



UNIVERSIDAD TÉCNICA DEL NORTE

**FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS CARRERA
DE INGENIERÍA INDUSTRIAL**

**TRABAJO DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERO INDUSTRIAL**

TEMA:

**MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE ENERGÍA
ELÉCTRICA DE EMELNORTE S.A - IBARRA APLICANDO REDES
NEURONALES ARTIFICIALES.**

AUTOR: MORILLO TARAPUES DANIEL FERNANDO

DIRECTOR: ING. YAKCLEEM MONTERO SANTOS MSC.

IBARRA – ECUADOR

2020

UNIVERSIDAD TÉCNICA DEL NORTE
BIBLIOTECA UNIVERSITARIA
AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA
UNIVERSIDAD TÉCNICA DEL NORTE

IDENTIFICACIÓN DE LA OBRA.

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
CÉDULA DE IDENTIDAD:	DE	040196100-8	
APELLIDOS Y NOMBRES:	Y	MORILLO TARAPUES DANIEL FERNANDO	
DIRECCIÓN:	GUAYAS ENTRE ISLA FERNANDINA Y SANTA ISABEL		
EMAIL:	dfmorillot@utn.edu.ec		
TELÉFONO FIJO:		TELÉFONO MÓVIL:	0999260469
DATOS DE LA OBRA			
TÍTULO:	MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA DE EMELNORTE S.A - IBARRA APLICANDO REDES NEURONALES ARTIFICIALES.		
AUTOR (ES):	MORILLO TARAPUES DANIEL FERNANDO		
FECHA: AAAAMMDD			
SÓLO PARA TRABAJOS DE GRADO			
PROGRAMA:	<input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO		
TITULO POR EL QUE OPTA:	INGENIERO INDUSTRIAL		
ASESOR /DIRECTOR:	ING. YAKCLEEM MONTERO SANTOS MSC.		

**UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA INDUSTRIAL**

CONSTANCIAS

El autor (es) manifiesta (n) que la obra de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es (son) el (los) titular (es) de los derechos patrimoniales, por lo que asume (n) la responsabilidad sobre el contenido de la misma y saldrá (n) en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 12 días del mes de octubre de 2020



.....
Nombre: Daniel Fernando Morillo Tarapues
Cédula: 040196100-8

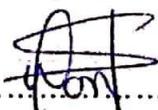
**UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA INDUSTRIAL**

CERTIFICACIÓN

Ing. Montero Santos Yakcleem MSc., director del Trabajo de Grado desarrollado por el señor estudiante Morillo Tarapues Daniel Fernando.

CERTIFICA

Que, el proyecto de Trabajo de Grado Titulado "MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA DE EMELNORTE S.A - IBARRA APLICANDO REDES NEURONALES ARTIFICIALES". ha sido elaborado en su totalidad por el señor estudiante Morillo Tarapues Daniel Fernando bajo mi dirección para la obtención del título de Ingeniero Industrial. Luego de ser revisado, considero que se encuentra concluido y cumple con las exigencias y requisitos académicos de la Facultad de Ingeniería en Ciencias Aplicadas, Carrera de Ingeniería Industrial, autorizo su presentación y defensa para que pueda ser juzgado por el tribunal correspondiente.



.....
Ing. Yakcleem Montero Santos MSc.

DIRECTOR DE TESIS

UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA INDUSTRIAL

DEDICATORIA

*Principalmente este logro académico se lo dedico a **Dios**, por ser mi sustento y ayuda diaria.*

TODO SE LO DEBO A ÉL, 2 Corintios 5:18.

*A mis padres **Jorge y Lourdes**, no hay forma de describir su amor incondicional y todo el esfuerzo y los sacrificios que hicieron para que no me falte nada y pueda llegar hasta aquí, han sido y siempre serán mi inspiración, sin su guía, dirección, corrección y consejo no lo podría haber logrado. Con su ejemplo, me han mostrado el camino para seguir adelante, le doy gracias a Dios por sus vidas y por ese regalo maravilloso que me hizo al tenerlos como padres. HONRA A TU PADRE Y A TU MADRE, Éxodo 20:12.*

*A mi hermano **Santiago**, por ser una guía y un ejemplo de dedicación y esfuerzo, te admiré, te admiro y te admiraré por tu rectitud y nobleza. A mi hermana **Patricia**, por darme siempre su apoyo y consejo, por enseñarme que no importa la situación que pasemos siempre vendrá algo mejor y a mi hermana **Liliana**, por su nobleza e inmenso amor que no podría describir ni comprender siempre velaré por ti, así como tu haz velado y cuidado por mi desde la niñez.*

EL QUE NO AMA A SU HERMANO NO PUEDE AMAR A DIOS, 1 Juan 4:20.

DANIEL FERNANDO MORILLO TARAPUES

UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA INDUSTRIAL

AGRADECIMIENTO

*A la **Universidad Técnica del Norte**, por abrir sus puertas y disponer de cada uno de sus recursos para mi crecimiento académico, a la **Facultad de Ingeniería en Ciencias Aplicadas** por su exigencia y rigurosidad en la formación y a la carrera de **Ingeniería Industrial** por darme los lineamientos necesarios para la vida profesional.*

*A **EMELNORTE S.A.-Ibarra**, por permitirme desarrollar mi propuesta y proveer de cada uno de los insumos necesarios para la misma, de forma específica a la Dirección de Planificación-Estudios Eléctricos a los ingenieros Omar Chacón y Diego Rivera.*

*Al **Ing. Yakcleem Montero**, que me guío siendo mi tutor para finalizar este trabajo y al **Ing. Leandro Lorente**, que me direccionó al inicio de la investigación. Gracias por su amistad, enseñanzas y conocimientos en esta etapa de formación académica.*

*A cada uno de los **profesores** de la carrera de **Ingeniería Industrial**, por compartir sus conocimientos y enseñarnos siempre que antes de ser un buen profesional, debemos ser buenos seres humanos.*

*A cada uno de mis **mentores** espirituales **P. Samuel, P. Yoan, P. Kurtis** y **P. Néstor**, cada uno han aportado a mi vida enseñanzas y principios que han marcado mi mente y corazón.*
Filipenses 1:3-4.

*A mis amigos **Roberth** y **Ronnie**, por estar en las buenas y las malas. Mejor son dos que uno, porque si cayeren el uno levantará a su compañero. Eclesiastés 4:9-12.*

DANIEL FERNANDO MORILLO TARAPUES

ÍNDICE

ÍNDICE DE CONTENIDOS

IDENTIFICACIÓN DE LA OBRA.....	ii
CONSTANCIAS.....	iii
CERTIFICACIÓN.....	iv
DEDICATORIA.....	v
AGRADECIMIENTO.....	vi
ÍNDICE.....	vii
RESUMEN.....	xiv
ABSTRACT.....	xv
CAPÍTULO I. GENERALIDADES.....	1
1.1. Objetivos.....	1
1.1.1 Objetivo General.....	1
1.1.2 Objetivos Específicos.....	1
1.2 Problema.....	1
1.3 Justificación.....	2
1.4 Metodología.....	4
1.4.1 Métodos de pronóstico de demanda.....	5
1.4.2 Técnicas.....	5
1.4.3 Herramientas.....	5
1.4.4 Metodología bibliográfica.....	5
1.4.5 Metodología descriptiva.....	6
1.5 Alcance.....	7
CAPITULO II. MARCO TEÓRICO.....	8
2.1 Pronóstico de la demanda de energía eléctrica (PDEE).....	8
2.1.1 Demanda de energía.....	10
2.1.2 Horizontes de tiempo.....	11
2.1.3 Factores que influyen en la demanda.....	12
2.1.4 Selección de datos.....	14
2.1.5 Variable.....	14
2.1.6 Métodos de PDEE.....	14
2.1.6.1 Métricas de evaluación de métodos de pronóstico.....	16
2.2 Redes Neuronales Artificiales (RNA).....	19
2.2.1 Fundamentos biológicos.....	19
2.2.2 Características de una red neuronal.....	20
2.2.3 Topología.....	21

2.2.4	Clasificación de las redes neuronales.....	22
2.2.5	Categorías de aplicación	23
2.3	Redes neuronales artificiales aplicadas a pronósticos.....	24
2.3.1	Proceso de pronóstico de la demanda de energía eléctrica	24
2.3.2	Análisis de series de tiempo.....	25
2.3.3	Características de las series de tiempo	25
2.3.4	Modelos de pronóstico.....	26
2.4	MATLAB.....	27
2.4.1	Características	29
2.4.2	Funciones	30
2.4.3	Ventajas.....	31
2.4.4	Redes neuronales en Matlab	31
2.4.5	Red neuronal tipo Feedforward (Pre-alimentada).....	32
2.4.6	Red neuronal tipo Feedback (Re-alimentada)	33
2.4.7	Red neuronal tipo Back Propagation (Retro-alimentación / BP)	34
2.4.8	Red neuronal tipo Recurrente (RNN).....	34
2.4.9	Red neuronal tipo Long short-term memory (LSTM).....	35
CAPITULO III. DIAGNÓSTICO DEL PROCESO DE PRONÓSTICO		37
3.1	Plan Maestro de Energía Nacional	37
3.1.1	Transformación y situación actual del sector eléctrico	37
3.1.2	Demanda eléctrica.....	38
3.1.3	Plan de expansión de la distribución.....	40
3.1.4	Análisis económico financiero.....	42
3.2	Empresa Eléctrica Regional Norte S.A. Ibarra.....	43
3.2.1	Generalidades.....	44
3.2.2	Estatuto orgánico.....	47
3.2.3	Nivel estratégico	49
3.3	Proceso de pronóstico actual	49
3.3.1	Elementos.....	49
3.3.2	Pronóstico	52
CAPÍTULO IV. DESARROLLO DEL MODELO PARA EL PRONÓSTICO		58
4.1	Diseño del modelo.....	58
4.1.1	Selección de variables.....	59
4.1.2	Recolección de datos.....	59
4.1.3	Pre-procesamiento.....	60
4.1.4	Conjunto de entrenamiento, validación y prueba.....	62
4.1.5	Arquitectura de la red neuronal.....	63
4.1.6	Criterios de evaluación.....	66

4.1.7 Entrenamiento	67
4.2 Aplicación	69
4.2.1 Subestación La Carolina	70
4.2.2 Subestación Ajaví	71
4.2.3 Subestación Otavalo.....	72
CAPÍTULO V. ANÁLISIS DE RESULTADOS.....	74
5.1 Interpretación de resultados	74
5.1.1 Métricas de evaluación.....	74
5.1.2 Comportamiento	76
CONCLUSIONES	79
RECOMENDACIONES	80
BIBLIOGRAFÍA.....	81

ÍNDICE DE FIGURAS

Figura 1. Método de Diseño de Modelos de Pronóstico con Redes Neuronales Artificiales.	5
Figura 2: Factores que influyen en el pronóstico de la demanda de energía eléctrica	12
Figura 3: Clasificación general de métodos de pronóstico de energía eléctrica.....	15
Figura 4: Comparación entre una neurona biológica y una neurona artificial	19
Figura 5: Red neuronal artificial.	20
Figura 6: Estructura de una red neuronal artificial.....	22
Figura 7: Tipos red neuronal artificial según su entrada	22
Figura 8: Características de una serie de tiempo.....	26
Figura 9: Estructura de un modelo de pronóstico mediante redes neuronales artificiales ...	27
Figura 10: Bloques para crear RNA en Simulink.....	32
Figura 11. Red neuronal tipo Feedforward	33
Figura 12. Red neuronal tipo Feedback	33
Figura 13. Red neuronal tipo Recurrente – Capa oculta	34
Figura 14. Red neuronal tipo LSTM	35
Figura 15. Demanda mensual de energía	38
Figura 16. Proyección de la demanda de potencia - Caso Base.....	39
Figura 17. Proyección de la demanda de energía - Caso Base.....	39
Figura 18. Proyección de la demanda de energía - Caso Base.....	41
Figura 19. Evolución del Costo Medio de Distribución y Energía - Caso Base.	42
Figura 20: Ubicación geográfica de EmelNorte S.A. Ibarra	44
Figura 21: Organigrama estructural	48
Figura 22: Serie de tiempo de demanda anual de energía eléctrica	56
Figura 23: Coeficientes de auto-correlación de la demanda anual de energía eléctrica.....	56
Figura 24: Selección de los datos.....	61
Figura 25: Entrenamiento, validación y prueba	62
Figura 26: Arquitectura de la red	64
Figura 27: Algoritmo de entrenamiento	65
Figura 28: Algoritmo de entrenamiento.....	66
Figura 29: Regresión	67
Figura 30: Entrenamiento.....	68
Figura 31: Previsión-Comportamiento La Carolina.....	76
Figura 32: Previsión-Comportamiento Ajavi.....	77
Figura 33: Previsión-Comportamiento Otavalo	78

ÍNDICE DE TABLAS

Tabla 1. Variables del pronóstico de la demanda de energía eléctrica.....	14
Tabla 2. Funciones de pre y post procesamiento.....	30
Tabla 3. Subestaciones de distribución	50
Tabla 4. Características técnicas de la demanda de energía eléctrica	50
Tabla 5. Puntos de entrega de las subestaciones	51
Tabla 6. Pronóstico por subestaciones	52
Tabla 7. Descripción de la función.....	55
Tabla 8. Subestaciones de distribución	60
Tabla 9. Estructura de datos técnicos	61
Tabla 10. Previsión S. La Carolina	70
Tabla 11. Previsión S. Ajaví.....	71
Tabla 12. Previsión S. Otavalo.....	73
Tabla 13. Métricas de evaluación.....	74

ANEXOS

Anexo 1: Unifilar de distribución de EMELNORTE S.A.....	85
Anexo 2: Demanda.....	86
Anexo 2.1 Demanda de energía eléctrica-2016.....	86
Anexo 2.2 Demanda de energía eléctrica-2017.....	87
Anexo 2.3 Demanda de energía eléctrica-2018.....	88
Anexo 2.4 Demanda de energía eléctrica-2019.....	89
Anexo 3. Entrenamiento de la red neuronal.....	90
Anexo 3.1 Subestación La Carolina.....	90
Anexo 3.2 Subestación Ajaví.....	90
Anexo 3.3 Subestación Alpachaca.....	91
Anexo 3.4 Subestación Atuntaqui.....	92
Anexo 3.5 Subestación Cayambe.....	93
Anexo 3.6 Subestación Chota.....	94
Anexo 3.7 Subestación Cotacachi.....	95
Anexo 3.8 Subestación El Ángel.....	96
Anexo 3.9 Subestación El Retorno.....	97
Anexo 3.10 Subestación La Esperanza.....	98
Anexo 3.11 Subestación Otavalo.....	99
Anexo 3.12 Subestación San Agustín.....	100
Anexo 3.13 Subestación San Gabriel.....	101
Anexo 3.14 Subestación San Vicente.....	102
Anexo 3.15 Subestación Tulcán.....	103
Anexo 4. Pronósticos por subestación.....	104
Anexo 4.1 Subestación La Carolina.....	104
Anexo 4.2 Subestación Ajaví.....	105
Anexo 4.3 Subestación Alpachaca.....	106
Anexo 4.4 Subestación Atuntaqui.....	107
Anexo 4.5 Subestación Cayambe.....	108
Anexo 4.6 Subestación Chota.....	109
Anexo 4.7 Subestación Cotacachi.....	110
Anexo 4.8 Subestación El Ángel.....	111
Anexo 4.9 Subestación El Retorno.....	112
Anexo 4.10 Subestación La Esperanza.....	113
Anexo 4.11 Subestación Otavalo.....	114
Anexo 4.12 Subestación San Agustín.....	115
Anexo 4.13 Subestación San Gabriel.....	116

Anexo 4.14 Subestación San Vicente	117
Anexo 4.15 Subestación Tulcán.....	118
Anexo 5. Comportamiento Previsión	119
Anexo 5.1 Previsión MATLAB	119
Anexo 5.2 Previsión RSTUDIO.....	119
Anexo 5.2 Previsión IBM SPSS.....	120

RESUMEN

Este trabajo de investigación presenta el diseño y aplicación de un modelo para el pronóstico de demanda de energía eléctrica mediante la utilización de redes neuronales artificiales en el software MATLAB ® y sus herramientas Toolbox/Neural Network Time Series. El garantizar una adecuada distribución de energía eléctrica se vuelve indispensable, esto requiere que las previsiones realizadas por la dirección de planificación cuenten con un grado de dispersión mínimo. La toma de decisiones de la organización se sustenta en los resultados generados, por lo cual su importancia. Al desarrollar y aplicar el modelo, se hace uso de herramientas como SPSS e IBM SPSS para poder comparar las previsiones en función de métricas como el MSE y R, y así, validar y sustentar la selección del modelo que presente aquellos resultados que se ajustan más al comportamiento real de la empresa. MATLAB ® generó los resultados más consecuentes con el objetivo, cabe mencionar que se utilizó el algoritmo de regulación Bayesiana para el entrenamiento de los datos técnicos de entrada, mejorando considerablemente los resultados obtenidos en comparación con los métodos convencionales considerados.

ABSTRACT

This research work presents the design and application of a model for the forecast of electrical energy demand using artificial neural networks in the MATLAB ® software and its Toolbox / Neural Network Time Series tools. Ensuring an adequate distribution of electrical energy becomes essential. This requires that the forecasts made by the planning department have a minimum degree of dispersion. The organization's decision making is based on the generated, results which is why its importance. When the developing and applying model, tools such as SPSS and IBM SPSS are applied to be able to compare the forecasts based on metrics such as MSE and R. Thus, validate and support the selection of the model that presents those results that fit more to the actual behavior of the company. MATLAB ® generated the most consistent results with the objective, it is worth mentioning that the Bayesian regulation algorithm was used for training the technical input data, considerably improving the results obtained in comparison with the considered conventional methods.

CAPÍTULO I. GENERALIDADES

1.1. Objetivos

1.1.1 Objetivo General

Desarrollar un modelo para el pronóstico de la demanda de energía eléctrica de la empresa EMELNORTE S.A – Ibarra aplicando Redes Neuronales Artificiales que garantice la operación eficiente y segura de la distribución eléctrica.

1.1.2 Objetivos Específicos

1. Establecer las bases teóricas de la investigación y la aplicación de Redes Neuronales Artificiales en el pronóstico de la demanda de energía eléctrica.
2. Diagnosticar la situación actual del proceso de pronóstico de la demanda de energía eléctrica de la empresa aplicando diferentes técnicas de investigación.
3. Desarrollar el modelo de pronóstico de la demanda de energía eléctrica con el empleo de Redes Neuronales Artificiales.
4. Realizar un análisis de los resultados obtenidos a partir del desarrollo del pronóstico de la demanda de energía eléctrica.

1.2 Problema

La Empresa Eléctrica Regional del Norte de Ibarra siendo una entidad de carácter mixto, brinda el servicio público de distribución de energía eléctrica y alumbrado general, con principios tales como calidad, calidez, responsabilidad social y ambiental a la población del área de cobertura. Además, cuenta con métodos de pronóstico en su red de distribución.

En la planificación a mediano o largo plazo existen variables que tienen un comportamiento incierto, por lo cual los criterios de planificación se amplían y forman problemas al buscar satisfacer la demanda de energía eléctrica en zonas urbanas y rurales.

Sin embargo, la inadecuada predicción de la demanda de electricidad es un problema. Se presentan varios escenarios negativos por la incertidumbre generada en la planificación, lo cual puede incidir en el incremento del costo operativo, disminución del nivel de servicio, deficiencia en la red de distribución, pérdidas en el flujo de potencia y desabastecimiento de insumos.

De forma general, si la distribución de energía no es suficiente para satisfacer la demanda del consumidor, la oferta se tornará irregular y si hay un exceso de generación, la empresa como tal tendrá que soportar pérdidas. Esto se convierte en el principal reto, es decir, la construcción de un modelo que permita una predicción más eficiente y precisa para una adecuada toma de decisiones.

El modelo de predicción con el uso de redes neuronales artificiales permite reducir el margen de incertidumbre existente en el pronóstico de la demanda de energía eléctrica, y de esta forma generar resultados óptimos, que permitan suplir los requerimientos de los clientes.

1.3 Justificación

La investigación tendrá como resultado final el desarrollo de un modelo para el pronóstico de la demanda de energía eléctrica de la empresa EMELNORTE S.A-Ibarra, el mismo permitirá efectivizar la toma de decisiones en la red de distribución de la zona, optimizando los recursos de tal forma que logre suplir la demanda con un mínimo costo de operación.

Según (Al-Alawi & Islam, 1996) el pronóstico de demanda de electricidad puede ser definido como: “el tipo de demanda eléctrica que una empresa puede esperar de un número específico de consumidores en un período específico de tiempo”, dicha demanda puede ser tanto de potencia como de energía.

La importancia de poseer un modelo de pronóstico adecuado para cubrir la demanda de estas dos variables, es indispensable, autores como (Islam & Al-Alawi, 1997) y (Hagan & Behr, 1987) concluyen que los pronósticos son una parte integral de los sistemas de potencia y ya que generan pronósticos precisos que permiten conocer la demanda de energía eléctrica a mediano plazo.

En la actualidad las demandas de electricidad dependen de una serie de factores que tienden a ser complejos ya que presentan características no lineales, algunos métodos de pronóstico utilizan inteligencia artificial, algoritmos como redes neuronales, lógica difusa y sistemas expertos (Feinberg & Genethliou, 2005).

El pronóstico es una parte indispensable para la planificación y la adecuada operatividad del sistema de distribución de energía eléctrica. Las redes neuronales artificiales han ayudado a reducir los problemas asociados con los modelos de predicción convencionales y tienen la ventaja de aprender directamente de los datos históricos (Swaroop & Abdulqader, 2012).

Es necesario y útil predecir la demanda de electricidad, teniendo como finalidad la reducción del costo existente entre la oferta y la demanda. Debido a que la tasa de crecimiento poblacional de las últimas décadas aumenta de una forma rápida, el consumo de energía eléctrica también se ve afectado por un incremento en dependencia a esta variable (Yong et al., 2017).

El desarrollo de un modelo que garantice la electricidad de la red pública se relaciona directamente con la capacidad de conexión con los sistemas de infraestructura. Logrando así, garantizar el derecho a la vivienda digna, adecuada y segura como lo establece el Objetivo 1, Eje 1, del Plan Nacional de Desarrollo 2017-2021-Toda una Vida (SENPLADES, 2017).

La programación en tiempo real de la generación de electricidad necesita un modelado preciso de la previsión de demanda de electricidad para un rango de plazos de entrega. Con el fin de capturar mejor las características no lineales y no estacionarias y los ciclos estacionales de los datos futuros de la demanda de electricidad (Jiang, Li, Lu, & Zhang).

La aplicación de las redes neuronales artificiales para el pronóstico de carga a corto plazo se ha convertido en un foco de investigación, ya que han demostrado ser adecuadas para resolver los problemas no lineales (Hu, Wen, Zeng, & Huang, 2017).

Las redes neuronales artificiales son lo suficientemente flexibles, como herramienta de modelado, mostrando un alto grado de precisión para la predicción de la demanda de electricidad (Tartibu & Kabengele, 2018). Por esto el modelo de pronóstico a desarrollar se podrá adaptar a las diferentes necesidades de las organizaciones que regulan la distribución de energía eléctrica.

Es de total consideración que, en dependencia al campo de aplicación del modelo, se requiere ajustar ciertos parámetros en la estructura que se definirá en la programación de la red neuronal. Además, en las restricciones para el conjunto de variables conocidas en la resolución del sistema.

1.4 Metodología

El enfoque que se va a emplear en el presente anteproyecto de titulación es del tipo cuantitativo. Se fundamenta en el estudio de las bases de datos numéricas de la

distribución de energía eléctrica que se puedan recolectar dentro del contexto de la organización, en la cual se está llevando a cabo el proyecto.

1.4.1 Métodos de pronóstico de demanda

En la Figura 1 se describen los pasos para la aplicación del método para el diseño de modelos de pronóstico con el uso de redes neuronales artificiales, independientemente del campo de aplicación de este.

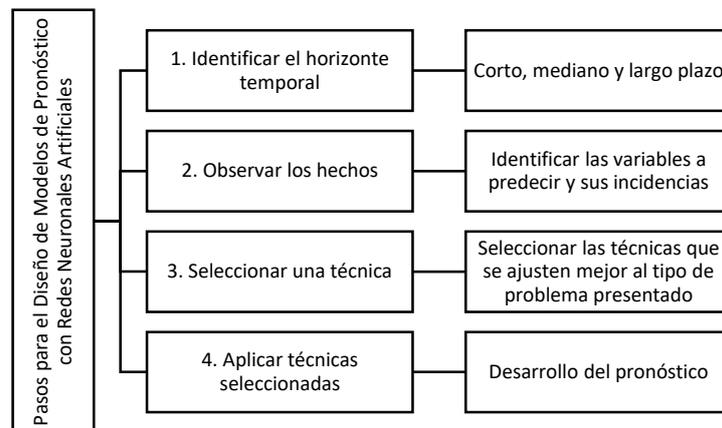


Figura 1. Método de Diseño de Modelos de Pronóstico con Redes Neuronales Artificiales

Fuente: (Siadén & Andrea, 2012)

1.4.2 Técnicas

Redes Neuronales Artificiales

1.4.3 Herramientas

MATLAB

MATLAB Neuronal Network Toolbox

1.4.4 Metodología bibliográfica

El archivo histórico de datos sobre demanda y distribución de energía eléctrica es proporcionado por la empresa EMELNORTE S.A. - Ibarra para el desarrollo del pronóstico.

