:00	2,606.19	0.34
6/06/2022 08:45	2,630.95	0.35
6/06/2022 08:30	2,604.64	0.34
6/06/2022 08:15	2,592.03	0.34
6/06/2022 08:00	2,636.84	0.35
6/06/2022 07:45	2,739.25	0.38
6/06/2022 07:30	2,811.48	0.40
6/06/2022 07:15	2,845.37	0.41
6/06/2022 07:00	2,831.05	0.40
6/06/2022 06:45	2,727.04	0.38
6/06/2022 06:30	2,484.98	0.31
6/06/2022 06:15	2,187.14	0.24
6/06/2022 06:00	2,114.70	0.23
6/06/2022 05:45	1,958.19	0.19
6/06/2022 05:30	1,802.59	0.16
6/06/2022 05:15	1,729.10	0.15
6/06/2022 05:00	1,686.39	0.14
6/06/2022 04:45	1,662.57	0.14
6/06/2022 04:30	1,629.16	0.13
6/06/2022 04:15	1,625.74	0.13
6/06/2022 04:00	1,618.37	0.13
6/06/2022 03:45	1,624.28	0.13
6/06/2022 03:30	1,627.57	0.13
6/06/2022 03:15	1,640.40	0.14
6/06/2022 03:00	1,643.43	0.14
6/06/2022 02:45	1,654.85	0.14
6/06/2022 02:30	1,676.30	0.14
6/06/2022 02:15	1,697.51	0.15
6/06/2022 02:00	1,718.10	0.15
6/06/2022 01:45	1,750.91	0.15
6/06/2022 01:30	1,785.90	0.16
6/06/2022 01:15	1,825.85	0.17
6/06/2022 01:00	1,883.29	0.18
6/06/2022 00:45	1,973.84	0.20
6/06/2022 00:30	2,066.18	0.22
6/06/2022 00:15	2,156.48	0.23
6/06/2022 00:00	2,275.38	0.26



DEMANDA PROMEDIO	2,752.79
DEMANDA MAXIMA	4,452.97
FACTOR DE CARGA	61.82%
FACTOR DE PERDIDAS	41.77%