1.4.5 Metodología descriptiva

Según (Kaastra & Boyd, 1996) la metodología para la aplicación de redes neuronales artificiales consta de los siguientes pasos:

1. Selección de la variable
2. Recolección de datos
3. Pre-procesamiento de los datos
4. Definición del conjunto de Entrenamiento, Validación y Prueba
 - 4.1 Conjunto de Entrenamiento
 - 4.2 Conjunto de Validación
 - 4.3 Conjunto de Prueba
5. Selección de la arquitectura de Redes Neuronales Artificiales
 - 5.1 Número de Neuronas de Entrada
 - 5.2 Número de Capas Ocultas
 - 5.3 Número de Neuronas Ocultas
 - 5.4 Número de Neuronas de Salida
 - 5.5 Función de Transferencia
6. Criterios de Evaluación
7. Entrenamiento de las Redes Neuronales Artificiales
 - 7.1 Número de Iteraciones

7.2 Tasa de Aprendizaje

8. Implementación del Modelo de Redes Neuronales Artificiales

1.5 Alcance

La Empresa Eléctrica Regional del Norte S.A-Ibarra debe conocer la demanda del consumidor para que pueda proveer de energía cercana o exactamente igual a la requerida. Por esto, mediante la aplicación de las redes neuronales artificiales, como técnica singular en la generación del pronóstico se desarrollará un modelo para determinar los requerimientos futuros de electricidad.

El mismo que se obtendrá, mediante el análisis de datos históricos de un mínimo de 3 años de la demanda y distribución de energía eléctrica. No obstante, el tiempo que se considera para la aplicación de la propuesta es de 12 a 24 meses.

La herramienta que se utilizará para el modelamiento es el software MATLAB, ya que permite realizar un análisis en base al nivel de error e incertidumbre de cada uno de los resultados generados por el modelo, de esta forma, logrando identificar la solución más eficiente dentro del análisis de los resultados que se obtendrán en el pronóstico.

Para constatar el rendimiento de los modelos se debe considerar: el porcentaje de error absoluto (MAPE), error cuadrático (R^2), criterio de información bayesiano (BIC), criterio de información Akaike (AIC), error cuadrático medio (MSE), desviación media absoluta (MAD), estacionalidades y tendencias. Considerando que tanto los datos de entrada como los de salida se encuentran expresados en GWh para el caso de compra y KWh en su distribución.

CAPITULO II. MARCO TEÓRICO

Es necesario establecer y definir las bases teóricas del proyecto de investigación con la finalidad de sustentar la construcción científica del modelo y a su vez la aplicación del pronóstico con el uso de redes neuronales artificiales. En cada uno de los acápites se desarrollan los contenidos con un enfoque que parte de lo general hacia lo particular, buscando una estructura equilibrada que precise el avance progresivo de este apartado.

2.1 Pronóstico de la demanda de energía eléctrica (PDEE)

Es necesario para dar cumplimiento al Objetivo 1, Eje 1, del Plan Nacional de Desarrollo 2017-2021-Toda una Vida (SENPLADES, 2017) la presencia y/o aplicación de un modelo de pronóstico que garantice la electricidad de la red pública esto se relaciona directamente con la capacidad de conexión con los sistemas de infraestructura, logrando así, garantizar el derecho a la vivienda digna, adecuada y segura.

La existencia de una regulación sobre “Calidad del Servicio Eléctrico de Distribución” marca los lineamientos para que la empresa garantice el proporcionar un servicio con los niveles de calidad establecidos los cuales están establecidos por el Consejo Nacional de Electricidad (CONELEC).

Además, como establece la Ley Orgánica del Servicio público de Energía Eléctrica, en su Título 1, Artículo 1.- Objeto y alcance de la ley el principal objetivo es planificar, ejecutar, regular, controlar y administrar el servicio público de energía eléctrica (ARCONEL, 2015). Conforme al Título 1, Artículo 2.- Objetivos específicos de la ley, Literales 2, 4, 6, 7, 8 y 9 de la misma ley las actividades de generación, transmisión, distribución y comercialización son los pilares para lograr cumplir eficientemente con la prestación del servicio.

Sin embargo, la Agencia de Regulación y Control de Electricidad (ARCONEL) no ha provisto de un modelo estandarizado que permita asegurar la igualdad y uso generalizado de los servicios e instalaciones de transmisión y distribución dentro de la estimación de la demanda. Por lo tanto, se puede evidenciar deficiencias en la sustentabilidad económica y financiera del sector eléctrico. Teniendo resultados de estimación con altos niveles de dispersión.

En los últimos años se ha generado un creciente interés en proporcionar modelos de predicción precisos para el consumo de energía eléctrica. La optimización del consumo de energía es un punto crítico para mejorar la confiabilidad de la red eléctrica y evitar desajustes de la oferta y la demanda (Ulkareem, Awadh, & Alasady, 2018).

Los pronósticos son un procedimiento ordenado que permite definir de forma cuantitativa la demanda futura, esto es de vital importancia para la organización por lo que debe procurarse que dicha información sea lo más exacta posible, considerando siempre un nivel de incertidumbre.

La realización del pronóstico tiene como principal objetivo el identificar los acontecimientos que tengan la mayor probabilidad de ocurrir y así reducir el nivel de dispersión en los resultados obtenidos para la distribución y toma de decisiones del sistema. La energía es un recurso que debe utilizarse de manera efectiva y eficiente (Karunathilake & Nagahamulla, 2017).

Se debe considerar diferentes variables para satisfacer la carga futura como los posibles proyectos de nuevas centrales de generación y redes de transmisión asociadas. El pronóstico de demanda puede referirse a la potencia pico, a la energía total demandada o al comportamiento de la curva de carga.

El pronóstico de la demanda de energía eléctrica puede ser analizado y desarrollado desde dos perspectivas (Ramírez, 2013):

Energía: La cual utiliza demanda de electricidad en unidades de Watts-hora (Wh).

Potencia: Considerada la demanda eléctrica que se mide unidades de Watts (W), usualmente se realizan proyecciones de potencia horaria-energía en el orden de los Mega Watts hora (MWh).

Es indispensable considerar cada una de las unidades de medida empleadas para generar el pronóstico de energía eléctrica, debido que dependiendo de estas variables se define y maneja el costo ya sea por venta y compra del servicio.

2.1.1 Demanda de energía

Es la cantidad de potencia que un consumidor requiere en un periodo de tiempo. Al momento de establecer una demanda es indispensable indicar el intervalo de esta. Puede ser expresada en kVA, kW, kVAR, A, entre otras (Enriquez, 2010).

Los sistemas eléctricos no son sistemas que presentan flexibilidad, es decir, para lograr cubrir la demanda es necesario contar con un estimado del valor demandado por dicho sistema y de esta forma poder cumplir con las exigencias del servicio.

Existen diferentes elementos que son parte del estudio de la demanda de energía eléctrica, tales como, la carga máxima la cual se considera como la carga mayor existente en un sistema o instalación, en un período de trabajo previamente establecido.

La carga de instalada, por otro lado, es definida por la suma de potencias nominales de cada uno de los aparatos y equipos de consumo que se encuentran conectados a un sistema o a parte de él.

Así también elementos como la demanda coincidente y no coincidente deben ser consideradas. La primera, suma varias cargas en un momento determinado, la siguiente suma la demanda máxima de cada usuario sin importar que ocurran o no al mismo tiempo.

2.1.2 Horizontes de tiempo

Dependiendo del período de tiempo que se adopte en el análisis se podría considerar dentro del pronóstico tres horizontes de predicción: corto, mediano y largo plazo. Cabe recalcar que esto es dependiente del tipo de análisis a ejecutarse y a su vez de la complejidad en la modelación.

Pronóstico de corto plazo

Los modelos de redes neuronales artificiales se emplean para predicciones a corto plazo, no obstante, se debe considerar variables como la naturaleza de los datos, el horizonte temporal y el costo computacional. (Marugán, Márquez, Perez, & Ruiz-Hernández, 2018).

Este pronóstico tiene una duración de hasta un año, pero es generalmente menos de tres meses. Se utiliza para planear la compra, el programar trabajo, niveles de mano de obra, asignaciones del trabajo, y los niveles de la producción, es decir es un insumo requerido por los encargados de la planificación diaria de operación.

Pronóstico de mediano plazo

Este pronóstico tiene una duración a partir de los tres meses hasta los tres años. Es útil en la planificación de ventas, producción y el presupuesto y en el análisis de algunos planes de operación.

Pronóstico de largo plazo

Cuando el horizonte de pronóstico es largo para proporcionar un buen resultado es necesario tener muchas muestras de entrada, debido a que la mayoría de los enfoques que se utilizan son métodos híbridos (Marugán et al., 2018).

Este pronóstico generalmente tiene una duración de los tres años en adelante, los pronósticos de largo alcance se utilizan en planificación de productos nuevos, los gastos en inversión de capital, localización o extensión de la facilidad, e investigación y desarrollo.

2.1.3 Factores que influyen en la demanda

La demanda de energía eléctrica de un sistema de potencia es influenciada por varios factores tales como: variables meteorológicas, socioeconómicas y demográficas. Por esto, el número de las variables que se requieren depende de la naturaleza del pronóstico, por lo tanto, estas variables deben ser seleccionadas cuidadosamente. La demanda de energía eléctrica está sujeta a distintas variaciones, esto es debido a un gran número de factores los cuales inciden directamente en su proyección como se muestra en la Figura 2 (Momoh, 2017).

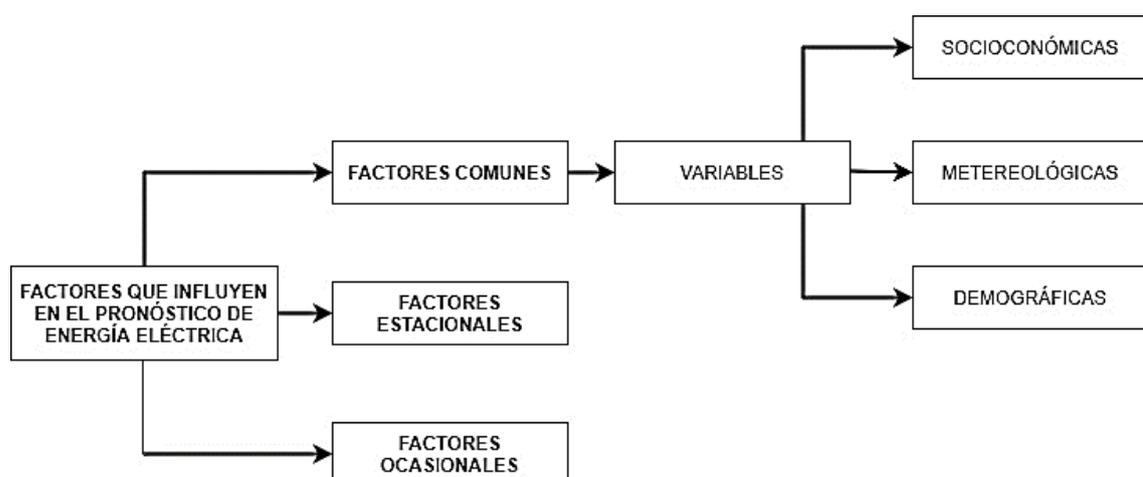


Figura 2: Factores que influyen en el pronóstico de la demanda de energía eléctrica

Fuente: Basado en (Al-Alawi & Islam, 1996; Gellings, 1992; Gonen, 1986; Islam & Al-Alawi, 1997; Momoh, 2017).

Predecir la demanda de energía es un tema vital para cumplir con la estrategia futura de cualquier país (Al-bayaty, Mohammed, Ghareeb, & Wang, 2019). Debido a esto, es indispensable que antes de un proceso de distribución se conozcan los factores que pueden incidir en la variación de la potencia de energía eléctrica.

La Figura 2 nos muestra cómo se puede clasificar los factores presentes dentro del pronóstico de la demanda de energía eléctrica dentro de tres grupos que abarcan las variables que tienden a tener un impacto más concurrente dentro de la generación de resultados.

Factores comunes

Algunos de estos factores reflejan cambios importantes en su consumo y en su producción. Variables como la temperatura, la humedad, la velocidad del viento, el número de consumidores conectados, el crecimiento de la población y el producto interno bruto entre otros se encuentran en esta clasificación

Factores ocasionales

Son aquellos que pueden o no provocar alguna influencia sobre el efecto de la carga dentro del sistema de distribución. Variables como festivales, acontecimientos religiosos, huelgas y demás se pueden incluir en esta clasificación.

Factores estacionales

La demanda puede ser analizada considerando también periodos y/o etapas. La demanda existente en el día es distinta a la existente en la noche, así mismo, la demanda relativa de los días laborables se diferencia lo que se requiere los fines de semana.

2.1.4 Selección de datos

En la realización del pronóstico de la demanda de energía eléctrica, la información histórica juega un papel crítico y decisivo, ya que el éxito o fracaso de un método de pronóstico depende básicamente de la disponibilidad de los datos, tales como los factores comunes y los ocasionales.

La relación entre la demanda y los factores comunes, ocasionales y estacionales mencionados es por su naturaleza no lineal. Por lo cual, cualquier método de pronóstico buscará de cierta manera, una relación de cualquier variable (temperatura, humedad, tiempo, celebraciones, crecimiento o déficit económico entre otras) con la demanda de energía eléctrica.

2.1.5 Variable

El interés en la predicción involucra emplear como entradas datos técnicos es decir el consumo eléctrico en lugar de fundamentales, de acuerdo con los objetivos planteados en la investigación. En la Tabla 1 se muestran las principales características de la variable de entrada que se utilizará para el diseño del modelo con el uso de redes neuronales artificiales.

Tabla 1. Variables del pronóstico de la demanda de energía eléctrica

Variable para pronosticar	Demanda de energía eléctrica de la empresa EmelNorte S.A-Ibarra
Tipo de variable	Cuantitativa
Frecuencia	Mensual
Unidad	KiloWatt (kW)

Fuente: Autor

2.1.6 Métodos de PDEE

El objetivo principal del sistema eléctrico de potencia es suministrar el servicio de energía de manera continua, segura y confiable, por esta razón debe adaptarse

continuamente a la demanda. No obstante, en algunas organizaciones no se cuenta con modelos definidos para poder identificar valores reales o aproximados de demanda generada por la población.

Todos los tipos y técnicas de pronósticos predicen con datos existentes de las bases de datos recogidas por las organizaciones. A pesar de esto al no contar con herramientas estandarizadas para realizar este proceso, se presenta un incremento en el nivel de incertidumbre al obtener los resultados de salida luego de haber generado un pronóstico. Es por esto que la Figura 3 muestra una clasificación general de los métodos utilizados de forma más común para poder realizar el desarrollo de una predicción de la demanda de energía eléctrica.



Figura 3: Clasificación general de métodos de pronóstico de energía eléctrica

Fuente: Autor

En los métodos cuantitativos la idea principal es la de minimizar el error del pronóstico, dentro de estos métodos se cuentan con las series de tiempo, modelos de regresión y nuevos métodos. Por otro lado, en los métodos cualitativos se practican con mayor frecuencia los métodos de exploración y los normativos. Tales métodos se requieren a menudo cuando los datos históricos no están disponibles o dependen de las opiniones de los expertos.

2.1.6.1 Métricas de evaluación de métodos de pronóstico

De acuerdo con (Zavala Hepp, 2015), para realizar una evaluación al desempeño del pronóstico (\tilde{X}), se utilizarán medidas que comparan la predicción con el valor real. Para una serie $(X_n)_t^n = 1$ de media \bar{X} , se tienen las siguientes medidas de error:

Error Absoluto Medio (MAE)

Indicador que entrega el promedio del error absoluto del pronóstico en toda la serie.

$$(1) \quad MAE = \frac{1}{n} \sum_{t=1}^T |X_t - \tilde{X}|$$

Error Porcentual Absoluto Medio (MAPE)

Indicador que entrega en promedio el error absoluto en el pronóstico de toda la serie, como porcentaje de la serie original.

$$(2) \quad MAPE = \frac{1}{n} \sum_{t=1}^T \left| \frac{X_t - \tilde{X}}{X_t} \right|$$

Error Porcentual Absoluto Medio Ponderado (Weighted MAPE)

Equivalente a calcular un error MAPE, ponderado por el tamaño del error relativo al valor original. El MAPE pondera cada error en el pronóstico por igual, independiente del nivel de los valores de la serie que se está pronosticando. WMAPE pondera cada error dependiendo del nivel de valores de la serie. WMAPE compensa el tamaño del error relativo al porcentaje del valor original.

$$(3) \quad WMAPE = \frac{\sum_{t=1}^T |X_t - \tilde{X}| * X_t * 100}{n \sum_{t=1}^T X_t}$$

Error Cuadrático Medio (MSE)

Se define como la media de e_t^2 , es decir el promedio de los errores entre el estimador y lo que se estima al cuadrado. Es necesario mencionar que y_t hace mención al valor real y por otro lado \hat{y}_t se define como el pronóstico. Logrando de esta forma identificar el valor existente entre estos dos valores, el cual de cierta forma determina el grado de dispersión en los resultados.

$$(4) \quad MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

Coefficiente de Correlación (R^2)

Mide el porcentaje del cambio de una variable dependiente explicado por el cambio de las variables independientes, a través de un modelo de regresión lineal múltiple. Entre más cercano a uno mejor es el ajuste (Anderson, Sweeney, Williams, Roa, & Álvarez, 2001).

$$(5) \quad R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Errores Bayesianos

En el enfoque bayesiano un parámetro es una variable aleatoria y la inferencia respecto a sus posibles valores se obtiene aplicando el cálculo de probabilidades (teorema de Bayes) para obtener la distribución del parámetro condicionada a la información disponible (Peña, 2013).

Si se desea un estimador puntual, se deberá tomar la media o la moda de dicha distribución; si se desea un intervalo de confianza es necesario identificar y seleccionar la zona que encierre una probabilidad fijada en dicha distribución.

En consecuencia, una vez obtenida la distribución de probabilidad del parámetro, los problemas habituales de inferencia quedan resueltos con la distribución a posteriori de manera automática y simple (Peña, 2013).

El enfoque bayesiano tiene dos ventajas principales:

Es un enfoque que se sustenta en la generalidad y coherencia: conceptualmente todos los problemas de estimación se resuelven con los principios del cálculo de probabilidades.

Su capacidad de incorporar información a priori con respecto al parámetro adicional a la muestra le da una fortaleza significativa, no obstante, exige siempre representar la información inicial respecto al vector de parámetros mediante una distribución inicial o a priori.

Ponderación BIC (Criterio de Información Bayesiano)

El criterio BIC trata de seleccionar el modelo correcto, con máxima probabilidad a posteriori, y puede demostrarse que es un criterio consistente, de manera que la probabilidad de seleccionar el modelo correcto tiende a uno cuando crece el tamaño muestral (Peña, 2013).

Ponderación AIC (Criterio de Información Akaike)

El criterio AIC no pretende seleccionar el modelo correcto, ya que admite que este modelo verdadero puede no estar entre los estimados, y trata de obtener el modelo que proporcione mejores predicciones entre los existentes.

2.2 Redes Neuronales Artificiales (RNA)

Son un modelo de computación, cuya estructura se compone de capas de nodos conectados. Una red neuronal puede aprender de los datos, de manera que se puede entrenar para que reconozca patrones, clasifique datos y pronostique eventos futuros (Beale, Hagan, & Demuth, 2010; MathWorks, 2020).

Por esto las redes neuronales se han utilizado para aprender estrategias de solución basadas en ejemplos de comportamiento típico de patrones, debido a su gran efectividad en el reconocimiento de estos. Por lo general, se ajustan o entrenan, de tal modo que una entrada articulada es lo que conduce a una salida objetivo de forma específica.

2.2.1 Fundamentos biológicos

Las redes neuronales artificiales son modelos matemáticos no lineales inspirados por el sistema nervioso biológico, que simulan el proceso de aprendizaje del ser humano (Lao, Rivas-Méndez, Pérez-Pravia, & Marrero-Delgado, 2017).

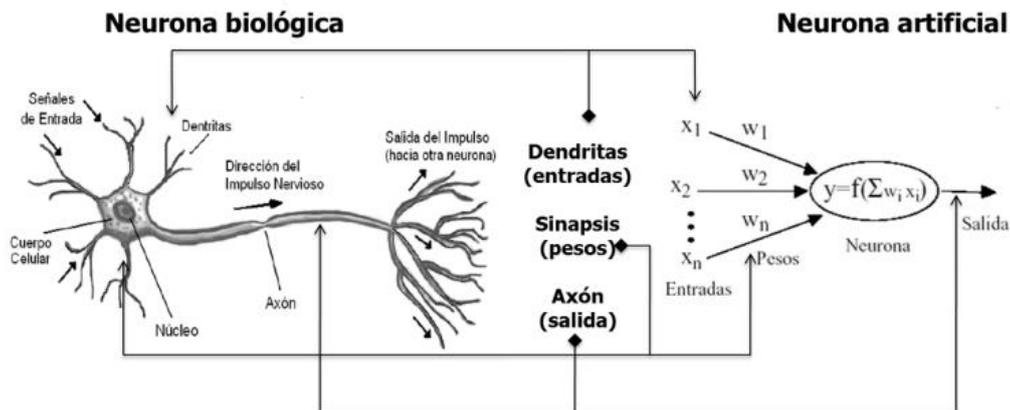


Figura 4: Comparación entre una neurona biológica y una neurona artificial

Fuente: (Lao et al., 2017)

En la Figura 4 se muestra una comparación entre lo que es una red neuronal biológica y una neurona artificial, ambas son redes conectadas masivamente en paralelo de elementos simples y adaptivos. La organización jerárquica presente en una red neuronal

artificial es lo que muestra la interacción existente con los objetos del mundo real, del mismo modo que lo hace el sistema nervioso biológico.

2.2.2 Características de una red neuronal

Una red neuronal artificial es la interconexión de varias neuronas. La Figura 5 muestra una red neuronal estructurada en capas; es una de las estructuras en las cuales se pueden asociar las neuronas. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa y el tipo y número de conexiones entre neuronas (Sanjinés Tudela, 2011)

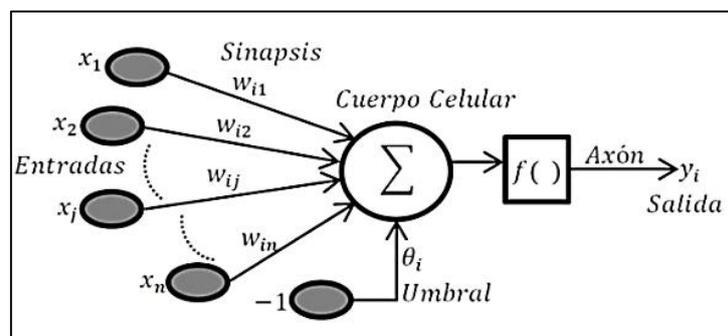


Figura 5: Red neuronal artificial.
Fuente: (Sanjinés Tudela, 2011)

Las entradas X_i representan las señales que provienen de otras neuronas y que son capturadas por las dendritas. Los pesos W_i son la intensidad de la sinapsis que conecta dos neuronas; tanto X_i como W_i son valores reales. θ es la función umbral que la neurona debe superar para activarse; este proceso ocurre biológicamente en el cuerpo de la célula.

Una red neuronal para alcanzar los requerimientos de desempeño del problema basado en muestras representativas pose un algoritmo para ajustar sus pesos es por esto que se lo considera de alto nivel adaptativo, además se señalan puntos importantes que caracterizan estos modelos.

Principalmente es que presenta un conjunto de unidades elementales, cada una de las cuales posee bajas capacidades de procesamiento. A la vez, se puede señalar una densa estructura interconectada que usa enlaces ponderados junto con parámetros libres que deben ser ajustados para satisfacer los requerimientos de desempeño obteniendo de esta forma un alto grado de paralelismo.

2.2.3 Topología

De manera formal (López & Fernández, 2008; Marugán et al., 2018), desarrollan la caracterización de tres tipos de neuronas artificiales. Consiste en la organización y disposición de las neuronas en la red. Las neuronas se agrupan formando capas, que pueden tener muy distintas características.

Neuronas de entrada (Input layer)

Reciben señales desde el entorno; estas entradas provienen generalmente de otros sectores del sistema como archivos de almacenamiento de patrones de aprendizaje.

Neuronas de salida (Hidden layer)

Las unidades de salida envían una señal fuera del sistema una vez finalizado el tratamiento de la información es decir la salida de la red.

Neuronas ocultas (Output layer)

Reciben estímulos y emiten salidas dentro del sistema, sin mantener contacto alguno con el exterior. En ellas se lleva a cabo el procesamiento básico de la información, estableciendo la representación interna de ésta. Una estructura típica corresponde al perceptrón multicapa (MLP), que se muestra en la Figura 6 (Jiménez, Muñoz, & Márquez, 2017; Marugán et al., 2018).

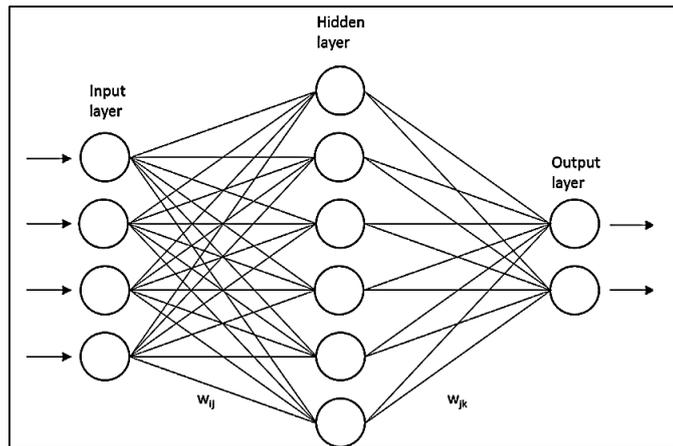


Figura 6: Estructura de una red neuronal artificial
Fuente: (Marugán et al., 2018; MathWorks, 2020)

2.2.4 Clasificación de las redes neuronales

La Figura 7 muestra los tipos de redes neuronales considerando sus entradas, en este caso se ha clasificado en entradas binarias y continuas. Buscando de esta forma atribuir características específicas en cada uno de estos grupos.

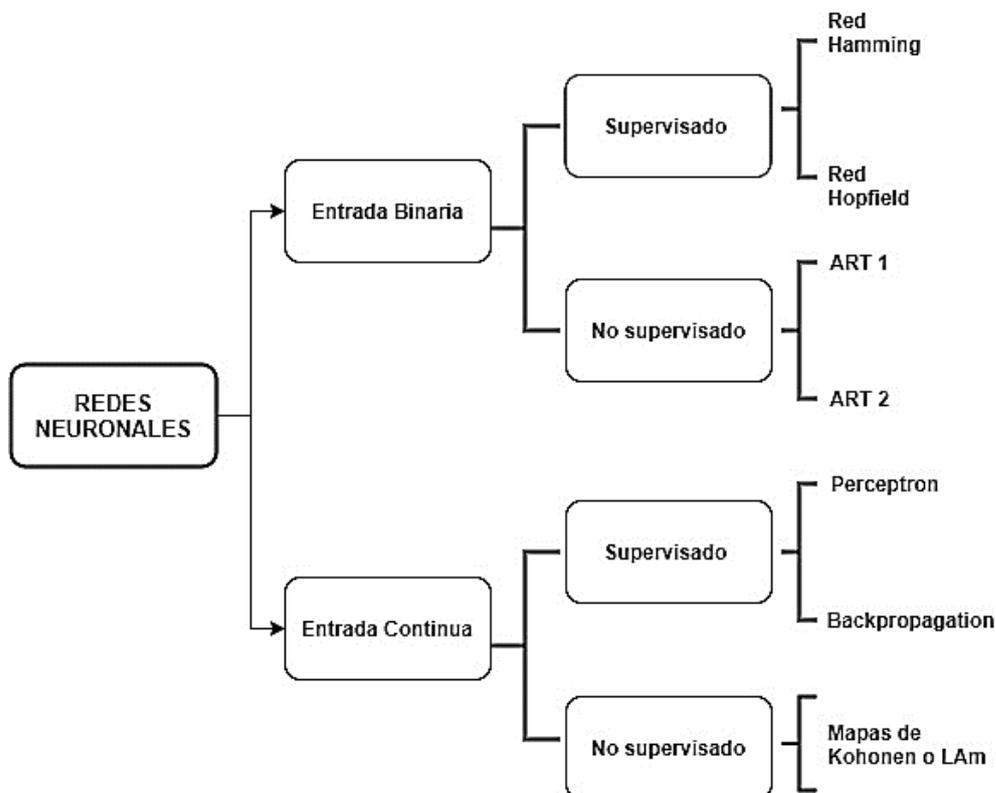


Figura 7: Tipos red neuronal artificial según su entrada
Fuente: Basado en (Acevedo Arenas, 2004)

Es necesario destacar que las redes neuronales no supervisadas se entrenan permitiendo que la red neuronal se autoajuste continuamente a las nuevas entradas. Se emplean para inferir información a partir de conjuntos de datos que constan de datos de entrada sin respuestas etiquetadas. Se pueden utilizar para descubrir distribuciones naturales, categorías y relaciones entre categorías en los datos (MathWorks, 2020).

2.2.5 Categorías de aplicación

Las redes neuronales artificiales son útiles para resolver una amplia gama de problemas de siete categorías (Basheer & Hajmeer, 2000; MathWorks, 2020):

Clasificación de patrones: Las redes neuronales artificiales pueden detectar patrones en un conjunto de datos a través del aprendizaje supervisado.

Agrupación: Las similitudes o diferencias de datos se identifican mediante un aprendizaje no supervisado. La red asignará datos similares al mismo grupo o clúster.

Aproximación de funciones: Las redes neuronales artificiales se pueden aplicar a problemas donde un modelo teórico no se puede aplicar. Pueden aproximar los datos de entrada a una función con cierto grado de detalle.

Pronóstico: Una red neuronal puede ser entrenada por series de tiempo para obtener una predicción del comportamiento futuro.

Optimización: Una solución que maximiza o minimiza una función sujeta a diferentes restricciones se pueden encontrar.

Asociación: Se puede emplear una red asociativa para reconstruir datos corruptos al desarrollar un patrón asociativo.

Control: Es posible determinar las entradas que causarán el comportamiento deseado del sistema.

2.3 Redes neuronales artificiales aplicadas a pronósticos

Su comportamiento está definido por la forma en que se conectan sus elementos individuales, así como por la importancia o ponderación de dichas conexiones (MathWorks, 2020). Las compañías eléctricas pronostican la carga de sus redes con precisión para garantizar la fiabilidad y optimizar la eficiencia de los generadores eléctricos que utilizan.

2.3.1 Proceso de pronóstico de la demanda de energía eléctrica

Existen varios métodos por los cuales se puede generar un pronóstico, autores como (Gupta & Saraswat, 2020) utilizan métodos de Machine Learning, juntamente con esto utilizan Redes Neuronales Artificiales, la Regresión Lineal Múltiple (MLP) y Máquina de Soporte Vectorial (SVM). Por otro lado (Panapongpakorn & Banjerdpongchai, 2019), en el análisis de series de tiempo aplicaron modelos como ARIMA, SARIMA y LSTM. Para finalmente comparar la eficiencia de cada uno de los modelos.

Los modelos híbridos también son usados al momento de pronosticar, Neural Network Auto-Regressive (NNAR) es una combinación entre ARIMA y Redes Neuronales. Sin dejar de lado las Redes Bayesianas las cuales superan a las populares herramientas de análisis de regresión (Goubko, Kuznetsov, Neznanov, & Ignatov, 2017).

Por otro lado, de igual forma que los demás investigadores (Al-bayat et al., 2019) emplea para su estudio técnicas de Machine Learning (ML), dos algoritmos basados en Redes Neuronales Artificiales (RNA) y Árboles de Decisión (DTs). Obteniendo las tasas de error más bajas con el uso de RNA.

Además, de acuerdo con las investigaciones de (Hu et al., 2017; Ma & Zhai, 2019; Panapongpakorn & Banjerdpongchai, 2019; Sulandari, Lee, & Rodrigues, 2020; Tartibu & Kabengele, 2018; Yong et al., 2017) los modelos que integran o hacen uso de las redes neuronales artificiales, destacan de forma significativa, debido a que estos se adaptan a los diferentes requerimientos de las organizaciones de energía eléctrica.

De esta forma evidenciando que cada uno de los modelos investigados y aplicados por estos autores, mostraron un rendimiento eficiente al momento de ser evaluados con métricas o indicadores estadísticos. En algunos casos, se pudieron observar mejoras incluso hasta de un 83% tomando como referencia parámetros como el RMSE.

2.3.2 Análisis de series de tiempo

Independientemente del modelo a implementar para la generación del pronóstico de la demanda de energía eléctrica, es fundamental conocer el comportamiento de los datos, por lo que el análisis de la serie de tiempo se vuelve un punto crítico para la generación de resultados eficientes (Subba Rao, 2018).

Una serie de tiempo es característica debido a que se integra por observaciones sucesivas, es decir, las observaciones no son independientes. Al realizar el tratamiento de los datos hay que considerar el orden en que son ingresadas. Cada valor registrado de la variable en estudio, le corresponde un valor en el tiempo como segunda variable por lo que las variables de salida están en función de estas.

2.3.3 Características de las series de tiempo

En el análisis de series de tiempo de datos, una tentación inmediata consiste en intentar explicar o contabilizar el comportamiento de las series. Para analizarlas, lo que se necesita es un enfoque sistemático. La descomposición clásica es un método que se basa en la suposición de que se pueden descomponer en componentes como tendencia, ciclo,

estacionalidad e irregularidad (Hanke & Wichern, 2014). En la Figura 8 se muestran las principales características de una serie de tiempo.

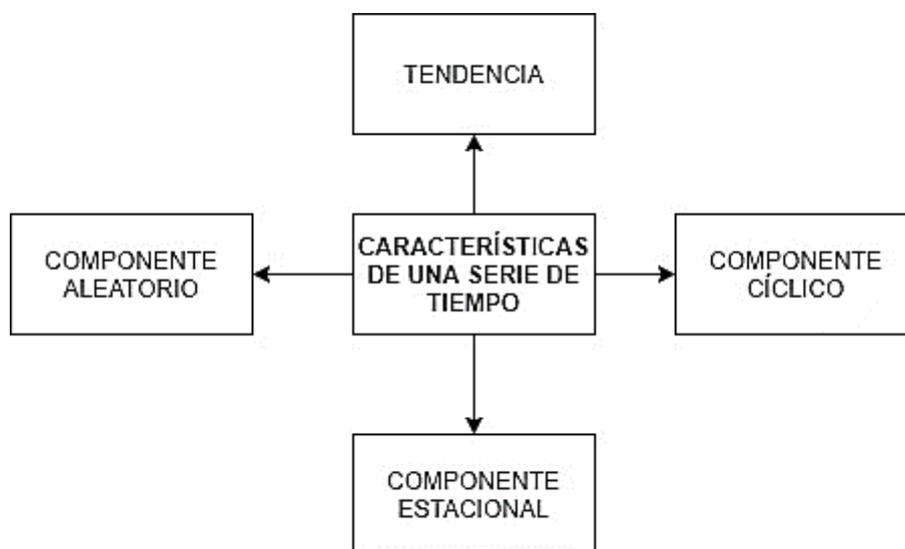


Figura 8: Características de una serie de tiempo

Fuente: Basado en (Acevedo Arenas, 2004; Hanke & Wichern, 2014)

La tendencia de una serie de tiempo es el componente de largo plazo que representa crecimiento o disminución en la serie sobre un periodo amplio. El componente cíclico es la fluctuación en forma de onda alrededor de la tendencia. El componente estacional es un patrón de cambio que se repite así mismo año tras año. Y por último el aleatorio mide la variabilidad de las series de tiempo después de retirar los otros componentes.

2.3.4 Modelos de pronóstico

Existen varias clasificaciones cuando hablamos sobre métodos. Los métodos predictivos son aquellos que intentan predecir valores futuros, dentro de estos tenemos: la regresión y series temporales, clasificación y las redes neuronales.

Mientras, que los métodos descriptivos se centran a encontrar patrones que describen la información y como asociarla. En la Figura 9 se muestra una estructura para la elaboración de un modelo de pronóstico con el uso de redes neuronales artificiales.

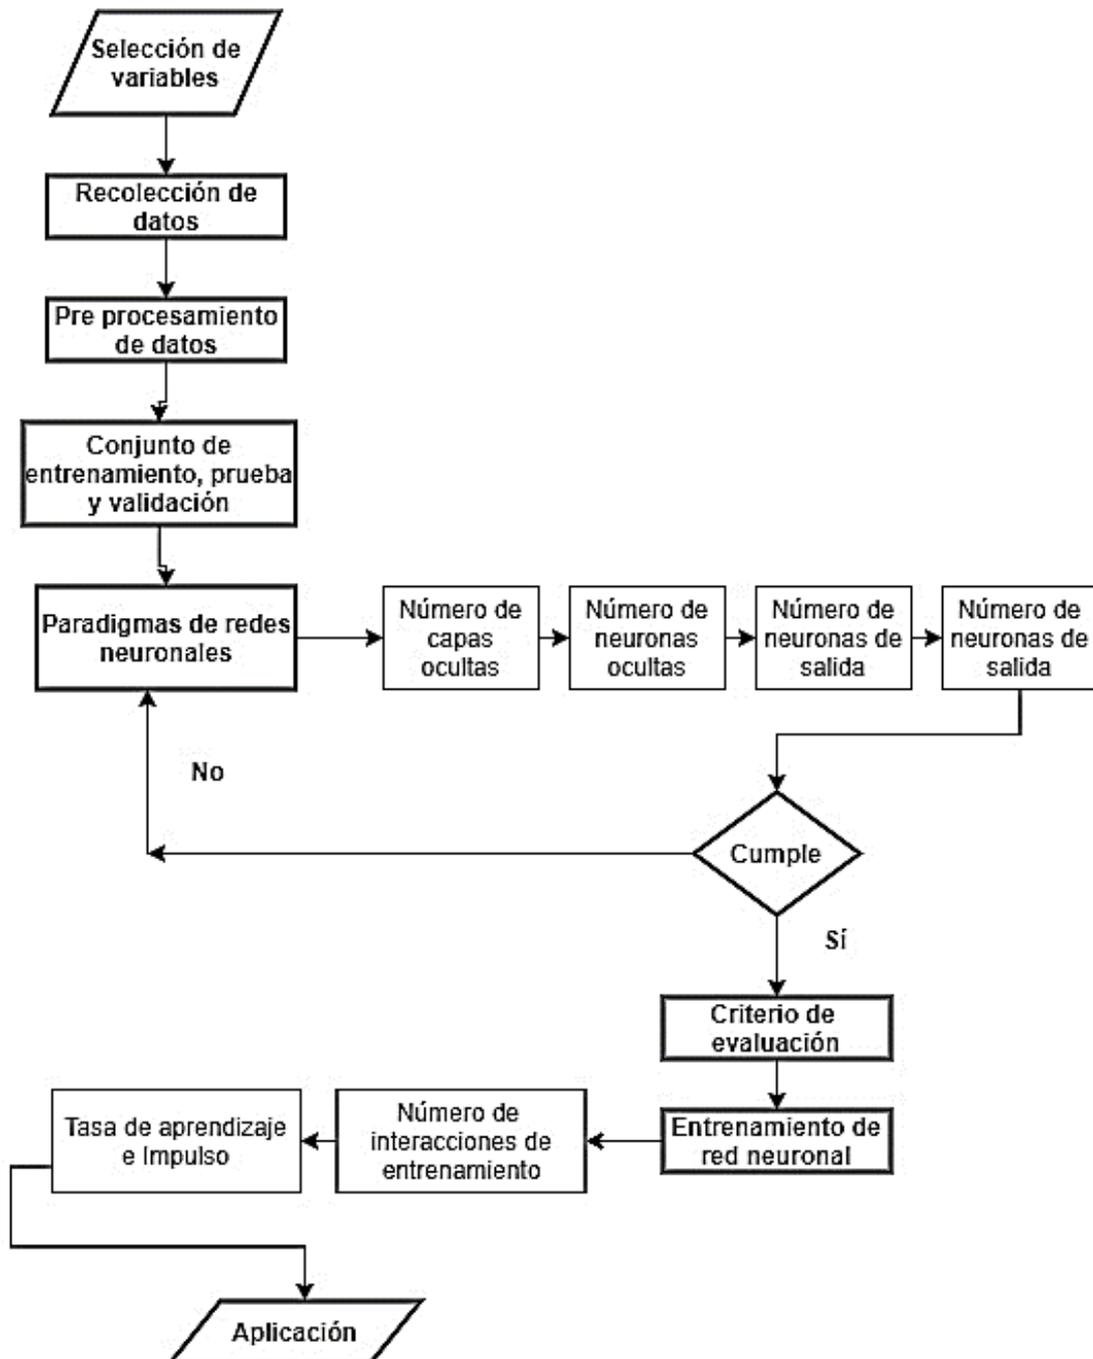


Figura 9: Estructura de un modelo de pronóstico mediante redes neuronales artificiales
Fuente: Basado en (MathWorks, 2020)

2.4 MATLAB

En la actualidad existen varios lenguajes de programación que permiten la obtención de resultados favorables al ser utilizados como herramienta dentro de un trabajo de investigación independientemente del área en la cual sean aplicados.

Python, sin duda ha ido creciendo significativamente dentro de distintos campos de aplicación, debido a que es un lenguaje de programación interpretativo multipropósito (Dewi & Chen, 2019). Por lo cual esto le permite soportar la programación imperativa y, en menor medida, la programación funcional.

RStudio, es un entorno de desarrollo integrado para el lenguaje de programación R, dedicado a la computación estadística y gráficos. Investigaciones recientes como la de (Pawar, Jape, & Mathew, 2019) utiliza este entorno para generar la predicción de energía eólica empleando un modelo SVM.

Por otro lado, (Matsila & Bokoro, 2018) emplea RStudio para examinar la forma del patrón de serie temporal de los datos históricos, posteriormente, en un intento de pronosticar datos de series futuras incluye un modelo ARIMA estacional de Box-Jenkins.

MATLAB nace como una solución a la necesidad de mejores y más poderosas herramientas de cálculo para resolver problemas complejos. Presenta cajas de herramientas especializadas para trabajar con aprendizaje automatizado, permitiendo la generación modelos de redes neuronales con eficiencia y consistencia.

A su vez, logra integrar los resultados en sus aplicaciones existentes. Además, automatiza la implementación de sus modelos de redes neuronales en sistemas de empresa, clusters, nubes y dispositivos (MathWorks, 2020).

En investigaciones como las de (Ethmane, Maaroufi, Mahmoud, & Yahfdhou, 2018; Sheikh & Unde, 2012; Uniejewski, Nowotarski, & Weron, 2018; Vinagre, Pinto, Ramos, Vale, & Corchado, 2016; Weron, 2017) se evidencia que el uso de la herramienta MATLAB permite producir resultados prácticos fácilmente, debido a su mayor flexibilidad en cuanto al cómputo numérico, la graficación, la prueba y exploración.

Por esto, para el desarrollo del presente trabajo de investigación se utilizará como herramienta principal MATLAB para la generación del pronóstico debido a las ventajas que presenta como un entorno dinámico para la previsión de demanda de energía eléctrica (MathWorks, 2020). Sin dejar de lado las demás herramientas, ya que se puede generar un punto comparativo durante el desarrollo de este proyecto.

2.4.1 Características

La manipulación y reducción de datos hace que el entorno de desarrollo de MATLAB tenga un rango amplio y completo para el procesamiento y análisis de datos, incluyendo La manipulación de arreglos multidimensionales, incluyendo reticulación e interpolación de datos, están también disponibles debido a las numerosas operaciones presentes en la herramienta.

Sus gráficos descriptivos le permiten visualizar al instante señales, superficies paramétricas, imágenes y más. Por esto se los considera con propósitos generales y de aplicación específica. Están integrados con las capacidades de análisis, de modo que permite mostrar gráficamente cualquier conjunto de datos sin editar, ecuación o resultado funcional.

Se puede ingresar y extraer datos de forma rápida, Las funciones están disponibles para leer y escribir archivos de datos formateados en MATLAB, llamados archivos MAT. Funciones adicionales ejecutan programas de todo nivel de programación permitiéndole trabajar con todos los formatos de datos.

Los métodos usados comúnmente para análisis de datos multidimensional generalizados se encuentran incorporados, junto con esto, existen interfaces gráficas fáciles de usar, específicas para aplicaciones, la línea de comando es interactiva y

herramientas de programación estructuradas le permiten elegir el mejor camino para el análisis de datos.

2.4.2 Funciones

Las entradas de red pueden tener funciones de procesamiento asociadas. Las funciones de procesamiento transforman los datos de entrada del usuario en un formulario que es más fácil o eficiente para una red.

Las salidas de red también pueden tener funciones de procesamiento asociadas. Estas se utilizan para transformar los vectores de destino proporcionados para el uso de la red. Se procesan de forma inversa utilizando las mismas funciones para producir datos de salida con las mismas características que los objetivos originales proporcionados por el usuario.

En la mayoría de los casos, no se necesita usar las funciones directamente, ya que los pasos de pre-procesamiento se convierten en parte del objeto de red. Cuando se realiza una simulación o entrenamiento de red, el pre-procesamiento y el post-procesamiento se realizará automáticamente. La Tabla 2 muestra las funciones de pre-procesamiento y post-procesamiento más comunes.

Tabla 2. Funciones de pre y post procesamiento

FUNCIÓN	ALGORITMO
mapminmax	Normalizar entradas / objetivos para caer en el rango $[-1, 1]$
mapstd	Normalizar entradas / objetivos para tener media cero y varianza de unidad
processpca	Extraer componentes principales del vector de entrada
fixunknowns	Procesar entradas desconocidas
removeconstantrows	Eliminar entradas / objetivos que son constantes

Fuente: Basado en (MathWorks, 2020)

2.4.3 Ventajas

Este entorno permite el uso de comandos como familias en áreas específicas, las cuales se las define como Toolboxes. Los cuales son grupos de comandos de MATLAB, que mejoran el ambiente de trabajo para poder resolver problemas en diferentes áreas de la ciencia y la ingeniería.

En los Toolboxes especiales se incluyen comandos para las áreas de: Procesamiento Digital de Señales Sistemas de Control, Redes Neuronales, Lógica Difusa, Wavelets, entre otras. Esto le permiten mezclar libremente computación simbólica y numérica una sintaxis simple e intuitiva.

Provee acceso inmediato a las características gráficas especializadas requeridas cada una de las áreas de aplicación. Su potente graficación orientada, le permite graficar los resultados de su análisis, incorporar gráficos en sus modelos de sistemas, y crear resultados de presentación.

2.4.4 Redes neuronales en Matlab

Deep Learning Toolbox proporciona un conjunto de bloques para crear redes neuronales superficiales en Simulink. Todos los bloques son compatibles con Simulink Code. Además, se puede crear y entrenar las redes y generar automáticamente bloques de simulación de red para usarlos con Simulink. Este enfoque también permite ver las redes de forma gráfica. (MathWorks, 2020). En la Figura 10 se muestra la clasificación de las funciones existentes dentro de esta herramienta.

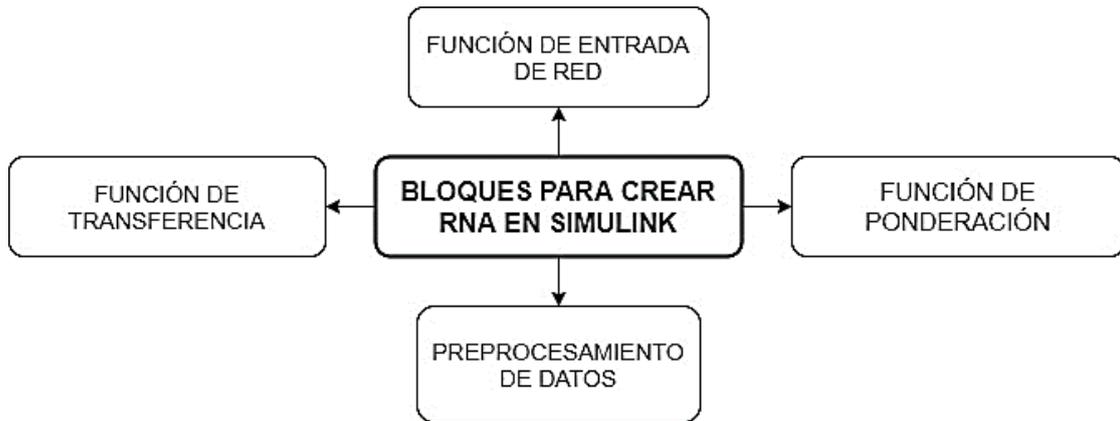


Figura 10: Bloques para crear RNA en Simulink
Fuente: Basado en (MathWorks, 2020)

Los bloques de función de transferencia admiten un vector de entrada de red y generan un vector de salida correspondiente. Los bloques de función de entrada de red admiten cualquier número de vectores de entrada ponderados, vectores de salida de capa de ponderación y vectores de tendencias, y devuelven un vector de entrada de red.

Los bloques de función de ponderación aplican un vector de ponderación neuronal a un vector de entrada o de salida de capa, con la finalidad de obtener un valor de entrada ponderado para una neurona. Finalmente, los bloques de pre-procesamiento de datos son aquellos que asignan datos de entrada y salida dentro de los rangos más adecuados para que la red neuronal los gestione directamente.

2.4.5 Red neuronal tipo Feedforward (Pre-alimentada)

El tipo de red Feedforward es cuando todas las neuronas de una capa reciben señales de entrada a la red, y envían señales de salida a una capa posterior, se está ante una red de conexiones hacia adelante, como se observa en la Figura 11, y que además realiza un aprendizaje supervisado.

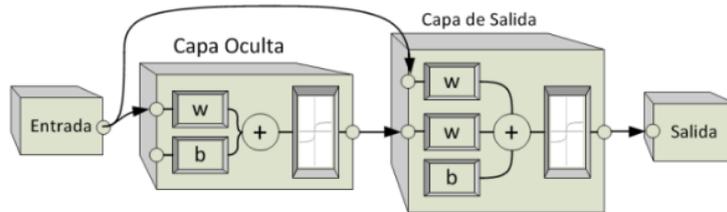


Figura 11. Red neuronal tipo Feedforward

Fuente: (Beale et al., 2010)

La primera capa tiene pesos provenientes de la entrada, cada capa posterior tiene un peso proveniente de la capa anterior. Todas las capas tienen predecesoras, la última capa es la salida de la red. La adaptación se logra con los procesos de aprendizaje que actualiza los pesos con la función de activación.

2.4.6 Red neuronal tipo Feedback (Re-alimentada)

Esta red se presenta cuando existen conexiones hacia atrás es decir las salidas de las neuronas de capas posteriores se conectan a las entradas de las capas anteriores como se muestra en la Figura 12.

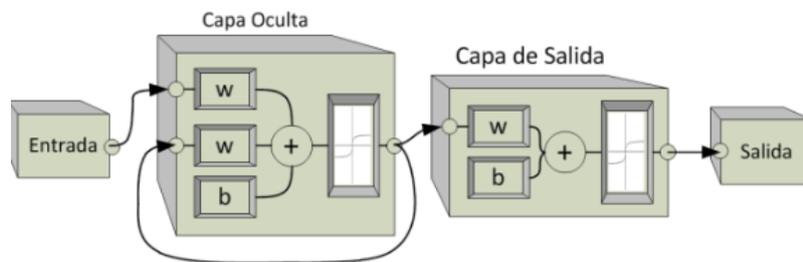


Figura 12. Red neuronal tipo Feedback

Fuente: (Beale et al., 2010)

La primera capa tiene pesos provenientes de la entrada, cada capa posterior tiene un peso proveniente de la capa anterior. Todas las capas excepto la última tienen un peso recurrente, las capas existentes en el modelo tienen predecesoras. La última capa es la salida de la red y al igual que la red anterior también realiza un aprendizaje supervisado.

2.4.7 Red neuronal tipo Back Propagation (Retro-alimentación / BP)

Una red neuronal BP es una estructura de red feed-forward (retro-alimentada) de varios niveles, que utiliza el valor de error entre la entrada y la salida para entrenar el proceso de retro-propagación (Wang, Chen, Quan, Wang, & He, 2020).

2.4.8 Red neuronal tipo Recurrente (RNN)

Son una de las arquitecturas de red fundamentales a partir de las cuales se construyen otras arquitecturas consideradas de aprendizaje profundo. Cuando se contrasta una red de múltiples capas típica y una red recurrente se observa que en lugar de conexiones, que se presentan plenamente adelantadas, una red recurrente puede tener conexiones que se realicen en capas anteriores o inclusive pueden generarse en la misma capa (Zhu, Li, Wu, & Jiang, 2015).

Esta retroalimentación permite a las RNN mantener la memoria de entradas pasadas y modelar problemas a tiempo. En la Figura 13 Los elementos Z representan los componentes de retardo de tiempo, esto genera un comportamiento con dinámica no lineal.

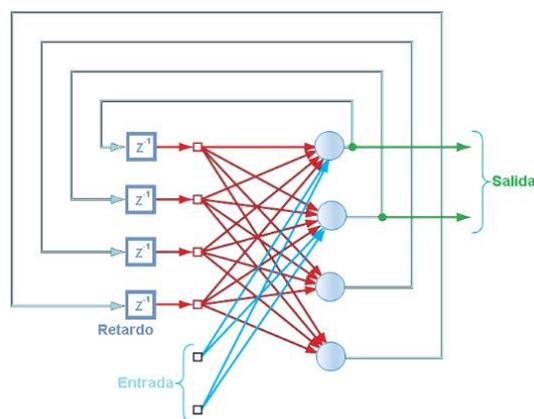


Figura 13. Red neuronal tipo Recurrente – Capa oculta

Fuente: (Su et al., 2019)

Entre los modelos de redes neuronales, la red neuronal recurrente procesa datos mediante bucles de memoria interna y mantiene una estructura de cadena, por esto son

más adecuadas para aprender las características de los datos de series de tiempo (Geem & Roper, 2009). Sin embargo, la estructura profunda en forma de cadena aumenta la dificultad de poder llevar modelos recurrentes hacia modelos que utilicen retro-propagación (Zhu et al., 2015).

2.4.9 Red neuronal tipo Long short-term memory (LSTM)

Este tipo de red hace diferencia a una red neuronal estándar, ya que presenta conexiones de retroalimentación que no solamente pueden procesar puntos de datos individuales sino también secuencias completas de datos (Hochreiter & Schmidhuber, 1997). En la Figura 14 se observa un ejemplo de red neuronal artificial LSTM.

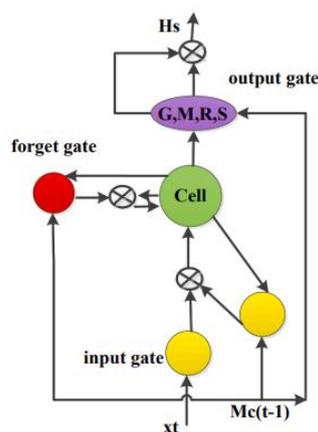


Figura 14. Red neuronal tipo LSTM

Fuente: (Beale et al., 2010; Shahid, Zameer, Mehmood, & Raja, 2020)

La memoria a corto plazo a largo plazo es un tipo de red neuronal recursiva en el tiempo, que es adecuada para procesar y predecir eventos con intervalos relativamente largos y retrasos en series de tiempo (Yu et al., 2019). Muchas aplicaciones basadas en series de tiempo han empleado LSTM, con la finalidad de realizar una predicción incluso del precio de la demanda eléctrica (Peng, Liu, Liu, & Wang, 2018).

Realmente existen muchos modelos que se han sustentado en las redes neuronales artificiales para poder mejorar la precisión de la predicción de energía eléctrica. Incluso, se han desarrollado muchos trabajos de investigación con esta temática, algunos por

ejemplo que fueron mencionados dentro de este capítulo, estos muestran la flexibilidad y el alto nivel de precisión en los resultados obtenidos, sin dejar de lado los modelos convencionales típicamente usados por empresas de este tipo.

El adecuado diseño del modelo depende de forma directa a la consideración de cada uno de los elementos de entrada del mismo, es decir, la información técnica, el reconocimiento de variables, la arquitectura de la red, el algoritmo de entrenamiento, el número de capas ocultas entre otros son pilares esenciales para establecer un modelo eficiente que se ajuste a los requerimientos de la empresa.

Sin duda, la realización del diagnóstico del proceso actual de pronóstico que lleva la organización en el área de estudios eléctricos, para la previsión de demanda de energía eléctrica es parte fundamental de la investigación. Esto permite, sustentar y dar inicio al diseño del modelo que se propondrá, utilizando elementos que se encuentran presentes en los métodos convencionales existentes en la empresa.

CAPITULO III. DIAGNÓSTICO DEL PROCESO DE PRONÓSTICO

Es de suma importancia un análisis que permita levantar una línea base de la situación actual del país, considerando esto, se genera e inicia estos apartados con un diagnóstico del sector eléctrico a nivel nacional, utilizando como principal fuente de información el Plan Maestro de Energía. Es así que, se busca de forma sintetizada evidenciar los modelos de previsión utilizados por empresas eléctricas en todo el país, logrando así, constatar el alto grado de dispersión dentro de los resultados considerados para años futuros.

Por consiguiente, priorizar el diagnóstico del proceso actual de pronóstico de la demanda en EMELNORTE S.A – Ibarra. Debido a que este es el punto de inicio para la realización y desarrollo del Capítulo IV, por lo cual, es necesario identificar los puntos clave y críticos dentro de este proceso. Logrando así, partir de una línea base que engloba todo el universo de distribución eléctrica del país hasta llegar de forma específica a la zona en la cual se desarrolla este proyecto de investigación.

3.1 Plan Maestro de Energía Nacional

3.1.1 Transformación y situación actual del sector eléctrico

En la Figura 15, se presenta la demanda mensual de energía del Sistema Nacional Interconectado (S.N.I), la información que ha sido recopilada hace referencia a las diferentes empresas del sector eléctrico.

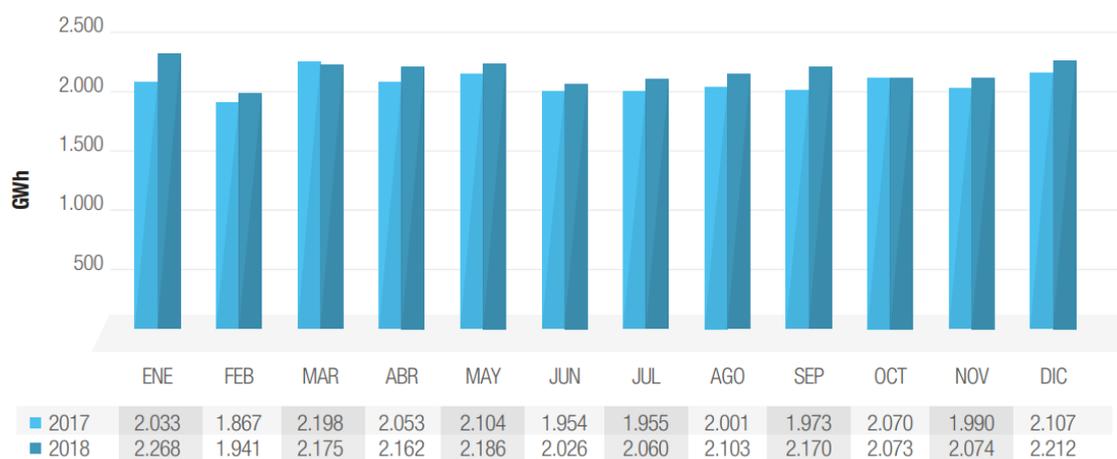


Figura 15. Demanda mensual de energía

Fuente: Plan Maestro de Energía

En los últimos 17 años se ha llevado a cabo distintos proyectos en el sector eléctrico ecuatoriano, encaminados a garantizar el abastecimiento eléctrico. La producción total de energía eléctrica del Ecuador, en 2018, fue de 29.243 GWh. Debido a la inversión realizada en el sector eléctrico, se ha logrado la reducción de pérdidas de energía, la mejora en la calidad del servicio y la modernización de los sistemas técnicos y comerciales, generando condiciones que impulsen a la innovación, y a su vez, creando productividad en cada una de las centrales eléctricas.

3.1.2 Demanda eléctrica

En la Figura 16 y 17 se presenta información de la demanda de potencia eléctrica y de energía desde el año 2001 hasta el año 2018. Para esto, se considera el crecimiento tendencial de la demanda, más las cargas de proyectos de eficiencia energética, transporte, institutos públicos y privados, centros de transferencia tecnológica, empresas de alta tecnología y de desarrollo agroindustrial.

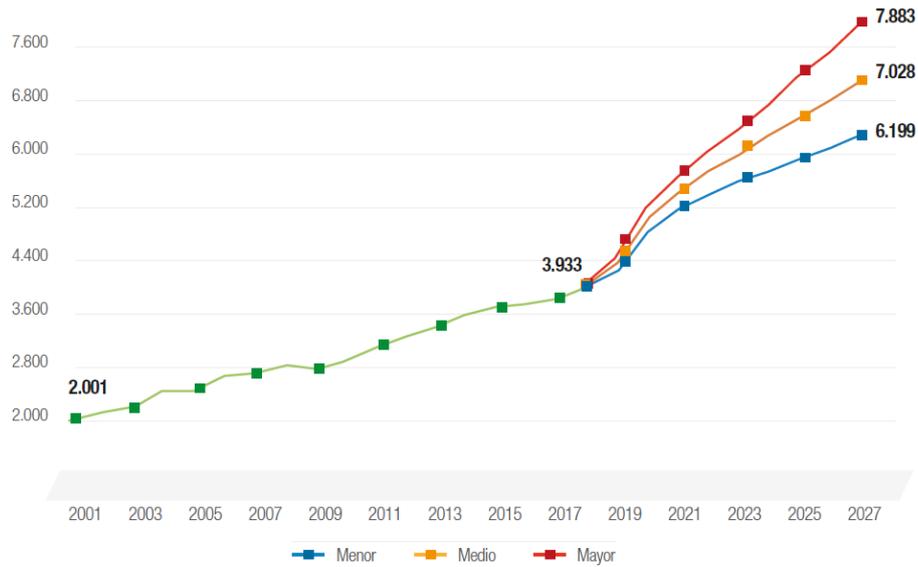


Figura 16. Proyección de la demanda de potencia - Caso Base.

Fuente: Plan Maestro de Energía

Para el periodo de análisis, se observa la evolución de la demanda anual de potencia, con un crecimiento medio del 6,66% en bornes de generación. Por otro lado, la proyección de la demanda de energía, presenta un crecimiento medio del 7,13%, este comportamiento obedece principalmente a las cargas singulares e industriales que se incorporarán al Sistema Nacional Interconectado (S.N.I), a nivel de distribución y de transmisión.

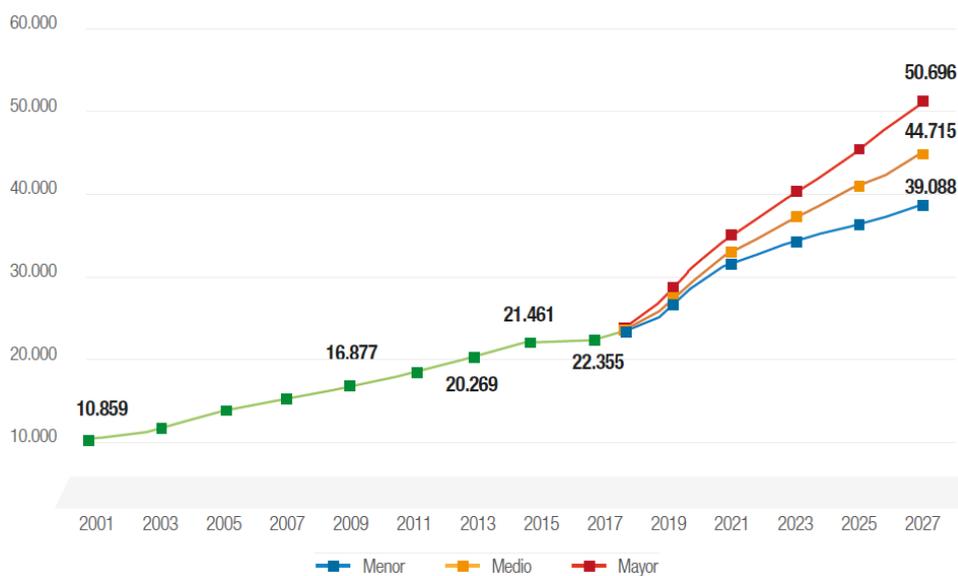


Figura 17. Proyección de la demanda de energía - Caso Base.

Fuente: Plan Maestro de Energía

3.1.3 Plan de expansión de la distribución

Objetivo

Establecer los proyectos y obras que se requieren para la Expansión y Mejora de los Sistemas de Distribución a fin de brindar el servicio público de energía eléctrica con los principios constitucionales de obligatoriedad, generalidad, uniformidad, responsabilidad, universalidad, accesibilidad, regularidad, continuidad, calidad, sostenibilidad ambiental, precaución, prevención y eficiencia, en el período 2018-2027.

Lineamientos

1. Incrementar la Cobertura del Servicio de Energía Eléctrica.
2. Fortalecer los Sistemas de Distribución para asegurar la calidad y confiabilidad del sistema.
3. Cumplir los Planes de Inversión financiados por el Presupuesto General Estado y con recursos propios.
4. Incrementar el nivel de satisfacción al cliente.
5. Reducir el nivel de pérdidas de energía en el sistema de distribución.
6. Incrementar el Servicio de Alumbrado Público, mediante la utilización de la tecnología eficiente.
7. Continuar con la Modernización del modelo de gestión y de los sistemas de información.

Situación actual de la distribución

Las inversiones para el desarrollo del sector eléctrico en la etapa de distribución están orientadas a reforzar y renovar la infraestructura física de sus instalaciones, así como para atender la modernización de la gestión, sustentada en estándares actualizados de las tecnologías de información, comunicación y de la industria eléctrica.

Esto ha permitido disponer de un servicio de energía eléctrica con mejoras en los niveles de eficiencia; y con el compromiso de lograr la sustentabilidad y sostenibilidad del sector eléctrico para cada una de las unidades que conforman el S.N.I. Sin embargo, es necesario considerar los requerimientos económicos para alcanzar las metas establecidas.

Los requerimientos considerados de inversión para el sistema de distribución son de 4.736 millones de dólares, esto permitirá mejorar los índices de pérdidas, calidad del servicio, infraestructura, cobertura, y la gestión propia de las distribuidoras.

Pérdidas

Dentro del plan de mejora de la distribución del sector eléctrico se establece como meta para el año 2027, la reducción de pérdidas a nivel de país del 8,92%, como se muestran en la Figura 18.

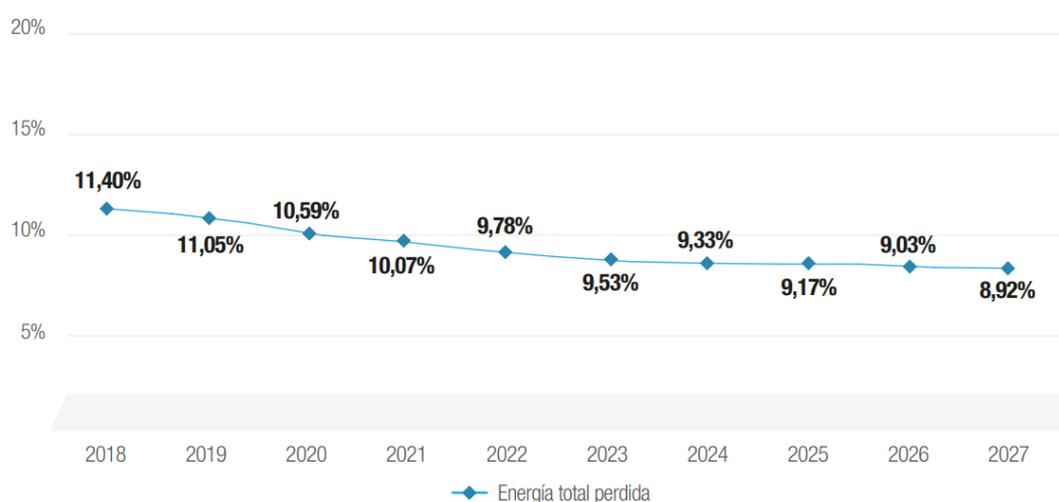


Figura 18. Proyección de la demanda de energía - Caso Base.

Fuente: Plan Maestro de Energía

Durante los últimos 10 años se ha logrado invertir más de doce mil millones de dólares en el sector eléctrico ecuatoriano, con lo cual se ha logrado la reducción de pérdidas de energía, la mejora en la calidad del servicio y la modernización de los sistemas técnicos

y comerciales, generando las condiciones para que florezca la innovación, creando productividad en Ecuador, pasando de ser importadores a exportadores de electricidad.

3.1.4 Análisis económico financiero

El plan de expansión de distribución, busca brindar el servicio de suministro de energía eléctrica a aproximadamente 6,43 millones de clientes regulados en el año 2027, lo que corresponde a una variación del 24% a lo largo del horizonte de tiempo analizado respecto del año 2018. Por lo tanto, se prevé una variación en cuanto a la venta de energía eléctrica de 84.30%, respecto al año 2018.

Se analiza la evolución del costo del servicio eléctrico, para la tarifa aplicada al consumidor final dentro del sector eléctrico, principalmente influenciados por las inversiones del ajuste realizado al Plan Maestro de Electrificación, para el período 2018 – 2027. En el contexto del análisis desarrollado se toma en cuenta la normativa vigente, metodologías internacionales relacionadas a la determinación de los costos del servicio y la evaluación financiera del PME.

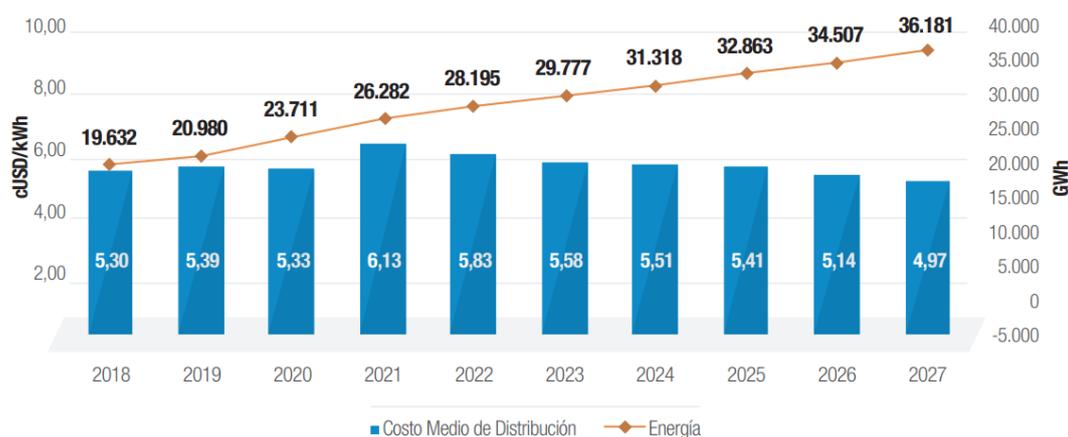


Figura 19. Evolución del Costo Medio de Distribución y Energía - Caso Base.

Fuente: Plan Maestro de Energía

En la Figura 19 se presenta el costo del servicio eléctrico con el cual se determina la tarifa o precio de venta a clientes regulados. Este corresponde a la sumatoria entre la

valoración económica de la producción óptima de energía eléctrica, el transporte por el sistema nacional interconectado hacia los centros de mayor concentración de carga eléctrica, y la entrega y comercialización de la energía eléctrica a los usuarios finales es decir la distribución y comercialización.

3.2 Empresa Eléctrica Regional Norte S.A. Ibarra

La Empresa es parte del Sistema Nacional Interconectado (S.N.I), la misma fue constituida el 25 de noviembre de 1975, con la siguiente información: NOMBRE Y ACCIONISTAS: Se denominó EMPRESA ELECTRICA REGIONAL NORTE “EMELNORTE”, con sus principales accionistas el INECEL y las empresas eléctricas de Ibarra, Montufar y Tulcán (EMELNORTE, 2020).

Es una de las 19 empresas eléctricas nacionales, cuya misión fundamental consiste en la distribución y comercialización de energía eléctrica, en un mercado cautivo, conformado por consumidores industriales, comerciales y residenciales, asentados en las áreas urbanas y rurales de las provincias de Imbabura y Carchi, así como en los cantones de Cayambe y Pedro Moncayo de la provincia de Pichincha y en el cantón Sucumbíos de la provincia del mismo nombre (EMELNORTE, 2020).

En la ciudad de Ibarra, la empresa cuenta con dos instalaciones. Su matriz se localiza específicamente en las calles Juan Manuel Grijalva 654 entre Simón Bolívar y José Joaquín de Olmedo. Además, cuentan con una central en la calle Eusebio Borrero y Manuel de la Chica Narváez. En la Figura 20, se muestra de forma gráfica la localización de estas.

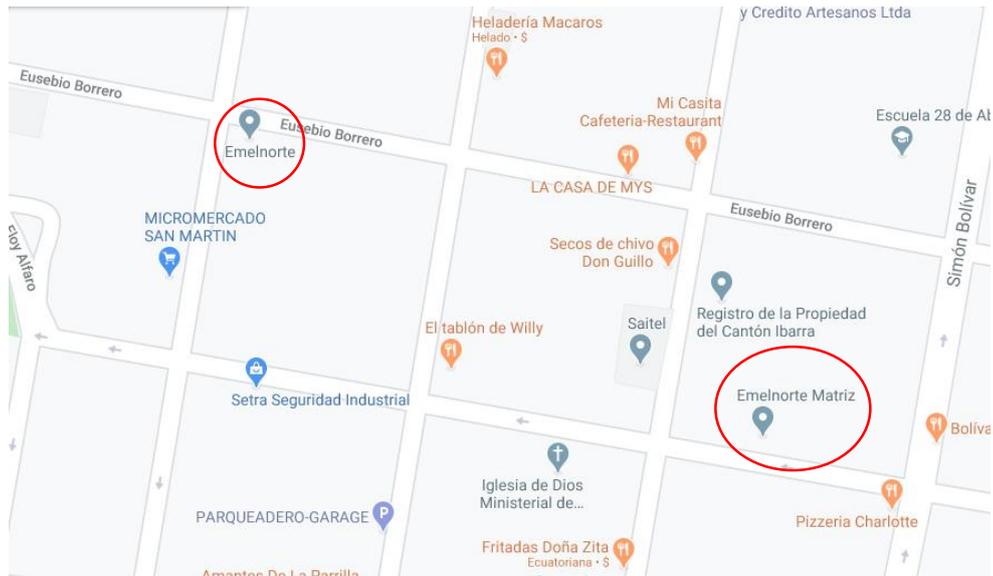


Figura 20: Ubicación geográfica de Emelnorte S.A. Ibarra

Fuente: Google Maps

De cierta forma esto permite poder tener un mayor nivel organizacional. Es así que, dentro de la matriz de la empresa se realiza en mayor porcentaje las actividades administrativas y organizacionales, por otro lado, en la central se desarrolla y prioriza la logística y la operativización de la empresa y en cierto grado también las tareas administrativas en base a las áreas existentes en el lugar.

3.2.1 Generalidades

En función del Estatuto Orgánico de EMELNORTE S.A. – Ibarra se presenta a continuación:

Misión

Brindar el servicio público de energía eléctrica y servicio de alumbrado público general, con calidad, calidez, responsabilidad social y ambiental a la población del área de cobertura.

Visión

Al año 2021, seremos una empresa pública que entregue a la comunidad, el servicio de energía eléctrica y alumbrado público general, en concordancia con las metas establecidas por los organismos de control, con excelencia de categoría internacional, compromiso social y ambiental.

Valores institucionales

Los valores institucionales son el conjunto de principios, creencias, reglas que se consideran la plataforma en gestión de la organización. Constituyen lo que es importante para la empresa, la forma de actuar como institución y de su talento humano.

Valores personales

Ética

El comportamiento de los colaboradores y de los entes ejecutores estará enmarcado en toda circunstancia, dentro de principios de honestidad, integridad y justicia. Profesar y practicar un claro rechazo a la corrupción en todos sus ámbitos del desempeño de la Empresa y cumplir cabalmente con la normativa vigente.

Transparencia

Significa el acceso creciente a la información sobre toda faceta del comportamiento de EMELNORTE. Genera el “capital-confianza”, valor inestimable que asegurará su progreso.

Honestidad

El compromiso de los Directivos y servidores de EMELNORTE es transparente consigo mismo y con sus clientes externos e internos.

Respeto

El respeto es la base de toda convivencia, cuando hablamos de respeto, no solo nos referimos a las demás personas, estamos hablando de nosotros mismos, de contemplar hasta donde llegan las propias posibilidades, de ver cuando hacer o no hacer ciertas cosas, por esto Baltasar García dice que “hemos de proceder de tal manera que no nos sonrojemos ante nosotros mismos”.

Disciplina

Valor corrige, moldea, da fortaleza, forma buenos hábitos y te compromete contigo mismo para cumplir con obligaciones y hacer un poco más de lo esperado.

Lealtad

Sentimiento de apego, fidelidad y respeto que inspira al talento humano de EMELNORTE, para llevar adelante acciones o ideas con las que la empresa se identifica.

Valores de trabajo

Comunicación efectiva

La comunicación requiere de un clima de confianza, congruencia entre lo que se dice y lo que se hace aumenta la credibilidad y la certidumbre y genera el clima apropiado para que la comunicación efectiva se logre.

Trabajo en Equipo

El compromiso que asume todo trabajador de EMELNORTE para generar sinergia en procura de resultados efectivos.

Orientación al cliente

Lo más característico es que no se trata de una conducta concreta frente a un cliente real, sino de una actitud permanente de contar con las necesidades y demandas del cliente,

supone el deseo de satisfacer a los clientes con el compromiso de superar sus expectativas y mejorar su calidad de vida, teniendo en cuenta, entre otras, las variables de respeto, amabilidad, calidad, oportunidad y excelencia.

Cultura de Calidad en el Servicio

Garantiza nuestro posicionamiento en el medio actual y en un futuro, exige esfuerzo por mejorar constantemente la calidad de los servicios, tanto internos como externos, mediante una actitud participativa, interactiva y de aprendizaje.

Responsabilidad Social y Ambiental

Enfoque empresarial que involucra el compromiso de EMELNORTE de enmarcar sus acciones con una contribución activa para el mejoramiento social, y ambiental, con el objetivo de mejorar su situación competitiva y su valor agregado, sin atentar contra las normas establecidas.

3.2.2 Estatuto orgánico

Organigrama

En la Figura 21, se muestra a detalle la estructura organizacional de la empresa con fecha de publicación al mes de febrero del año 2020. Considerando que cada uno de los procesos inmersos en este apartado se encuentran sujetos a cambios en dependencia a la adaptabilidad del sistema, debido a la situación de riesgo por la cual se está atravesando.

**ORGANIGRAMA ESTRUCTURAL
EMELNORTE**

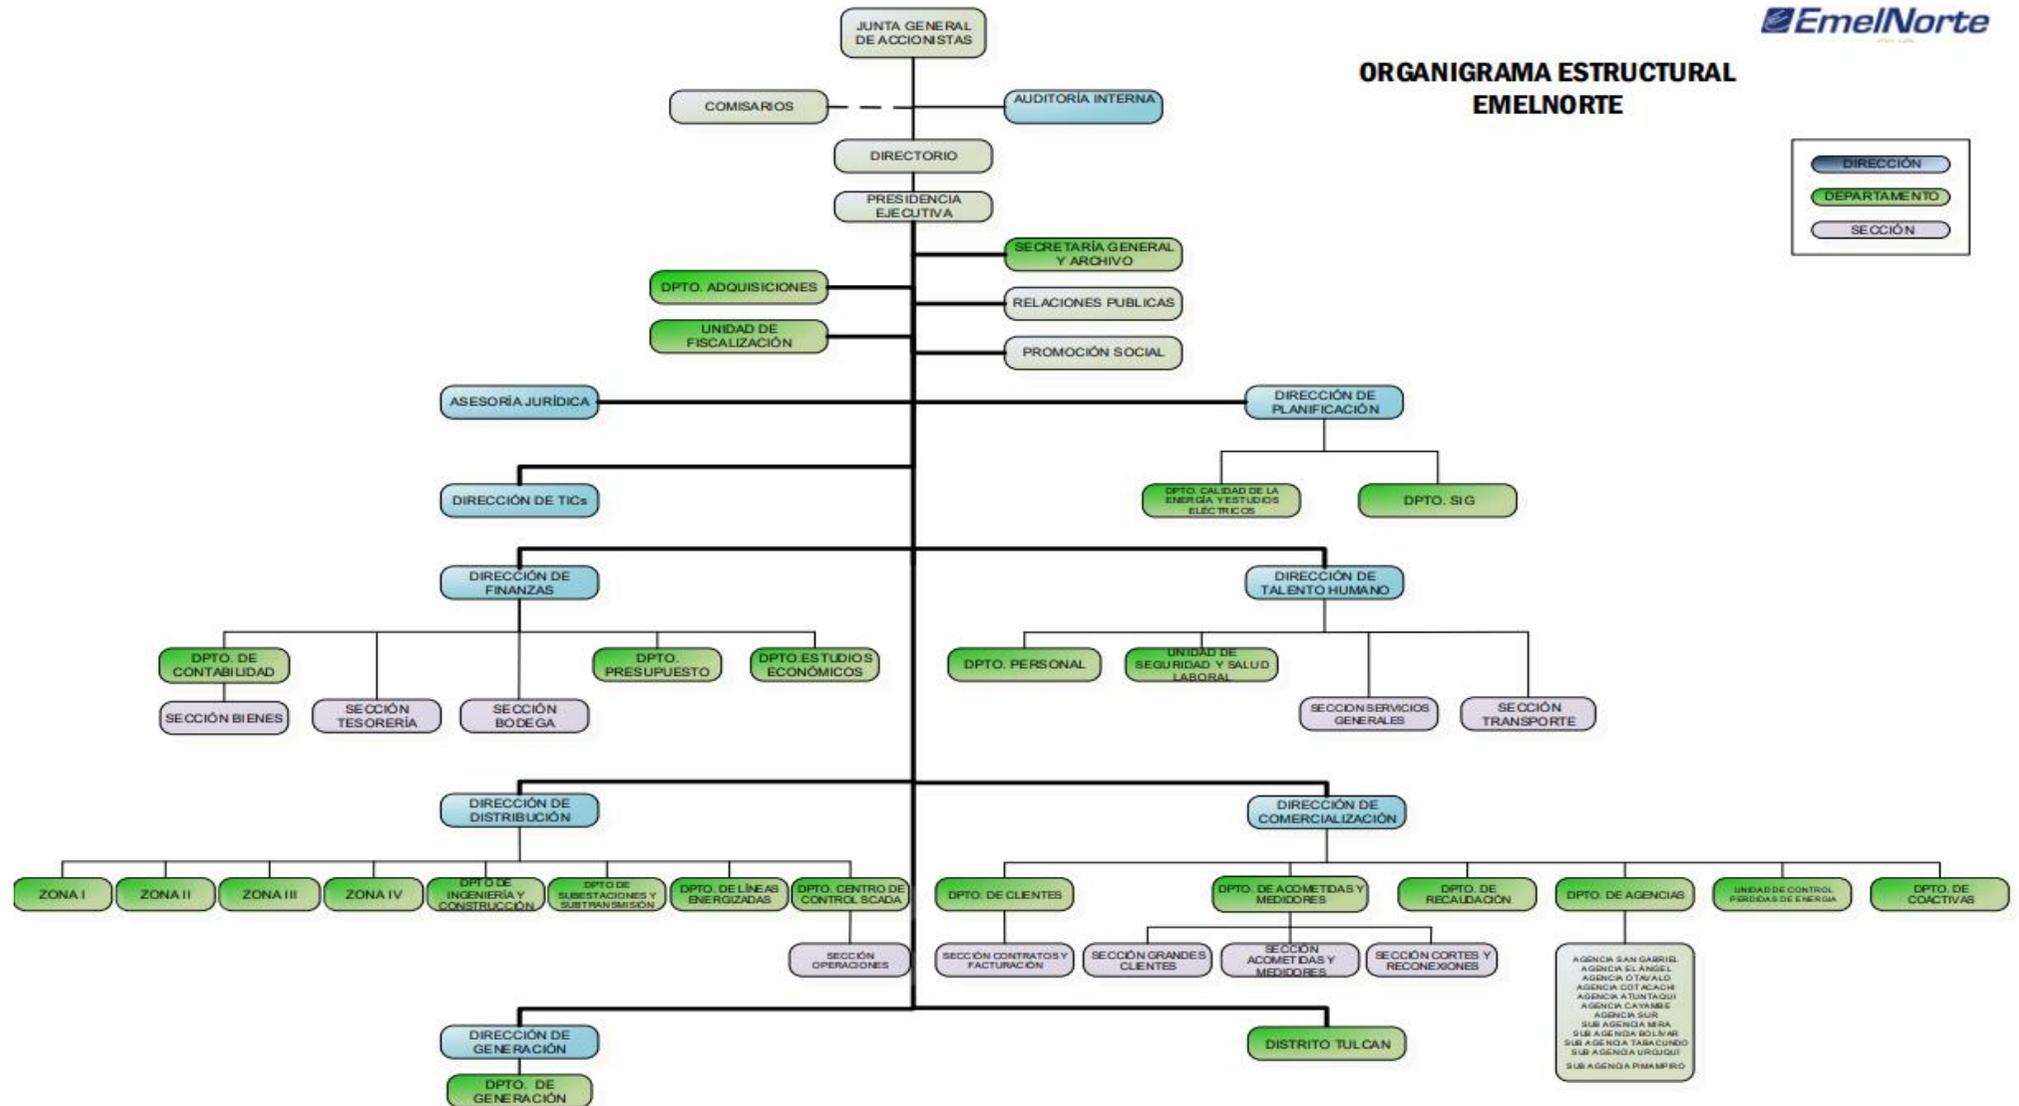


Figura 21: Organigrama estructural
Fuente: Dirección de talento humano

3.2.3 Nivel estratégico

Objetivos estratégicos

De forma puntual y general se plantean 5 objetivos estratégicos dentro de la empresa como tal los mismos que rigen el trabajo y desarrollo del Plan Estratégico, el Plan Maestro de Electricidad, los Planes Operativos Anuales y demás. Con la finalidad de dar direccionamiento a cada uno de los procesos dentro de la organización.

- Garantizar el suministro de energía eléctrica con calidad, continuidad y seguridad.
- Optimizar el uso de los recursos disponibles.
- Potenciar las competencias del Talento Humano.
- Consolidar la imagen corporativa e incrementar la cobertura y prestación del servicio eléctrico en el área de concesión.
- Reducir los impactos socio-ambientales del sistema eléctrico.

3.3 Proceso de pronóstico actual

La unidad de Planificación es la encargada dentro de su área de estudios eléctricos de realizar el pronóstico de la demanda de energía eléctrica, los cuales utilizan la información histórica aproximadamente desde el 2010 hasta el año 2018, generando un pronóstico para los años 2019 al 2027, sin embargo, en los siguientes acápite se logra describir el proceso mencionado de forma más detallada.

3.3.1 Elementos

Subestaciones

En la Tabla 3, se muestran las subestaciones de distribución existentes en la estructura de distribución de la empresa. En la Tabla 4 se explican las especificaciones existentes dentro de cada subestación. Dentro del pronóstico como tal de la empresa se utilizan las subestaciones

con la finalidad de direccionar de forma eficiente la distribución eléctrica, es así que, se requiere la existencia y control eficiente de las mismas.

Tabla 3. Subestaciones de distribución

# S/E	Subestación de Distribución
1	S/E CAYAMBE 69/13.8KV - 2X10 MVA
2	S/E LA ESPERANZA 69/13.8KV - 1X10 MVA
3	S/E OTAVALO 69/13.8KV - 1X10 MVA
4	S/E COTACACHI 69/13.8KV - 1X5 MVA
5	S/E DIESEL 34.5/13.8/6.3KV - 11.75 MVA
6	S/E ALPACHACA 69/13,8 KV - 1X20 MVA
7	S/E ATUNTAQUI 34.5/13.8KV - 8 MVA
8	S/E SAN VICENTE 34,5/13.8KV - 2 MVA
9	S/E CHOTA 69/13.8KV - 2X5 MVA
10	S/E EL RETORNO 69/13.8KV - 1X10 MVA
11	S/E SAN AGUSTIN 69/13.8KV - 1X10 MVA
12	S/E LAFARGE 69/4,16 KV - 30 MVA
13	S/E EL ANGEL-ESPEJO 69/13.8KV - 1X2.5MVA
14	S/E SAN GABRIEL 69/13.8KV - 1X10 MVA
15	S/E TULCAN 69/13.8KV - 1X10 MVA
16	S/E LA CAROLINA 69/13,8KV - 1X5 MVA
17	S/E SN. VICENTE 69/13,8 KV 1X10 MVA
18	S/E AJAVÍ 69/13.8KV - 1X10 MVA
19	S/E EL ROSAL 69/35,5 kV 1X5 MVA
20	S/E VACAS GALINDO 69/13,8 kV - 1X5 MVA
21	S/E ECUAJUGOS 69/13,8 kV - 1X3,5 MVA
22	S/E SANTA BARBARA 69/13,8 kV - 1X5 MVA
23	S/E YACHAY 69/13,8 kV - 1X24 MVA

Fuente: Estudios Eléctricos

Tabla 4. Características técnicas de la demanda de energía eléctrica

POTENCIA APARENTE	MVA
DEMANDA TOTAL NO COINCIDENTE	MW
DEM. POT. REACTIVA NO COINCIDENTE	MVAR
ENERGIA CONSUMIDA	GWH
FACTOR DE POTENCIA	PU
FACTOR DE CARGA	PU

Fuente: Estudios Eléctricos

Dentro de la información proporcionada por la organización hay periodos en que algunas subestaciones no presentan la información que indiquen los niveles de demanda. Por lo tanto, existe la necesidad de priorizar aquellas subestaciones que posean información de forma continúa buscando que los resultados generados por el proyecto de investigación en desarrollo cuenten con niveles considerablemente altos de veracidad logrando así la reducción de las medidas de dispersión en las previsiones de demanda eléctrica.

Puntos de entrega

Se hace referencia a los transformadores que comprende toda la cobertura existente por la empresa eléctrica, es así como, en la Tabla 5 se muestran cada uno de los puntos de entrega de las subestaciones con valores de los 4 últimos años de operación considerando que se han realizado redistribuciones de carga en dependencia de los cambios existentes en el momento de la distribución.

Tabla 5. Puntos de entrega de las subestaciones

PUNTO DE ENTREGA S/E	Unidad	2016	2017	2018	2019
S/E TULCAN TRANSFORMADOR ATQ [33 MVA]	GWh	95,17	90,39	93,01	101,94
	MW	18,73	18,43	18,09	19,53
	MVAR	5,24	5,12	4,99	5,35
Total	MVA	19,45	19,12	18,77	20,24
S/E IBARRA TRANFOS EN PARALELO [2x66 MVA]	GWh	475,54	493,19	550,13	624,97
	MW	93,60	100,54	107,02	119,71
	MVAR	26,19	27,93	29,52	32,78
Total	MVA	97,19	104,35	111,01	124,11
S/E IBARRA TRANSFORMADOR T1 [50 MVA]	GWh	25,96	29,97	31,81	34,01
	MW	5,11	6,11	6,19	6,51
	MVAR	1,43	1,70	1,71	1,78
Total	MVA	5,31	6,34	6,42	6,75
S/E CAJAS TRANSFORMADOR ATQ [167 MVA]	GWh	0,00	0,00	0,00	0,00
	MW	0,00	0,00	0,00	0,00
	MVAR	0,00	0,00	0,00	0,00
Total	MVA	0,00	0,00	0,00	0,00
ENERGÍA ACTIVA	GWh	596,68	613,55	674,95	760,91
POTENCIA ACTIVA MÁXIMA NO COINCIDENTE	MW	117,44	125,07	131,30	145,75
POTENCIA REACTIVA MÁXIMA NO COINCIDENTE	MVAR	32,87	34,75	36,22	39,91
POTENCIA APARENTE MÁXIMA NO COINCIDENTE	MVA	121,95	129,81	136,20	151,11

Fuente: Estudios Eléctricos

En el Anexo 1, se muestra un gráfico unifilar de toda la estructura de distribución de la empresa teniendo en cuenta y considerando cada punto expuesto anteriormente como sus respectivas subestaciones como sus puntos de entrega. Considerando y añadiendo además de forma informativa la descripción de cada simbología en el mismo.

3.3.2 Pronóstico

En la Tabla 6, se muestra el pronóstico de la empresa, realizado por subestación hasta el año 2027, los resultados obtenidos responden a una función estadística de Excel, es decir utilizan métodos convencionales, por ende, el grado de dispersión en los resultados podría ser alto. Esto debido a que estas funciones no consideran ni se adaptan a la variabilidad del comportamiento de los datos existentes, ya sea por circunstancias imprevistas o cambios dentro de la planificación de energía nacional. Esto incide de forma directa en los resultados. Y abre paso a la necesidad de un modelo adaptable y flexible a todos los escenarios posibles dentro de la previsión de la demanda eléctrica.

Tabla 6. Pronóstico por subestaciones

# S/E	Subestación de Distribución	2019	2020	2021	2022	2023	2024	2025	2026	2027
1	S/E CAYAMBE 69/13.8KV - 2X10 MVA	14,97	15,57	16,18	16,78	17,39	17,99	18,59	19,20	19,80
2	S/E LA ESPERANZA 69/13.8KV - 1X10 MVA	10,55	10,95	11,34	11,74	12,13	12,53	12,92	13,32	13,71
3	S/E OTAVALO 69/13.8KV - 1X10 MVA	7,62	7,80	7,98	8,16	8,33	8,51	8,69	8,87	9,05
4	S/E COTACACHI 69/13.8KV - 1X5 MVA	4,12	4,44	4,76	5,08	5,40	5,73	6,05	6,37	6,69
5	S/E DIESEL 34.5/13.8/6.3KV - 11.75 MVA	-	-	-	-	-	-	-	-	-
6	S/E ALPACHACA 69/13,8 KV - 1X20 MVA	9,42	9,84	10,26	10,68	11,09	11,51	11,93	12,35	12,77
7	S/E ATUNTAQUI 34.5/13.8KV - 8 MVA	6,51	6,84	7,16	7,25	7,46	7,66	7,85	8,03	8,21

8	S/E SAN VICENTE 34,5/13.8KV - 2 MVA	-	-	-	-	-	-	-	-	-
9	S/E CHOTA 69/13.8KV - 2X5 MVA	4,85	4,85	4,85	4,84	4,83	4,82	4,81	4,80	4,78
10	S/E EL RETORNO 69/13.8KV - 1X10 MVA	10,49	10,75	11,00	11,26	11,51	11,77	12,02	12,28	12,53
11	S/E SAN AGUSTIN 69/13.8KV - 1X10 MVA	9,23	9,36	9,50	9,65	9,79	9,94	10,09	10,24	10,39
12	S/E LAFARGE 69/4,16 KV - 30 MVA	19,22	36,00	46,00	46,00	56,00	56,00	56,00	56,00	56,00
13	S/E EL ANGEL- ESPEJO 69/13.8KV - 1X2.5MVA	2,26	2,33	2,40	2,47	2,54	2,61	2,68	2,75	2,82
14	S/E SAN GABRIEL 69/13.8KV - 1X10 MVA	7,87	8,12	8,38	8,63	8,89	9,14	9,39	9,65	9,90
15	S/E TULCAN 69/13.8KV - 1X10 MVA	9,40	9,55	9,70	9,85	10,00	10,15	10,30	10,45	10,60
16	S/E LA CAROLINA 69/13,8KV - 1X5 MVA	3,14	3,45	3,77	4,08	4,40	4,71	5,03	5,34	5,65
17	S/E SN. VICENTE 69/13,8 KV 1X10 MVA	8,36	8,86	9,37	9,87	10,38	10,88	11,39	11,89	12,40
18	S/E AJAVÍ 69/13.8KV - 1X10 MVA	8,06	8,18	8,31	8,43	8,56	8,69	8,82	8,95	9,08
19	S/E EL ROSAL 69/35,5 kV 1X5 MVA	-	-	-	-	-	-	-	-	-
20	S/E VACAS GALINDO 69/13,8 kV - 1X5 MVA	-	-	-	-	-	-	-	-	-
21	S/E ECUAJUGOS 69/13,8 kV - 1X3,5 MVA	1,27	1,28	1,28	1,28	1,29	1,29	1,29	1,30	1,30
22	S/E SANTA BARBARA 69/13,8 kV - 1X5 MVA	-	-	-	-	-	-	-	-	-
23	S/E YACHAY 69/13,8 kV - 1X24 MVA	8,40	9,80	11,20	12,60	14,00	15,30	16,50	17,80	18,90

Fuente: Estudios Eléctricos

Como se muestra en la Tabla 6, dentro de la información histórica no se cuenta con todas las mediciones correspondientes a cada subestación, generando vacíos en la previsión de la

demanda. Debido a la redistribución existente dentro de los valores de demanda se tiende a realizar arreglos a los resultados con la finalidad de evitar niveles elevados en costos por sobre estimación de recursos o falta de producción de energía eléctrica por una mala previsión.

Además, luego del procesamiento de las bases de datos de las subestaciones se logró definir 15 subestaciones que cuentan con la información necesaria para ser tratada y llevada a un proceso de pronóstico con el uso y/o aplicación de un modelo que emplee redes neuronales artificiales como esencia de su desarrollo y junto con esto el aprovechamiento del software Matlab y sus interfaces como lo es Toolbox.

Función de pronóstico

En Excel 2016, la función pronóstico se reemplazó con pronóstico lineal. La sintaxis y el uso de las dos funciones son iguales, pero la función de previsión más antigua se la considera obsoleta. El valor futuro es un valor y para un valor x dado. Los valores existentes son valores x y valores y conocidos, es así que, el valor futuro se pronostica con el uso de la regresión lineal (Microsoft, 2020).

Por lo tanto, al utilizar un modelo convencional en función de una regresión lineal, no se consideran variables como el producto interno bruto (PIB), condiciones atmosféricas, factores ocasionales y estacionales entre otros, que inciden en la efectividad de los resultados generados por la proyección de la demanda.

Sintaxis

La sintaxis de la función pronóstico lineal tiene los siguientes argumentos:

Función: PRONOSTICO (x , conocido_ y , conocido_ x)

En la Tabla 7, se describe cada uno de los argumentos existentes dentro de la función de previsión de Excel. Considerando una estructura general, que permita normalizar la aplicación para las distintas subestaciones.

Tabla 7. Descripción de la función

Argumento	Requerido	Detalle
X	Sí	Es el punto de datos cuyo valor se desea predecir.
Conocido_y	Sí	Es la matriz o rango de datos dependientes.
Conocido_x	Sí	Es la matriz o rango de datos independientes.

Fuente: (Microsoft, 2020)

Esto es debido a que esta clase de métodos no garantizan la eficiencia y/o efectividad en los resultados generados. Considerando esto, el alcance que tiene esta función tiene deficiencias, por esto se propone que se desarrolle y diseñe un modelo con la aplicación de redes neuronales artificiales.

Las redes neuronales artificiales son una opción de solución a la problemática existente dentro de la empresa, ya que estas se ajustan de forma eficiente y eficaz a cada uno de los parámetros (económicos, sociales, climáticos entre otros) que se deben considerar para la realización de una previsión de demanda de energía eléctrica.

Análisis de la demanda de energía eléctrica

En las subestaciones que conforman las líneas de distribución de EMELNORTE S.A – Ibarra, se ha realizado una previsión tomando como insumos de entrada valores históricos desde el año 2012 hasta el 2018. En la Figura 22 se muestra el comportamiento general de las subestaciones, tratando de señalar puntos clave dentro de la serie de datos.

Serie de tiempo de demanda anual

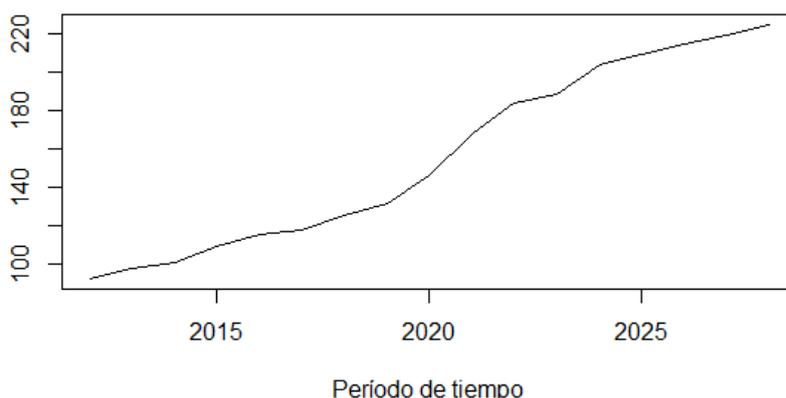


Figura 22: Serie de tiempo de demanda anual de energía eléctrica
Fuente: RStudio

La información recopilada durante 7 años permite realizar una previsión para 9 años de forma general para las subestaciones que se encuentran dentro del S.N.I. es así que, se pueden identificar diferentes características dentro de la serie de tiempo que se presenta como información o insumos de entrada tanto como para la previsión realizada. Para esto, se requiere un análisis que pueda ser sustentado de forma cuantitativa y en este caso utilizando softwares como IBM SPSS y RStudio.

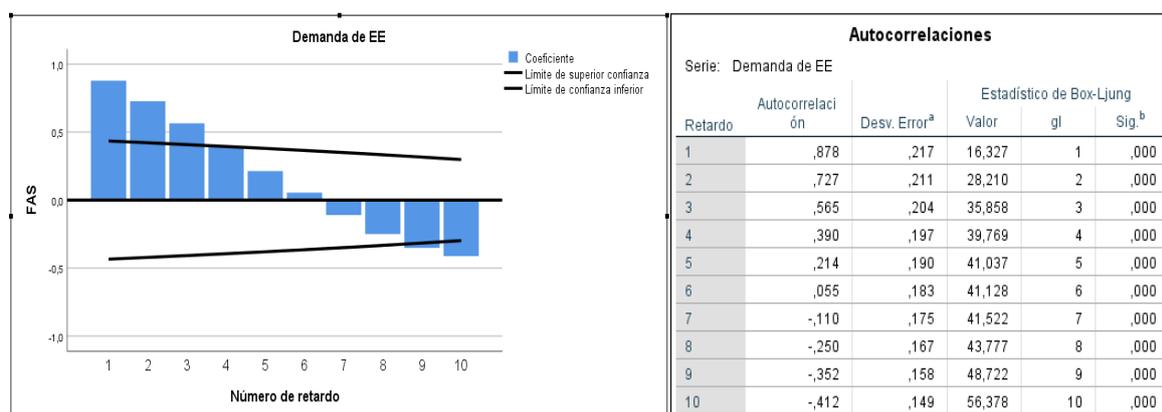


Figura 23: Coeficientes de auto-correlación de la demanda anual de energía eléctrica
Fuente: RStudio

En la Figura 23 se puede observar el comportamiento de la serie de tiempo de demanda de energía eléctrica en función de sus coeficientes de correlación. Al analizar la función de auto-correlación se puede observar que los coeficientes tienen un comportamiento decreciente, pero

significativamente muy lento. Por tanto, esto determina que existe una tendencia dentro de la serie. No se puede determinar estacionalidad debido a que es un análisis general de las subestaciones, aún con esto, la tendencia se ajusta a las previsiones dentro del marco nacional del plan maestro de energía.

Además, se puede identificar que al no decrecer rápidamente los coeficientes de autocorrelación y no acercarse a 0 de forma inmediata aproximadamente desde el retardo 2 sino al hacerlo únicamente en el retardo 6 por esto se concluye que tampoco es una serie estacionaria. Sin embargo, el análisis que se considerará de forma individual por subestación y si es el caso por puntos de entrega deberá someterse a los mismos parámetros de análisis.

CAPÍTULO IV. DESARROLLO DEL MODELO PARA EL PRONÓSTICO

Como se observó en el capítulo anterior, en el Plan Maestro de Energía incluso se desarrollan y presentan las proyecciones de las pérdidas que se presentarán en los siguientes años en la distribución de energía eléctrica. Sin duda esto implica que los métodos utilizados dentro de las áreas de estudios eléctricos, presentan ciertos niveles de incertidumbre en los resultados que generan falencias dentro de la previsión de la demanda incidiendo en pérdidas para las empresas eléctricas del país.

El desarrollo de este modelo se ajusta a los requerimientos existentes de predicción de la demanda de energía eléctrica en la empresa EMELNORTE S.A. – Ibarra. Por lo tanto, se muestran y detallan cada uno de los elementos que intervienen en el proceso de diseño del modelo con el empleo de redes neuronales artificiales y juntamente la aplicación del software MATLAB.

A continuación, se presenta el pre-procesamiento de la información histórica proporcionada por la empresa, la descripción de los elementos presentes en el trabajo con la red neuronal, las variables existentes de las subestaciones analizadas, a su vez, los pronósticos realizados y la evaluación de métricas entre métodos empleados.

4.1 Diseño del modelo

Conforme a la Figura 9 presentada en el Capítulo II, se desarrolla el diseño del modelo considerando cada uno de los puntos existentes en la estructura de un modelo de pronóstico mediante redes neuronales artificiales. Es así que, se considera para el modelo la selección de variables, recolección, pre-procesamiento, entrenamiento, validación y prueba de datos, definición de la arquitectura de la red, establecimiento de los criterios de evaluación, entrenamiento de la red con sus iteraciones y finalmente su aplicación.

Cabe mencionar, que el desarrollo del diseño se lo describe en primera instancia de forma general, para finalmente llegar a la aplicación del modelo en cada una de las subestaciones de EMELNORTE S.A. – Ibarra.

4.1.1 Selección de variables

Es de suma importancia un adecuado reconocimiento de las variables de entrada que intervienen en función de los datos técnicos de demanda eléctrica, debido a que los resultados generados son consecuentes a una correcta definición de las mismas. Para esto se considera la siguiente clasificación.

Variable a pronosticar: Demanda de energía eléctrica

Tipo de variable: Cuantitativa

Unidad: Kilo Watt (kW)

4.1.2 Recolección de datos

La información y/o datos técnicos para el desarrollo de esta investigación fueron proporcionados por la empresa EMELNORTE S.A. – Ibarra. Es decir, la demanda de energía eléctrica, esto es manejado y controlado por la Dirección de Planificación en el área de Estudios Eléctricos.

Se contó con información desde el año 2016 hasta el 2019, sin embargo, las subestaciones que cumplieron con toda la información necesaria fueron 15 las cuales son especificadas en la Tabla 8. Las subestaciones restantes, en algunos casos no cuentan con información histórica de ningún tipo, por otro lado, existen otras que presentan datos históricos inferiores a un año. Para un adecuado desarrollo del modelo se requiere un mínimo de 36 meses dentro de los datos de entrada.

Tabla 8. Subestaciones de distribución

# S/E	SUBESTACIÓN
1	S/E CAYAMBE 69/13.8KV - 2X10 MVA
2	S/E LA ESPERANZA 69/13.8KV - 1X10 MVA
3	S/E OTAVALO 69/13.8KV - 1X10 MVA
4	S/E COTACACHI 69/13.8KV - 1X5 MVA
5	S/E ALPACHACA 69/13,8 KV - 1X20 MVA
6	S/E ATUNTAQUI 34.5/13.8KV - 8 MVA
7	S/E CHOTA 69/13.8KV - 2X5 MVA
8	S/E EL RETORNO 69/13.8KV - 1X10 MVA
9	S/E SAN AGUSTIN 69/13.8KV - 1X10 MVA
10	S/E EL ANGEL-ESPEJO 69/13.8KV - 1X2.5MVA
11	S/E SAN GABRIEL 69/13.8KV - 1X10 MVA
12	S/E TULCAN 69/13.8KV - 1X10 MVA
13	S/E LA CAROLINA 69/13,8KV - 1X5 MVA
14	S/E SN. VICENTE 69/13,8 KV 1X10 MVA
15	S/E AJAVÍ 69/13.8KV - 1X10 MVA

Fuente: Estudios Eléctricos

Es necesario, aclarar que el estudio consideró los generadores de 69 kilovoltios (kV), debido a que, los generadores de 13.8 kV y 34.5 kV en algunos casos no contaban con información mayor a un año dentro de los datos técnicos de demanda de energía eléctrica. Cada una de las subestaciones presentan salidas con valores diarios en intervalos de tiempo de 15 minutos, esto se lo realiza por mes durante cada uno de los años.

4.1.3 Pre-procesamiento

Para realizar un trabajo eficiente dentro del software que se emplea, es necesario identificar y preparar todos los datos. En el caso de MATLAB se requiere una distribución en función de su interfaz matricial. Para este modelo se emplean una matriz por columna ajustando los datos de entrada y salida por mes y año. Como se muestra en la Tabla 9 ejemplificando solo hasta el segundo mes de cada año.

Tabla 9. Estructura de datos técnicos

SUBESTACIÓN LA CAROLINA		
ENTRADA		SALIDA
Mes	Año	Demanda
1	2016	3731576
1	2017	-2223140
1	2018	-4534285
1	2019	5387789
2	2016	6071607
2	2017	-1745262
2	2018	-2878720
2	2019	3762584

Fuente: Autor

De igual forma en la Figura 24 se muestra en forma de ejemplo el ingreso dentro del software MATLAB de las hojas preparadas de Excel. Los inputs representan a las x en función de la serie de tiempo. Los targets definen la forma de las salidas deseadas en este caso y .

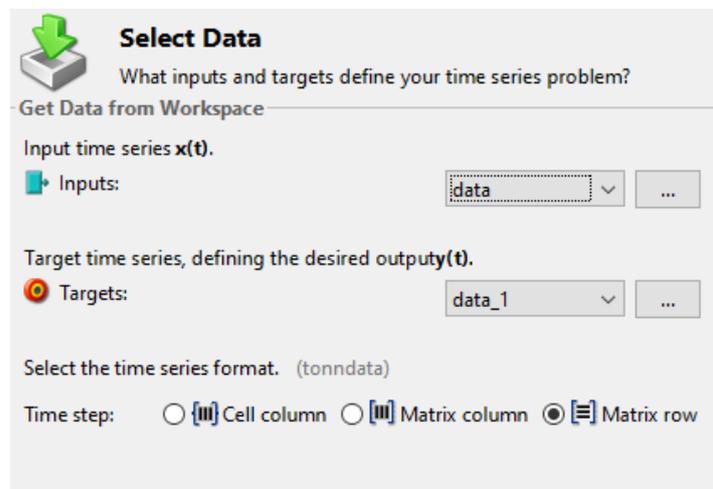


Figura 24: Selección de los datos

Fuente: MATLAB

Tanto para inputs como targets el software nombra a los datos como *data* y *data_1* de esta forma comienzan a ser parte dentro del área de trabajo de MATLAB. Es necesario, seleccionar el formato en el cual se trabajará. En nuestro modelo la información se la trabajará en la opción de matriz por fila (Matrix Row).

Además, toda la información trabajada no presenta valores nulos ni tampoco valores perdidos, por estos motivos no es necesario emplear un tratamiento especial a la información, sino únicamente de forma al momento de la entrada de cada una de las subestaciones.

Es necesario mencionar que el software MATLAB presenta dentro de sus múltiples bondades funciones que permiten tratar de forma automática el pre-procesamiento y a su vez el post-procesamiento de la información esto se lo describirá al detallar la forma en la cual se realiza el entrenamiento de la red.

4.1.4 Conjunto de entrenamiento, validación y prueba

Estos conjuntos se definen y generalizan para cada una de las subestaciones y/o puntos de entrega. Buscando de esta forma que existan parámetros iguales de entrenamiento, validación y prueba dentro del desarrollo del modelo. En la Figura 25 se presenta el interfaz existente dentro del software utilizado, para definir estos conjuntos.

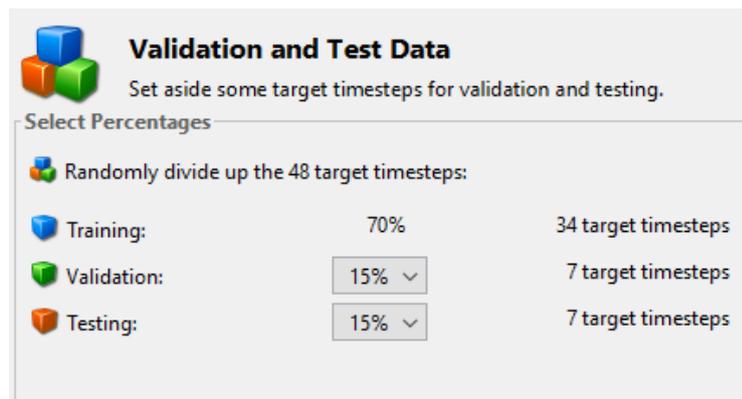


Figura 25: Entrenamiento, validación y prueba

Fuente: MATLAB

Conjunto de entrenamiento

El conjunto que se trata dentro del desarrollo del modelo presenta por subestación un total de 48 mediciones haciendo función a los 4 años y a los 12 meses tomados por cada uno de ellos. De forma general se cuenta con 720 mediciones mensuales de demanda de energía eléctrica considerando las 15 subestaciones por procesar.

En la Figura 25 se muestra como este conjunto representa el 70% de los datos ingresados dentro de la selección de datos, es decir, al hablar únicamente del análisis de una subestación el valor sería de 34 mediciones.

Conjunto de validación

Como se muestra en la Figura 25 este conjunto representa el 15% de las mediciones empleadas, en el caso de una subestación esto indica 7 de las mediciones ingresadas. Este conjunto debe ser definido, ya que se utiliza para medir la generalización de la red y para detener el entrenamiento cuando la generalización ya no presenta valores con mejores resultados. Con esto se logra que la red dentro del proceso de entrenamiento aprenda de forma general en el procesamiento de los datos y así evitando que el aprendizaje sea de forma individual.

Conjunto de prueba

Representando el 15% el conjunto de prueba también equivale a 7 mediciones de demanda de energía eléctrica, en el caso de procesamiento de una subestación como se observa en la Figura 25. Este conjunto no tiene ningún efecto al momento de la realización del entrenamiento. Esto permite que el rendimiento durante y después del entrenamiento de la red posea una medida independiente.

4.1.5 Arquitectura de la red neuronal

MATLAB define de forma automática el número de neuronas con las cuales la información va a generar los resultados más eficientes. En la Figura 26, se muestra a detalle la estructura definida para el número de capas ocultas como el retardo que presenta la red neuronal. Además, se observa la red neuronal en función de la estructura previamente definida.

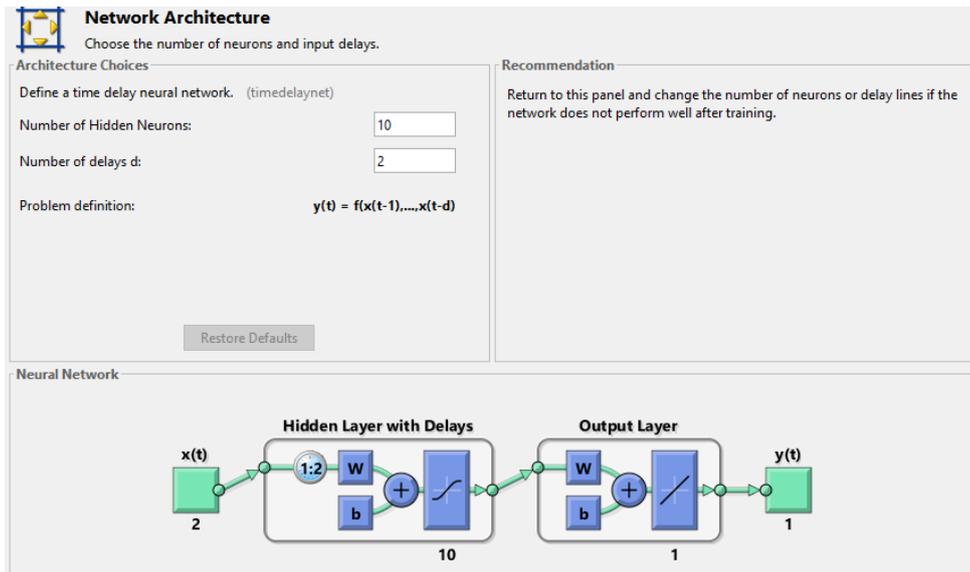


Figura 26: Arquitectura de la red
Fuente: MATLAB

Neuronas de entrada: 2

Esto hace referencia a la *data* y *data_1* anteriormente mencionado, es así que aquí se hace referencia a las 48 mediciones mensuales por subestación de los 4 años proporcionados por la empresa. Sin embargo, el software considera netamente 2 neuronas de entrada debido al ingreso de las 2 hojas de Excel preparadas para la selección de datos.

Capas ocultas: 1

En aras de un mejor desempeño computacional solo se plantea 1 capa oculta, de esta forma, evitando un sobreajuste en el procesamiento y así aumentando el desempeño en el momento de la predicción del modelo.

Neuronas ocultas: 10

Como se lo mencionó el software define las combinaciones e iteraciones que se ejecutarán en función de las neuronas ocultas existentes, esto en consideración del rendimiento y generación de resultados más precisos dentro de la previsión de la demanda de energía eléctrica.

Neuronas de salida: 1

Debido a que el modelo únicamente predice el valor de la variable que seleccionamos dentro de este proceso, y así buscando un mayor porcentaje de precisión en la red.

Retardo (Delay)

Esto permite que la red tenga una respuesta dinámica finita a los datos de entrada de series de tiempo. En este caso se determina el retardo con un valor de 2 como se observa en la Figura 26. Las redes neuronales que consideran retardo de tiempo se asemejan a las redes de alimentación pre-alimentada (Feedforward).

Algoritmo de entrenamiento

En la Figura 27 se muestra el algoritmo utilizado para el entrenamiento de este modelo, en este caso es Bayesian Regularization o Regulación Bayesiana debido a que las mediciones de que se utilizaron presentan un alto nivel de dispersión.

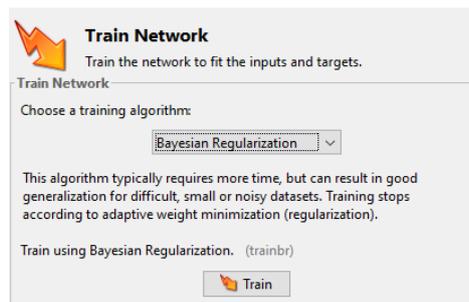


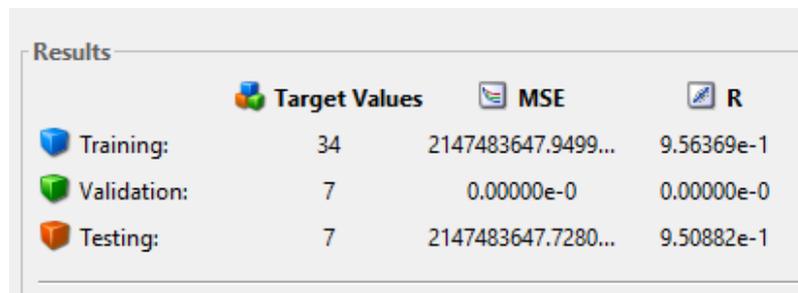
Figura 27: Algoritmo de entrenamiento

Fuente: MATLAB

La regularización Bayesiana logra minimizar una combinación lineal de errores logrando de esta forma que al final del entrenamiento el resultado presente buenos parámetros de generalización. Dentro de los entrenamientos al usar este algoritmo se presentaron los mejores resultados debido a la condición de la información ingresada de demanda.

4.1.6 Criterios de evaluación

Al realizar el entrenamiento los primeros valores o métricas de evaluación que se deben considerar son el error cuadrático y el coeficiente de correlación, en la Figura 28 se muestra el interfaz de estos parámetros.



	Target Values	MSE	R
Training:	34	2147483647.9499...	9.56369e-1
Validation:	7	0.00000e-0	0.00000e-0
Testing:	7	2147483647.7280...	9.50882e-1

Figura 28: Algoritmo de entrenamiento

Fuente: MATLAB

Error cuadrático medio (MSE)

El MSE cuando su valor tiende a 0 expresa que el nivel de error es bajo, sin embargo, en dependencia a la información utilizada se puede considerar proporcional el error. Como es el caso en esta subestación analizada, debido a esto se considera como un promedio entre las salidas existentes y los objetivos de entrenamiento.

Coefficiente de correlación (R)

La métrica R nos muestra el nivel de relación lineal existente entre las salidas y los objetivos de entrenamiento. Cuando su valor es lo más cercano a 1 determina que la relación es fuerte mostrando así una dependencia total entre las variables. Si el valor es 0 no indica necesariamente que las variables sean independientes, esto puede dar paso a que existan otros tipos de relación, como son las relaciones no lineales. Si el valor es -1, indica una dependencia total, pero cabe mencionar que en este caso se puede observar una relación inversa.

Regresión

Una de las funciones dentro del entrenamiento es la generación de gráficas que muestran el comportamiento de cada uno de los conjuntos que se ajustan a el algoritmo seleccionado. En la Figura 28 se muestra un ejemplo del comportamiento del entrenamiento de una subestación.

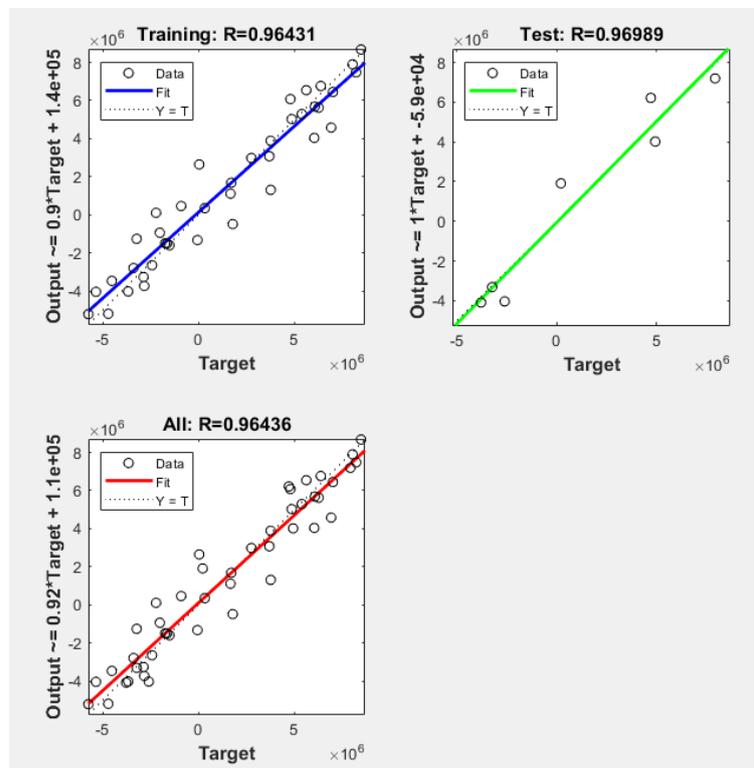


Figura 29: Regresión
Fuente: MATLAB

Aquí se muestra el comportamiento del entrenamiento (training) junto con esto también el comportamiento de las pruebas de ajuste (test) de las entradas y en este caso finalmente el ajuste general del entrenamiento y la prueba. La gráfica de la validación al usar el algoritmo de regularización Bayesiana no se muestra debido a que tanto para el MSE y R el valor se fija de forma automática en 0 para los entrenamientos que se realicen.

4.1.7 Entrenamiento

En la etapa de entrenamiento se logra observar y apreciar el progreso existente de la subestación que se esté analizando, como se presenta en la Figura 30 existen distintos

parámetros de seguimiento, tal es el caso de las iteraciones (epoch), dada a la naturaleza del estudio el entrenamiento o reentrenamiento puede parar en dependencia al aprendizaje generado por la red.

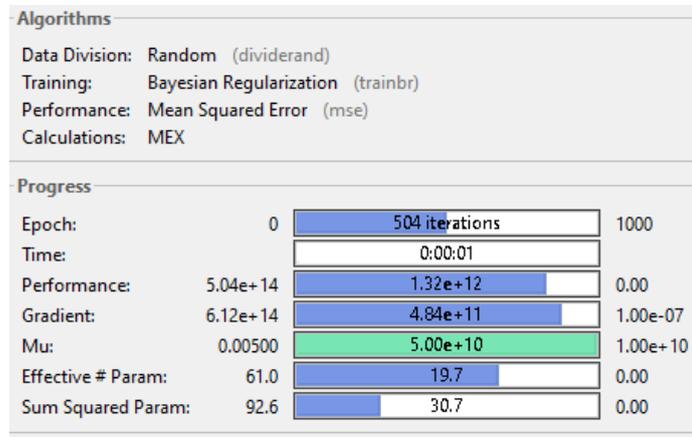


Figura 30: Entrenamiento
Fuente: MATLAB

En cada una de las iteraciones realizadas los resultados para MSE y R son distintos, la valoración y aceptación de los resultados dependen de forma directa del análisis generado por el especialista y desarrollador del trabajo de investigación. El Mu nos muestra el valor máximo de aprendizaje existente por la red neuronal, hasta que el ajuste de las series de demanda y tiempo comiencen a disminuir en su nivel de confiabilidad.

Otras variables como el tiempo de iteración, el entrenamiento el numero efectivo de parámetros y la suma cuadrada de la misma son valores que pueden ayudar para la selección de los resultados finales dentro de la subestación.

El reentrenamiento como se muestra en la Figura 27 se ajusta al algoritmo que se seleccione, en este caso al realizar un entrenamiento y no conseguir los resultados esperados medidos por los criterios de evaluación, se debe reentrenar la red en función de las entradas y objetivos de este proceso.

Con la finalidad de consolidar de mejor forma los resultados se presentó el proceso general del trabajo con redes neuronales artificiales. Cada uno de los procesos que se mencionaron fueron aplicados para cada una de las subestaciones que componen el sistema de distribución eléctrica de EMELNORTE S.A. – Ibarra.

4.2 Aplicación

Como se describió anteriormente se definieron 15 subestaciones que cumplen con los requisitos necesarios para realizar el modelado, análisis y entrenamiento en el interfaz *Neural Network Time Series* del software MATLAB. En todas las subestaciones procesadas se utilizó el algoritmo Bayesiano debido a que se requería generar una suavización y/o tratamiento previo, debido a la alta dispersión existente en los datos técnicos de demanda.

Considerando también resultados obtenidos de pronósticos generados en IBM SPSS, en donde se utilizaron modelos estacionales simples, el aditivo de Winter y en algunos casos un modelo ARIMA (0,0,2) (0,0,0), estos fueron definidos de forma automática por el software debido a que son los que generan mejores resultados dentro de cada una de las métricas de evaluación de los distintos métodos.

Además, se presenta los resultados generados del software RStudio con el empleo de modelo considerado Perceptrón Multicapa (MLP), se realizaron 5 entrenamientos con 200 repeticiones por cada subestación. El número de nodos que generaron los mejores resultados en función de las métricas de evaluación en este caso MSE, tanto como para las capas de entrada, ocultas y de salida, se ajusta a esta distribución (30,35,12).

La previsión se la realizó para los años 2020 y 2021, en cada una de las herramientas empleadas y se priorizó el modelo que genere mejores resultados, en aras de que el nivel de incertidumbre sea el más bajo posible.

En el siguiente apartado, se representan y describen los resultados obtenidos, sin embargo, al existir un gran número de subestaciones dentro de la línea de distribución eléctrica de la empresa, y en su mayoría presentan comportamientos generalizados se muestran aquellas que logran dar una idea clara y general del comportamiento del sistema eléctrico. El resto de resultados se los presenta dentro del Anexo 4.

4.2.1 Subestación La Carolina

Uno de los principales casos es cuando los resultados presentan valores negativos, tal y como se puede observar en la Tabla 10. En primera instancia se debe considerar que los datos técnicos mostrados en el Anexo 2 presentan estas mismas características, siendo esto resultado de la instalación y el funcionamiento de nuevos generadores dentro del sistema de distribución.

Tabla 10. Previsión S. La Carolina

LA CAROLINA				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	-3716646,39	-2109028,7	-2708239,5
	FEBRERO	5327386,27	-1396951,24	-2996887,5
	MARZO	5981952,998	-3165315,04	-3991943,4
	ABRIL	-1763116,62	-5905656,96	-8450945,6
	MAYO	-3396464,74	-6273956,5	-7731232,8
	JUNIO	3400861,44	-3747583,09	-5251292,8
	JULIO	1678510,60	112390,7	-1633283,4
	AGOSTO	-3283125,14	3076830,17	1583911,3
	SEPTIEMBRE	-3124679,78	4264227,88	1861102,4
	OCTUBRE	230420,75	2688431,44	-272053,8
	NOVIEMBRE	-1824169,29	-102803,34	-5356792,8
	DICIEMBRE	-4336685,05	-3775492,39	-474314,1
2021	ENERO	-3712552,72	-2109028,7	-3565240,1
	FEBRERO	-2706796,45	-1396951,24	-3876405,3
	MARZO	-1875645,01	-3165315,04	-5869305,1

	ABRIL	-4570437,46	-5905656,96	-9056395,6
	MAYO	-4334361,29	-6273956,5	-7583092,3
	JUNIO	-2668504,46	-3747583,09	-4780807,7
	JULIO	1167873,70	112390,7	-1738437,4
	AGOSTO	-3540889,10	3076830,17	1332007,4
	SEPTIEMBRE	-2642936,59	4264227,88	565065,7
	OCTUBRE	796914,02	2688431,44	-24422176,8
	NOVIEMBRE	4665481,76	-102803,34	-7509617,3
	DICIEMBRE	-954254,97	-3775492,39	-7101078,6

Fuente: Autor

Además, en la subestación La Carolina, considerando todos los modelos aplicados existen otras subestaciones que presentan estas características en los resultados de su previsión, tal es el caso de El Ángel, El Retorno, La Esperanza, Otavalo y Tulcán. Esto implica, que a futuro se podría utilizar el modelo propuesto para el análisis y previsión de los generadores extras adjuntos a estas subestaciones en dependencia a que logren cumplir con la información técnica requerida.

4.2.2 Subestación Ajaví

En la Tabla 11, se presenta el comportamiento generalizado de las subestaciones con un alto nivel de dispersión, los valores presentados se encuentran en un rango común en dependencia a cada uno de los modelos aplicados. Sin embargo, en el siguiente capítulo se evalúa y sustenta con el apoyo de métricas de evaluación, la selección del método que más se ajusta al comportamiento real de este sistema.

Tabla 11. Previsión S. Ajaví

AJAVÍ				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	45538350,49	46803596,66	49510043

	FEBRERO	45639657,26	42726165,67	45580338
	MARZO	44659709,02	46822741,85	42535458
	ABRIL	41898547,63	45737922,11	45725259
	MAYO	44946442,53	47121281,91	45781200
	JUNIO	45438669,88	46508873,65	48989866
	JULIO	45145040,22	47818749,23	49538220
	AGOSTO	43915591,87	46236900,61	45425049
	SEPTIEMBRE	45061106,29	44795402,19	44410320
	OCTUBRE	45719813,99	43931446,24	37316812
	NOVIEMBRE	45610045,87	46195420,65	44354275
	DICIEMBRE	45525158,72	47143271,1	44721369
	2021	ENERO	45877232,25	46803596,66
FEBRERO		46807188,81	42726165,67	42979512
MARZO		45774878,51	46822741,85	44100857
ABRIL		46173254,89	45737922,11	45166586
MAYO		46684496,82	47121281,91	45576202
JUNIO		48537341,68	46508873,65	45354717
JULIO		45258694,78	47818749,23	48244968
AGOSTO		46109201,41	46236900,61	45211765
SEPTIEMBRE		46820364,35	44795402,19	44695369
OCTUBRE		49812756,37	43931446,24	41411476
NOVIEMBRE		44193910,53	46195420,65	45366022
DICIEMBRE		45879099,26	47143271,1	43416426

Fuente: Autor

4.2.3 Subestación Otavalo

Se observa en la Tabla 12, que los resultados obtenidos por cada uno de los métodos difieren en grandes cantidades, esto se presenta debido al alto grado de dispersión existente en los datos técnicos históricos de las subestaciones Cotacachi, La Esperanza y Otavalo. Esto se sustenta con el procesamiento de la información desarrollado que puede ser observado en el Anexo 3.

Tabla 12. Previsión S. Otavalo

OTAVALO				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	105921880,2	34849240,73	-122459127
	FEBRERO	13857631,69	41279901,23	-44626260
	MARZO	-159510290,8	37065446,84	36863620
	ABRIL	3917391,87	37368517,24	-165328480
	MAYO	176942243,4	35255349,14	-181951642
	JUNIO	53514869,39	42913027,41	-351197044
	JULIO	-148297518	33165842,23	-225444763
	AGOSTO	44091518,98	45084222,98	-212782884
	SEPTIEMBRE	263958821,9	115509243,3	-178077832
	OCTUBRE	96114689,32	47754352	-343878243
	NOVIEMBRE	-134904251,7	46686020,63	-348342016
	DICIEMBRE	80258450,96	39279597,33	-163786547
2021	ENERO	363326463	34849240,73	-194281868
	FEBRERO	146217180,7	41279901,23	-196283344
	MARZO	-117876105,3	37065446,84	-240551354
	ABRIL	118021451,1	37368517,24	-247060711
	MAYO	465358961,1	35255349,14	-192737994
	JUNIO	208651966,2	42913027,41	-182002289
	JULIO	-94851991,62	33165842,23	-239943965
	AGOSTO	164595604,1	45084222,98	-244211895
	SEPTIEMBRE	556507578,6	115509243,3	-307845894
	OCTUBRE	285351869	47754352	-255782848
	NOVIEMBRE	-62600887,05	46686020,63	-231710500
	DICIEMBRE	220415381,8	39279597,33	-285124265

Fuente: Autor

Sin embargo, la subestación de Otavalo es la que presenta los valores más bajos en cuanto a métricas como el MSE y R. Por lo cual, es necesario identificar y ajustar los resultados previstos en dependencia al comportamiento real de la empresa.

CAPÍTULO V. ANÁLISIS DE RESULTADOS

Un adecuado análisis e interpretación de resultados, permite una adecuada identificación del comportamiento del sistema eléctrico en función de la demanda de energía eléctrica, considerando siempre el sistema de distribución como punto general de análisis y cada una de las subestaciones como elementos particulares que conforman y convergen en el mismo.

A continuación, se encuentra el análisis de 3 subestaciones presentadas previamente en el capítulo anterior estas son La Carolina, Ajaví y Otavalo. Debido a que estas logran transmitir una idea global, del comportamiento general de los resultados obtenidos en la aplicación del modelo de pronóstico propuesto.

En el Anexo 5, se presenta la información extendida de cada subestación en cuanto al análisis e interpretación de resultados, con la finalidad de generar una mayor comprensión y claridad en la descripción técnica que se desarrolla en este acápite. Se recurre a estas medidas por el extenso tratamiento de información existente, al contar con 15 subestaciones dentro del sistema de distribución.

5.1 Interpretación de resultados

5.1.1 Métricas de evaluación

En cada una de los métodos y herramientas utilizadas se logra identificar una métrica de evaluación constante y común para los resultados obtenidos como es el MSE. Por lo tanto, en la Tabla 13 se muestran los resultados por subestación de esta métrica.

Tabla 13. Métricas de evaluación

MÉTRICAS DE EVALUACIÓN			
SUBESTACIÓN	MATLAB	RSTUDIO	SPSS
	MSE	MSE	MSE
LA CAROLINA	2147483647,92	1686187,26	4,85476E+12
AJAVI	2147483647,99	85518406358	4,12874E+12
ALPACHACA	2147483647,68	42222585,20	2,17543E+13

ATUNTAQUI	2147483647,03	25572082556	9,08766E+12
CAYAMBE	2147483647,67	47390797,14	5,4451E+13
CHOTA	2147483647,29	171913646,60	1,59916E+13
COTACACHI	2147483647,33	325372714,90	4,46543E+14
EL ÁNGEL	2147483647,56	3044197,97	2,83619E+12
EL RETORNO	2147483647,69	1097963276	8,16161E+13
LA ESPERANZA	2147483647,55	3,63791E+11	5,39863E+13
OTAVALO	2147483647,98	5,23224E+12	1,47058E+15
SAN AGUSTÍN	2147483647,81	2641447,24	2,75399E+12
SAN GABRIEL	2147483647,32	3019887,71	8,35976E+12
SAN VICENTE	2147483647,91	57069628,67	1,53137E+13
TULCÁN	2147483647,84	38703888845	2,70591E+13

Fuente: Autor

En la presente tabla se muestra como los valores de error de los modelos utilizados en el software IBM SPSS, son los más altos. Por lo cual, esto indica que los resultados diferirán de forma considerable del comportamiento real del sistema de distribución de energía eléctrica.

Por otro lado, se encuentra RStudio al emplear un modelo de redes neuronales multicapa los resultados emergen en dependencia a la arquitectura de la red, en este caso tienden a generar errores bajos, no obstante, debido a la presencia de datos técnicos relativamente altos con evidentes niveles de dispersión en los datos de entrada, los valores de error se muestran y son proporcionales a la información utilizada como insumo de entrada.

Además, en MATLAB, se pueden observar valores constantes de error es decir se asemejan en cada una de las subestaciones, esto infiere a que el modelo compara el comportamiento anterior y posterior para aprender y buscar obtener resultados que describan la situación del sistema entero.

Al ser éstos considerablemente altos, es decir, mensualmente se cuenta con mediciones inclusive de millones de kilo watts, la cantidad de datos de entrada, validación y entrenamiento debería ser proporcional. Por lo cual, se debe considerar la medición de forma sistémica en función y relación de los datos tratados.

El desarrollo de una comparación entre los valores reales y previstos se encuentra limitado. En el Capítulo III, Tabla 6 la previsión en función de métodos convencionales se presenta con un alcance de 9 años. Sin embargo, con el modelo propuesto se logró generar resultados para dos años de forma mensual, con la finalidad de un mejor detalle a la hora de presentar resultados y la toma de decisiones, debido a su mayor grado de confiabilidad.

5.1.2 Comportamiento

Cada una de las subestaciones tratadas en esta investigación presentan comportamientos particulares, sin embargo, se pueden clasificar en 3 grupos que engloban el marco de previsión expuesto a continuación. Considerando así que las subestaciones detalladas, son aquellas que poseen características críticas dentro del sistema de distribución de energía eléctrica.

Subestación La Carolina

En la Figura 31, se observa una representación gráfica del comportamiento de aquellas subestaciones que presentan valores negativos dentro de su previsión, como se puede observar existe una variación notable de generación, esto dependerá de la utilización del generador de 69 KV en función de los demás generadores presentes en el sistema.

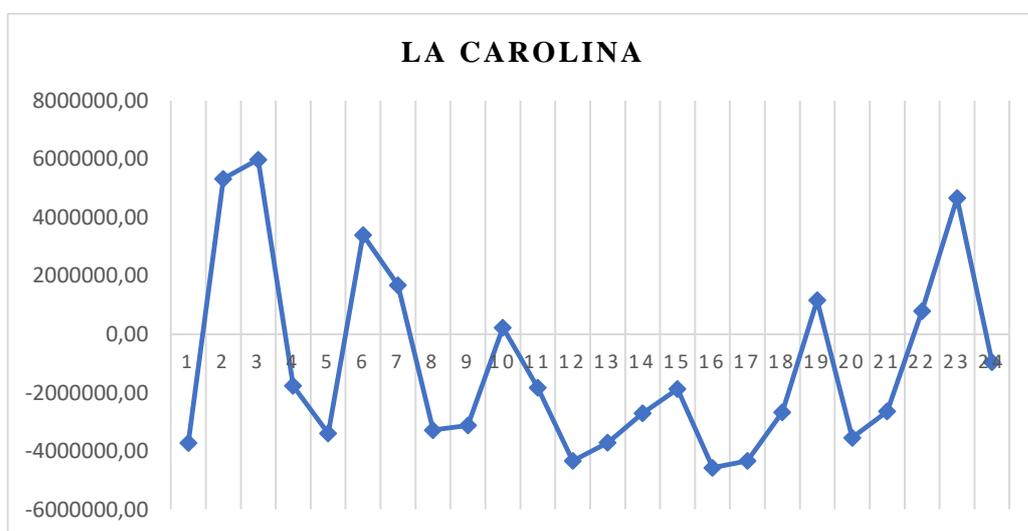


Figura 31: Previsión-Comportamiento La Carolina

Fuente: MATLAB

El resto de subestaciones que presentan tanto como información histórica y resultados negativos se encuentran expuestos en el Anexo 5, debido a que su comportamiento se asemeja al expuesto en la Figura 31. Es necesario mencionar que este tipo de subestaciones deben tener un tratamiento especial debido a la inmensa variación existente en los resultados, esto puede incidir en costos de compra y venta, así mismo como en pérdidas energéticas y económicas.

Subestación Ajaví

Existen subestaciones como se lo mencionó en el capítulo anterior que presentan características poco variables y se encuentran con un comportamiento que se ajusta a los valores reales utilizados en la previsión realizada.

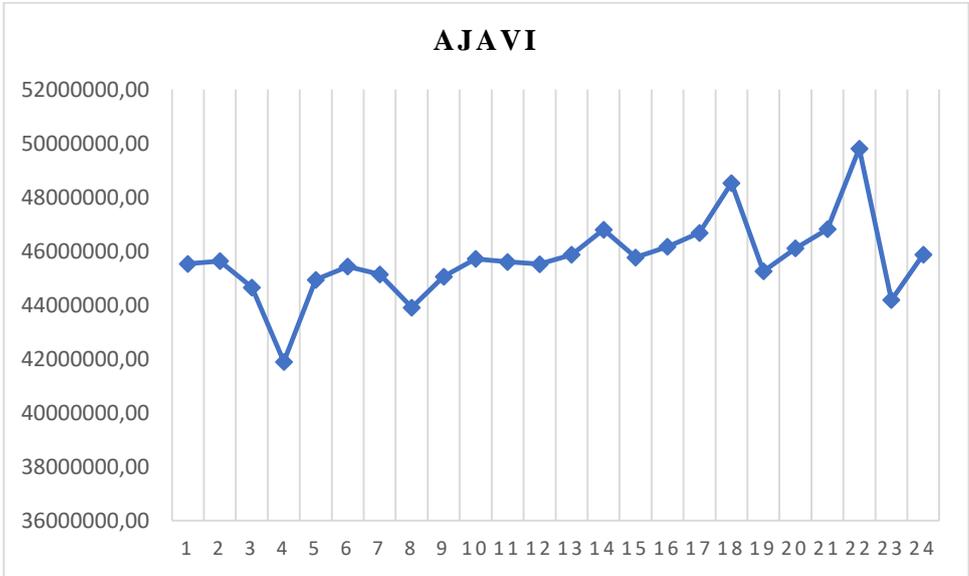


Figura 32: Previsión-Comportamiento Ajavi
Fuente: MATLAB

Estos valores se perciben como óptimos debido a que su R se acerca significativamente a 1. De forma general la mayoría de los datos se encuentran con valores mayores a 0.90 esto permite garantizar que el modelo propuesto cuente con un nivel aceptable de confiabilidad, en cada uno de sus resultados obtenidos por subestación incidiendo así en un aumento en la precisión del sistema de distribución eléctrica.

Subestación Otavalo

Esta subestación representa uno de los principales puntos críticos en la distribución de energía eléctrica, presenta valores con realmente altos niveles de dispersión. Inclusive al utilizar el algoritmo de Regulación Bayesiana para su tratamiento, no se logró aumentar el valor generado de R obteniendo así valores entre 0.5 y 0.7 debido a esto como se puede observar también en el Anexo 3, los gráficos de regresión demuestran y son consecuentes a estas premisas.

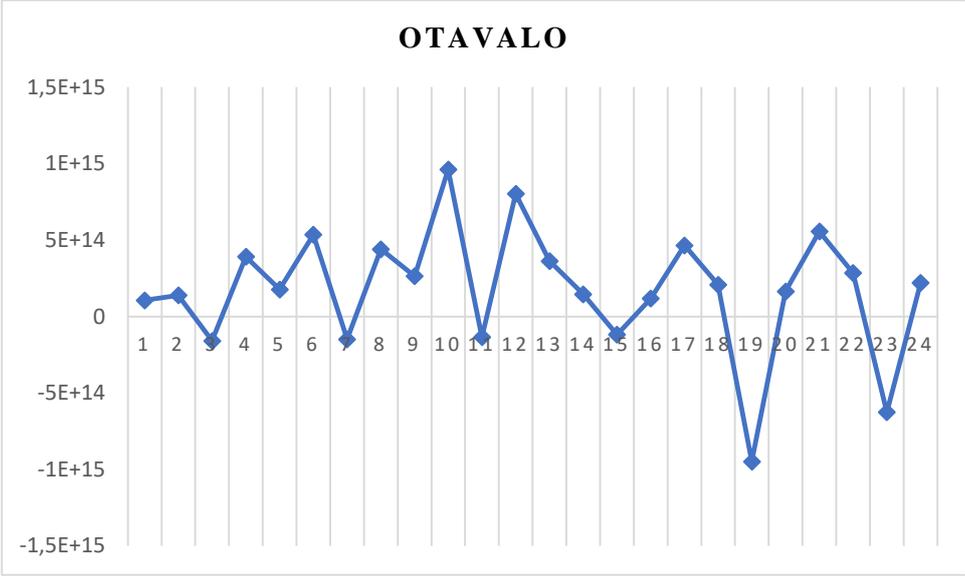


Figura 33: Previsión-Comportamiento Otavalo
Fuente: MATLAB

Es importante destacar que los valores generados para esta subestación son elevados, teniendo incluso un máximo de 15 dígitos, esto incurre en el grado de dispersión existente. Sin embargo, son los valores con mayor confiabilidad dentro de los modelos aplicados, debido a que si consideramos los métodos convencionales aplicados vemos que tanto como el MSE y R muestran una mayor variabilidad en los resultados.

CONCLUSIONES

La fundamentación teórica y legal permitió sustentar de forma objetiva los principios científicos de la investigación como también su importancia en función de la mejora en el proceso de previsión de demanda de energía eléctrica y la utilización de técnicas novedosas como son las redes neuronales artificiales relacionadas con la predicción de la demanda eléctrica.

El diagnóstico al proceso de pronóstico actual de la organización, mostró un alto nivel de incertidumbre en los resultados de previsión, debido a que se utiliza métodos convencionales y además, existe un alto grado de dispersión en los datos de información técnica de demanda de energía eléctrica de las subestaciones Esperanza, Cotacachi y Otavalo.

El diseño del modelo de pronóstico se sustentó en la utilización de redes neuronales artificiales mediante el software MATLAB y su aplicativo Toolbox, obteniendo los mejores resultados en función de métricas de evaluación como MSE y R, además considerando que los resultados de error obtenidos con modelos convencionales existentes en IBM SPSS fueron inclusive el doble en comparación con el modelo de red neuronal propuesto.

Los resultados obtenidos por subestación se ajustan al comportamiento real del sistema de distribución eléctrica, aun considerando que presentan un alto grado de dispersión e inclusive se tuvo que trabajar con demandas negativas, esto es debido a que en el entrenamiento de la red realizado en MATLAB se utilizó el algoritmo de regulación Bayesiana, el cual permitió que las previsiones cuenten con un mayor grado de confiabilidad, precisión e incidiendo así de forma positiva en la obtención de datos para la toma de decisiones en la Dirección de Planificación de la empresa.

RECOMENDACIONES

Se recomienda la implementación del modelo propuesto ya que es necesario para que se generen y visualicen los beneficios expuestos en esta investigación, esto es, el nivel de confiabilidad y desempeño organizacional, que presentan una relación directamente proporcional con la aplicación del modelo en la previsión de demanda de energía eléctrica.

Es necesario la utilización de bases científicas actuales, estas son de vital importancia para sustentar el desarrollo progresivo de la investigación, sin embargo, existen investigaciones de años anteriores que deben ser consideradas, debido al aporte y gran incidencia que generan al enriquecimiento bibliográfico.

El diagnóstico de la situación actual debe permitir identificar los puntos críticos del proceso de pronóstico actual de la empresa, y de esta forma, lograr sustentar un modelo que sea enfocado en la disminución de la incidencia negativa dentro de los resultados de previsión del modelo.

En el diseño del modelo de pronóstico, se hace necesario definir parámetros semejantes dentro de la arquitectura de la red neuronal, tanto como para el conjunto de entrada, entrenamiento y validación, en aras de que las condiciones de aplicación sean las mismas para cada una de las subestaciones y así exista objetividad en los resultados.

Realizar una evaluación de los resultados empleando métricas de evaluación, como el MSE y R, mejorará la interpretación de resultados y de esta forma sustentar la selección de aquel modelo que presente salidas y/o previsiones que al ser comparadas con el comportamiento real del sistema de distribución logren presentar características con un alto grado de similitud.

BIBLIOGRAFÍA

- Acevedo Arenas, C. Y. (2004). *Predicción De Demanda De Corto Plazo Empleando Redes Neuronales*. Universidad Industrial de Santander, Escuela De Ingeniería Eléctrica ...,
- Al-Alawi, S. M., & Islam, S. M. (1996). Principles of electricity demand forecasting. I. Methodologies. *Power Engineering Journal*, 10(3), 139-143.
- Al-bayaty, H., Mohammed, T., Ghareeb, A., & Wang, W. (2019). *City scale energy demand forecasting using machine learning based models: a comparative study*. Paper presented at the Proceedings of the Second International Conference on Data Science, E-Learning and Information Systems.
- Anderson, D. R., Sweeney, D. J., Williams, T. A., Roa, M. d. C. H., & Álvarez, T. L. (2001). *Estadística para administración y economía*: International Thomson.
- ARCONEL. (2015). LEY ORGÁNICA DEL SERVICIO PÚBLICO DE ENERGÍA ELÉCTRICA. In.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31.
- Beale, M. H., Hagan, M. T., & Demuth, H. B. (2010). Neural network toolbox. *User's Guide, MathWorks*, 2, 77-81.
- Dewi, C., & Chen, R.-C. (2019). Integrating Real-Time Weather Forecasts Data Using OpenWeatherMap and Twitter. *International Journal of Information Technology and Business*, 1(2), 48-52.
- EMELNORTE. (2020). Transparencia. Ley Orgánica de Transparencia y Acceso a la Información Pública. In.
- Enriquez, H., Gilberto. (2010). *El ABC del Alumbrado y las Instalaciones Eléctricas en Baja Tensión* (Editorial Limusa, S.A. ed. Vol. 2). México.
- Ethmane, I., Maaroufi, M., Mahmoud, A., & Yahfdhou, A. (2018). Optimization for electric power load forecast. *International Journal of Electrical and Computer Engineering*, 8(5), 3453.
- Feinberg, E. A., & Genethliou, D. (2005). Load forecasting. In *Applied mathematics for restructured electric power systems* (pp. 269-285): Springer.
- Geem, Z. W., & Roper, W. E. (2009). Energy demand estimation of South Korea using artificial neural network. *Energy policy*, 37(10), 4049-4054.
- Gellings, C. W. (1992). Demand forecasting for electric utilities.

- Gonen, T. (1986). *Electrical Power Distribution System Engineering*, McGraw-Hill. *Inc.*, Copyright.
- Goubko, M. V., Kuznetsov, S. O., Neznanov, A. A., & Ignatov, D. I. (2017). Bayesian learning of consumer preferences for residential demand response. *arXiv preprint arXiv:1701.08757*.
- Gupta, Y., & Saraswat, A. (2020). *Machine Learning Techniques for Short-Term Forecasting of Wind Power Generation*. Paper presented at the International Conference on Advanced Machine Learning Technologies and Applications.
- Hagan, M. T., & Behr, S. M. (1987). The time series approach to short term load forecasting. *IEEE Transactions on Power Systems*, 2(3), 785-791.
- Hanke, J. E., & Wichern, D. W. (2014). *Pronósticos en los negocios* (Quinta Edición ed.): Pearson educación.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hu, R., Wen, S., Zeng, Z., & Huang, T. (2017). A short-term power load forecasting model based on the generalized regression neural network with decreasing step fruit fly optimization algorithm. *Neurocomputing*, 221, 24-31.
- Islam, S. M., & Al-Alawi, S. M. (1997). Principles of electricity demand forecasting. Part 2: Applications. *Power Engineering Journal*, 11(2), 91-95.
- Jiang, P., Li, R., Lu, H., & Zhang, X. Modeling of electricity demand forecast for power system. *Neural Computing and Applications*, 1-19.
- Jiménez, A. A., Muñoz, C. Q. G., & Márquez, F. P. G. (2017). *Machine learning and neural network for maintenance management*. Paper presented at the International Conference on Management Science and Engineering Management.
- Kaastra, I., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3), 215-236.
- Karunathilake, S. L., & Nagahamulla, H. R. (2017). *Artificial neural networks for daily electricity demand prediction of Sri Lanka*. Paper presented at the 2017 Seventeenth International Conference on Advances in ICT for Emerging Regions (ICTer).
- Lao, Y. O., Rivas-Méndez, A., Pérez-Pravia, M. C., & Marrero-Delgado, F. (2017). Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales. *Ciencias Holguín*, 23(1), 1-18.
- López, R. F., & Fernández, J. M. F. (2008). *Las redes neuronales artificiales*: Netbiblo.

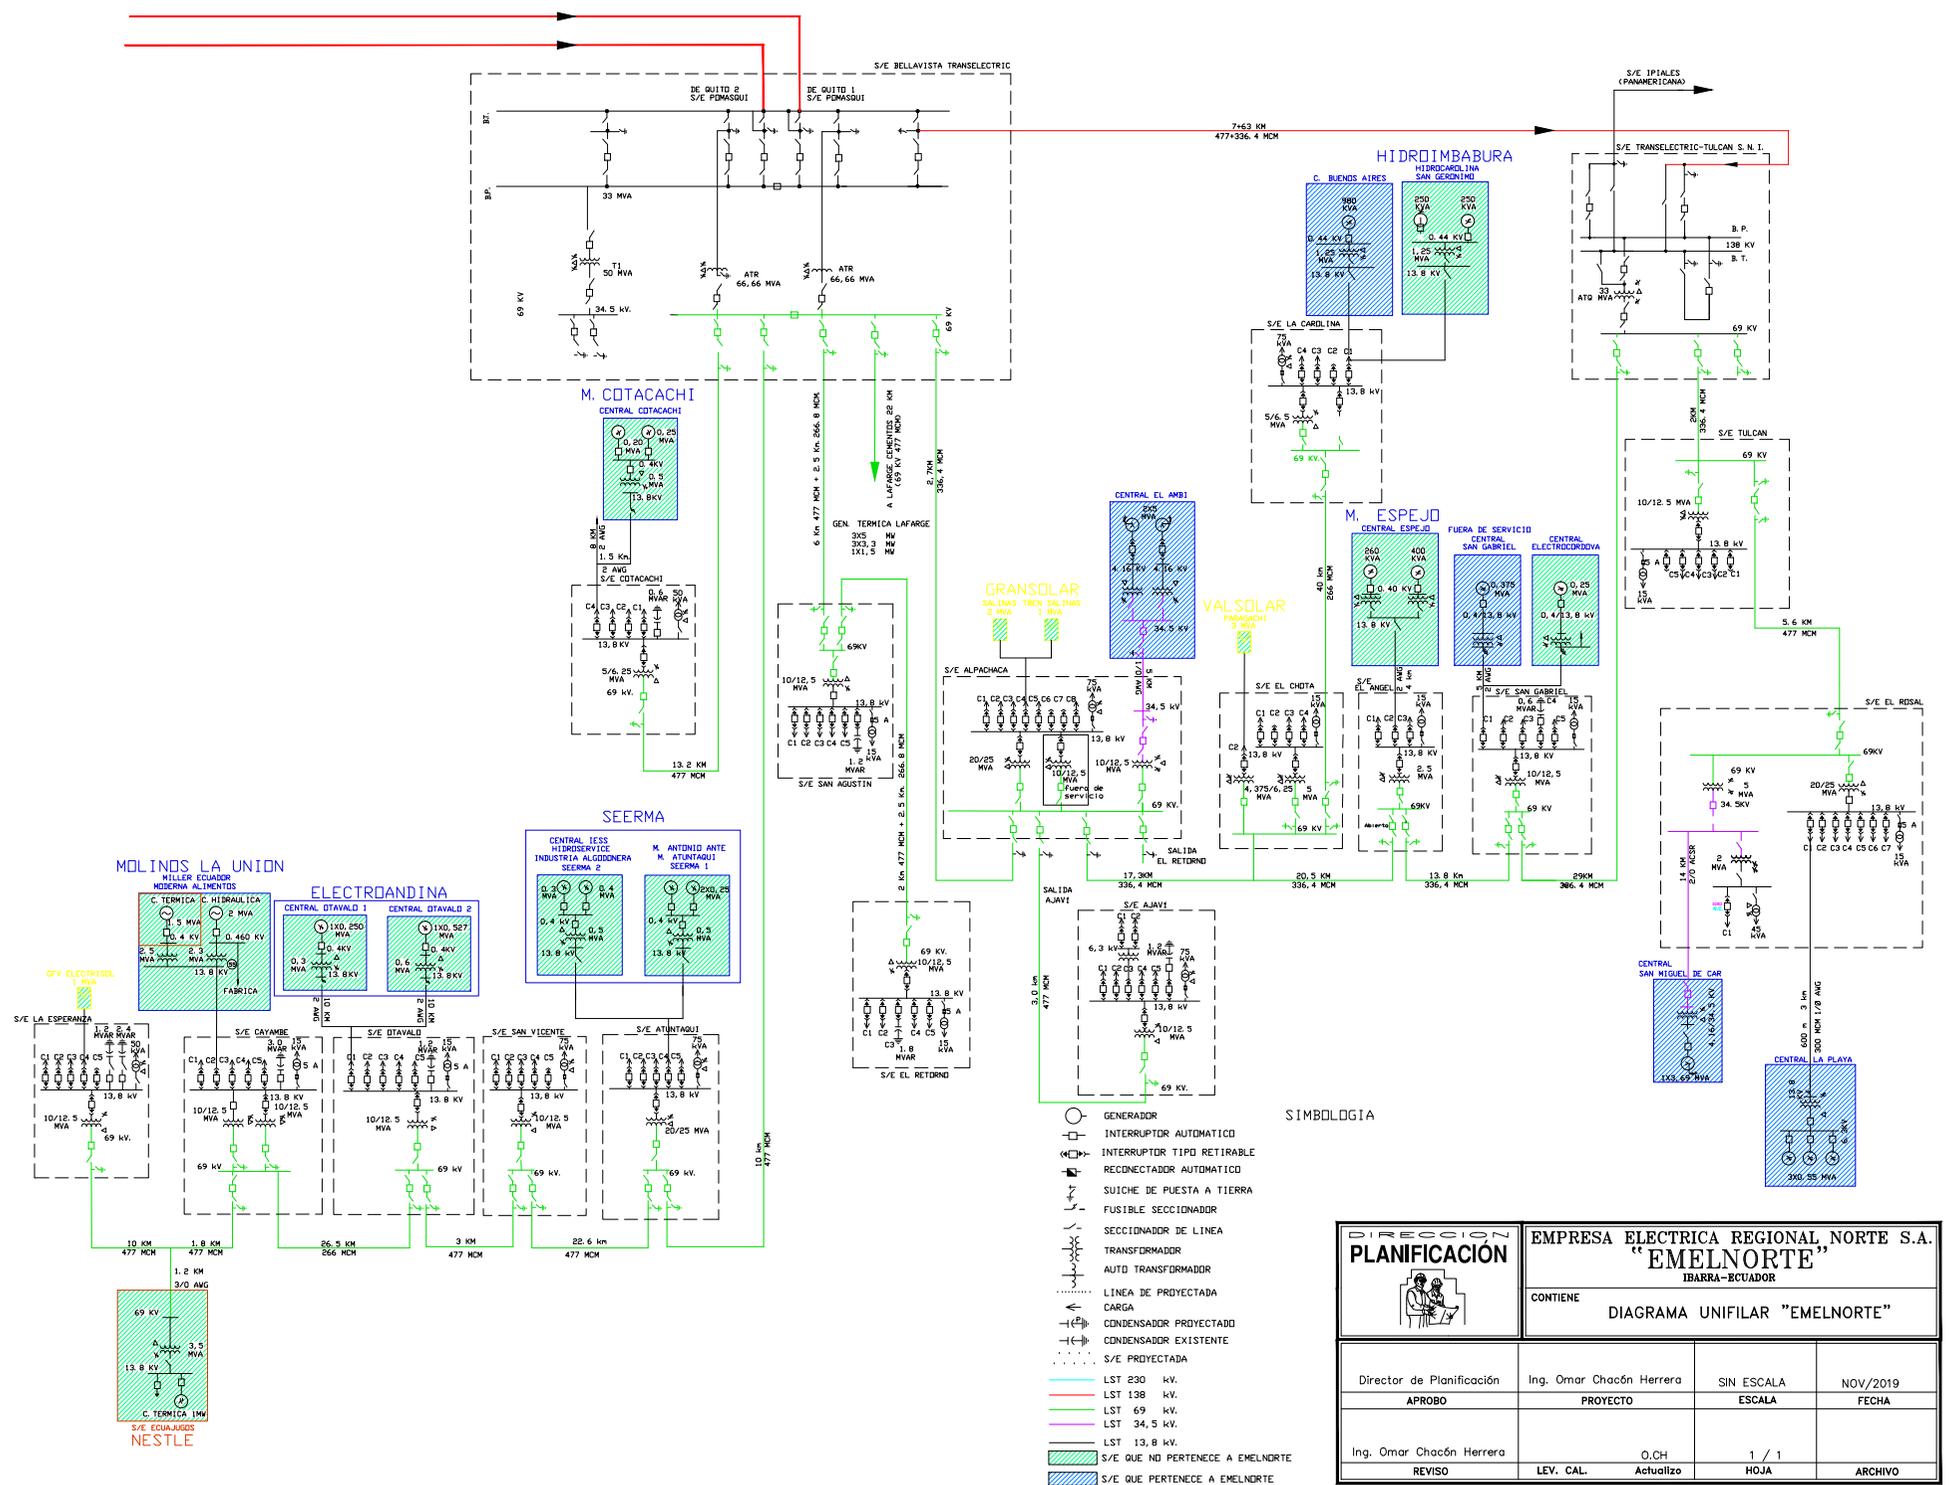
- Ma, Y.-J., & Zhai, M.-Y. (2019). Day-Ahead Prediction of Microgrid Electricity Demand Using a Hybrid Artificial Intelligence Model. *Processes*, 7(6), 320.
- Marugán, A. P., Márquez, F. P. G., Perez, J. M. P., & Ruiz-Hernández, D. (2018). A survey of artificial neural network in wind energy systems. *Applied energy*, 228, 1822-1836.
- MathWorks. (2020). Redes Neuronales. Recuperado de: <https://la.mathworks.com/discovery/neural-network.html>. In.
- Matsila, H., & Bokoro, P. (2018). *Load forecasting using statistical time series model in a medium voltage distribution network*. Paper presented at the IECON 2018-44th Annual Conference of the IEEE Industrial Electronics Society.
- Microsoft. (2020). Previsión y previsión. Funciones lineales. In.
- Momoh, J. A. (2017). *Electric power distribution, automation, protection, and control*: CRC press.
- Panapongpakorn, T., & Banjerdpongchai, D. (2019). *Short-Term Load Forecast for Energy Management Systems Using Time Series Analysis and Neural Network Method with Average True Range*. Paper presented at the 2019 First International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP).
- Pawar, A., Jape, V., & Mathew, S. (2019). Wind power forecasting using support vector machine model in RStudio. In *Cognitive Informatics and Soft Computing* (pp. 289-298): Springer.
- Peng, L., Liu, S., Liu, R., & Wang, L. (2018). Effective long short-term memory with differential evolution algorithm for electricity price prediction. *Energy*, 162, 1301-1314.
- Peña, D. (2013). *Análisis de datos multivariantes*: McGraw-Hill España.
- Ramírez, A. M. A. (2013). *Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución*. Universidad Tecnológica de Pereira. Facultad de Ingenierías Eléctrica ...,
- Sanjinés Tudela, G. N. (2011). Análisis y pronóstico de la demanda de potencia eléctrica en Bolivia: una aplicación de redes neuronales. *Revista Latinoamericana de Desarrollo Económico*(15), 45-77.
- SENPLADES. (2017). Plan Nacional de Desarrollo 2017-2021. Toda una Vida. In.
- Shahid, F., Zameer, A., Mehmood, A., & Raja, M. A. Z. (2020). A novel wavenets long short term memory paradigm for wind power prediction. *Applied Energy*, 269, 115098.
- Sheikh, S. K., & Unde, M. (2012). Short term load forecasting using ANN technique. *International Journal of Engineering Sciences & Emerging Technologies*, 1(2), 97-107.

- Siadén, V., & Andrea, Y. (2012). Aplicación de las redes neuronales artificiales para el pronóstico de la demanda de agua potable en la Empresa Epsel SA de la ciudad de Lambayeque.
- Su, H., Zio, E., Zhang, J., Xu, M., Li, X., & Zhang, Z. (2019). A hybrid hourly natural gas demand forecasting method based on the integration of wavelet transform and enhanced Deep-RNN model. *Energy*, *178*, 585-597.
- Subba Rao, S. (2018). A Course in Time Series Analysis. In: Ders notları, Texas A&M Üniversitesi, ABD.
- Sulandari, W., Lee, M. H., & Rodrigues, P. C. (2020). Indonesian electricity load forecasting using singular spectrum analysis, fuzzy systems and neural networks. *Energy*, *190*, 116408.
- Swaroop, R., & Abdulqader, H. (2012). Load forecasting for power system planning and operation using artificial neural network At Al Batinah Region Oman. *Journal of Engineering Science and Technology*, *7*(4), 498-504.
- Tartibu, L., & Kabengele, K. (2018). *Forecasting Net Energy Consumption of South Africa using Artificial Neural Network*. Paper presented at the 2018 International Conference on the Industrial and Commercial Use of Energy (ICUE).
- Ulkareem, M. A., Awadh, W. A., & Alasady, A. S. (2018). *A comparative study to obtain an adequate model in prediction of electricity requirements for a given future period*. Paper presented at the 2018 International Conference on Engineering Technology and their Applications (IICETA).
- Uniejewski, B., Nowotarski, J., & Weron, R. (2018). ENERGIES_9_621_CODES: MATLAB codes for computing electricity spot price forecasts from "Automated variable selection and shrinkage for day-ahead electricity price forecasting". *HSC Software*.
- Vinagre, E., Pinto, T., Ramos, S., Vale, Z., & Corchado, J. M. (2016). *Electrical energy consumption forecast using support vector machines*. Paper presented at the 2016 27th International Workshop on Database and Expert Systems Applications (DEXA).
- Wang, X., Chen, J., Quan, S., Wang, Y.-X., & He, H. (2020). Hierarchical model predictive control via deep learning vehicle speed predictions for oxygen stoichiometry regulation of fuel cells. *Applied Energy*, *276*, 115460.
- Weron, R. (2017). HOLTWINTERS: MATLAB function to compute forecasts of the Holt-Winters exponential smoothing model. *HSC Software*.

- Yong, B., Xu, Z., Shen, J., Chen, H., Tian, Y., & Zhou, Q. (2017). *Neural network model with Monte Carlo algorithm for electricity demand forecasting in Queensland*. Paper presented at the Proceedings of the Australasian Computer Science Week Multiconference.
- Yu, R., Gao, J., Yu, M., Lu, W., Xu, T., Zhao, M., . . . Zhang, Z. (2019). LSTM-EFG for wind power forecasting based on sequential correlation features. *Future Generation Computer Systems*, 93, 33-42.
- Zavala Hepp, B. I. (2015). Pronóstico de demanda desagregada para una empresa de productos de consumo masivo.
- Zhu, L., Li, M., Wu, Q., & Jiang, L. (2015). Short-term natural gas demand prediction based on support vector regression with false neighbours filtered. *Energy*, 80, 428-436.

ANEXOS

Anexo 1: Unifilar de distribución de EMELNORTE S.A.



SIMBOLOGIA

- GENERADOR
- INTERRUPTOR AUTOMÁTICO
- INTERRUPTOR TIPO RETIRABLE
- RECONECTADOR AUTOMÁTICO
- SUICHE DE PUESTA A TIERRA
- FUSIBLE SECCIONADOR
- SECCIONADOR DE LINEA
- TRANSFORMADOR
- AUTO TRANSFORMADOR
- LINEA DE PROYECTADA
- CARGA
- CONDENSADOR PROYECTADO
- CONDENSADOR EXISTENTE
- S/E PROYECTADA
- LST 230 kV.
- LST 138 kV.
- LST 69 kV.
- LST 34.5 kV.
- LST 13.8 kV.
- S/E QUE NO PERTENECE A EMELNORTE
- S/E QUE PERTENECE A EMELNORTE

DIRECCION PLANIFICACION 		EMPRESA ELECTRICA REGIONAL NORTE S.A. "EMELNORTE" IBARRA-ECUADOR	
CONTIENE		DIAGRAMA UNIFILAR "EMELNORTE"	
Director de Planificación	Ing. Omar Chacón Herrera	SIN ESCALA	NOV/2019
APROBO	PROYECTO	ESCALA	FECHA
Ing. Omar Chacón Herrera	O.CH	1 / 1	
REVISO	LEV. CAL. Actualizo	HOJA	ARCHIVO

Anexo 2: Demanda

Anexo 2.1 Demanda de energía eléctrica-2016

DEMANDA DE ENERGÍA ELÉCTRICA												
AÑO	2016											
MES	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
LA CAROLINA	3731576,33	6071607,98	209999,40	-2025686,27	-1522818,89	322873,62	4933603,20	7009863,29	6266210,80	28545,43	1780689,58	-3400483,04
AJAVI	46392046,85	43408102,4	46382808,3	45246691,88	46350466	44374215,78	45313772,8	44928134,17	43798197	45691378,2	44283143,46	46052200,43
ALPACHACA	26845125,19	18030136,72	35961917,3	39928682,83	38060283,05	35234402,73	18554165,3	12363518,23	9245614,92	25355047,4	20833900,9	21040497,99
ATUNTAQUI	7321734,73	6911243,21	7742336,44	7856701,38	7715872,93	7587928,99	7741779,26	8130551,09	8535042,73	8489122,88	7871711,49	8212016,53
CAYAMBE	43545520,56	38984161,97	40473350,81	40003106,68	40358451,36	38680869,36	40047794	42265020,77	39143703,41	42145624,5	42660193,97	43961739,5
CHOTA	21092919,4	19222808,05	21354027,97	8663692,13	8446159,87	7564980,64	7755090,17	7919910,79	7497965,5	7855258,21	17001615,65	19456990,08
COTACACHI	15110121,98	14725638,31	15678014,06	15118498,45	15508938,00	14812411,73	15434302,85	15457063,71	15037422,73	15616000,74	15325273,39	15757113,35
EL ÁNGEL	8394753,44	8157334,49	8027627,24	7489267,57	7472131,37	7213922,18	7648405,22	8474650,15	8438952,01	8057828,54	8070236,56	7931145,09
EL RETORNO	1660341,70	1583428,01	19723818,22	19227712,85	19761686,39	18856123,33	19434634,35	19697313,15	18987210,94	18923651,57	18035381,87	18750309,22
LA ESPERANZA	57787613,60	52240956,52	51988536,88	51058938,30	51473888,40	48827362,00	51686494,89	55440721,60	52269173,74	54348116,18	54541181,91	56164134,32
OTAVALO	35378046,50	33771224,64	36455741,21	16254833,91	55002,73	33701583,16	11982333,02	34316033,89	35087721,97	36351020,86	34159059,44	34436620,70
SAN AGUSTÍN	39979928,04	37367607,96	40366581,88	38822490,10	39983941,20	38701865,29	39856289,41	40172849,05	38934266,33	43859914,05	43450675,31	46077854,26
SAN GABRIEL	36030715,50	33700869,35	36257379,02	34324616,49	34558095,17	33113266,26	33407007,33	33541059,04	33694418,37	34362354,58	33930912,11	35072227,37
SAN VICENTE	33829971,10	32453550,75	33138534,39	32245009,90	32485947,89	31361796,72	34887950,36	35947171,73	34518146,78	34133499,76	33716866,06	34416545,82
TULCÁN	44722906,04	39755959,56	40163866,19	36995955,43	37124173,66	35874344,55	37266109,56	38908822,95	39788530,61	37568881,89	39977239,04	39161731,52

Anexo 2.2 Demanda de energía eléctrica-2017

DEMANDA DE ENERGÍA ELÉCTRICA												
AÑO	2017											
MES	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
LA CAROLINA	-2223140,83	-1745262,89	-2605366,96	-4719967,78	-5758517,61	-3785869,91	-61969,05	2754380,51	5621475,12	6378208,13	6037159,43	-912362,63
AJAVI	45441470,32	40943160,34	45765327,4	44585522,85	46404361,8	45332597,15	46385735	45811979,01	45103928,24	47094844,8	45691322,02	46887206,1
ALPACHACA	38566119,27	33459661,58	34358883,63	39636148,62	39810389,68	42418562,84	23583367,9	17653102,4	13898774,74	26586685,7	33202966,65	32964791,06
ATUNTAQUI	8034923,58	7459128,42	8780128,99	8245196,22	8976904,83	7937092,67	8771036,58	9248884,24	9100821,53	9605570,72	10301921,35	10669199,75
CAYAMBE	44707752,32	38894090,38	41364297,86	11111950,57	11314470,91	18358553,62	11443356,1	46712403,7	20410699,53	15418518,8	14146488,77	34060183,17
CHOTA	18125542,24	19730964,69	19846415,16	9342517,59	8871287,15	14204368,02	22467362	22606650,6	21552900,66	18491151	16739470,64	21710549,88
COTACACHI	15465821,15	14429916,25	15671855,42	15265846,32	15866297,17	15545143,59	15098463,24	15713841,12	16139637,20	16541832,94	16231580,04	16444269,87
EL ÁNGEL	7370341,06	7164325,82	7775913,14	7818104,64	7904992,99	7705567,24	7857145,59	8245671,15	9500590,99	9209678,96	6523467,08	8397582,25
EL RETORNO	18160871,91	16768327,79	18374206,69	16442581,51	18574560,15	18440495,91	18703284,35	15440798,67	14960997,18	15559918,42	15151816,33	15741637,97
LA ESPERANZA	53705500,90	50795806,38	53502225,64	52776670,47	54162957,49	53649022,17	56282069,76	57858666,46	57639114,04	58821238,22	58178613,07	57761062,28
OTAVALO	34701035,04	31356283,96	36193954,53	34160662,60	37855183,93	38531068,27	39059906,96	38232408,46	39325692,12	40294567,02	39440901,62	42601379,08
SAN AGUSTÍN	43911378,99	40628820,52	45518267,87	43836167,08	45514782,67	44797163,39	45703720,30	48782058,70	49360024,88	50965538,13	49038616,15	51090331,98
SAN GABRIEL	33825120,54	30566000,99	34220178,06	33165957,46	34370211,37	33249165,04	34147328,19	33998298,02	34079244,40	32820894,72	32819819,68	34893474,54
SAN VICENTE	33410692,99	31091409,02	35499666,84	33634596,35	34667440,66	32931862,82	35134182,98	36731247,48	36045396,23	35550022,06	34616450,80	34355241,37
TULCÁN	37828791,06	33920302,27	42772942,52	46598861,98	48437854,31	47324045,75	48212918,82	48035312,71	47040275,32	47302058,09	39923131,67	40406588,92

Anexo 2.3 Demanda de energía eléctrica-2018

DEMANDA DE ENERGÍA ELÉCTRICA												
AÑO	2018											
MES	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
LA CAROLINA	-4534285,92	-2878720,61	-3231519,30	-2841103,24	-5364147,59	-2432868,12	1664167,73	4859630,36	7930459,79	8223953,27	4791999,43	3691333,88
AJAVI	46831546,53	42149679,76	47031338,32	45855909,24	47418005,86	45843949,88	47156543,6	46040885,87	45418232,09	47853516,9	46437101,59	47316593,59
ALPACHACA	35211173,79	29494562,82	33578543,92	38330397,87	39217029,74	30524901,75	21059501,8	21393187,13	15596900,56	15650102,2	25462698,08	29295076,85
ATUNTAQUI	10445542,18	9666297,63	10683378,18	24669191,79	31554966,76	29800603,18	32281873,4	32111022,6	31379264,48	31383153,3	29710443,37	29907119,93
CAYAMBE	43213853,83	42339029,49	45965917,23	44183474,93	44049029,67	41741656,27	45757733,7	47114004,83	49319818,07	57354405	54595178,22	47344099,01
CHOTA	21403718,39	14802938,71	9399150,49	9621259,01	11008561,31	9167533,79	9497152,75	10534413,95	9007119,98	9377850,47	9195320,2	9502382,11
COTACACHI	16262027,13	15159960,74	16832891,47	16276101,38	16741371,33	16291681,28	16792109,83	16961283,93	16541484,11	17130998,71	16635700,00	16893010,00
EL ÁNGEL	7931320,30	7923701,56	2632334,29	8238520,42	8608370,34	8346457,13	9165136,47	9434439,13	9184447,64	10172124,57	9754197,58	9822076,31
EL RETORNO	15416016,26	14183527,79	15975088,58	15525991,34	16022412,69	15333715,12	15955888,98	15902382,62	15663548,02	16578656,92	15151816,33	43850040,22
LA ESPERANZA	57420650,18	54055444,91	58622975,15	58022838,91	58052305,31	57407575,30	59463821,87	55850109,84	31918276,89	54754569,12	51725370,18	53013942,79
OTAVALO	3948040,47	36390801,65	12516328,22	39407896,91	41560568,19	40843130,89	18665263,17	44611253,39	325887333,33	51661332,79	50518401,41	17269467,30
SAN AGUSTÍN	49741253,99	45593901,14	51263683,20	45231905,27	51209495,71	49869538,16	43613950,16	48128145,88	50281346,83	52949532,56	51143424,74	52752664,12
SAN GABRIEL	35114573,55	31833570,15	34767900,14	33699359,46	34834418,64	33684268,34	34558343,73	34281180,32	34563120,30	35527162,35	34282164,81	35769166,11
SAN VICENTE	34175060,71	31993404,89	9032202,41	33402278,17	34578247,50	33481006,76	36626958,87	36583346,54	37004808,99	39278162,91	36497878,07	36020940,71
TULCÁN	38603727,96	32267886,70	40362172,18	39088938,48	42515583,36	42536747,72	45672315,42	43686650,66	41297075,70	42299987,17	40550833,77	40939175,51

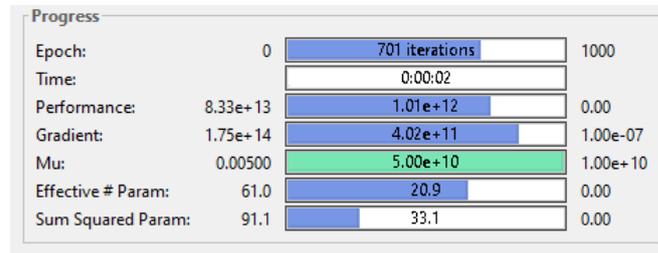
Anexo 2.4 Demanda de energía eléctrica-2019

DEMANDA DE ENERGÍA ELÉCTRICA												
AÑO	2019											
MES	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
LA CAROLINA	5387789,14	3762584,92	3763629,34	-3237871,46	-1652343,89	1703529,71	4711758,35	8481443,50	8036761,29	6921009,53	-2223087,51	-3682537,82
AJAVI	47776664,25	43631061,88	47338835,48	46490906,95	47539636,89	49712075,12	51646289,3	47393947,67	44088596,24	34313390,4	47597461,5	47544430,89
ALPACHACA	27869806,06	26406758,21	31681534,15	31174980,82	31805939,52	26741116,91	30011,76	11793041,31	6601481,34	26059740,6	29276989,39	29301780,49
ATUNTAQUI	30004609,95	27109050,31	37240176,29	35127313,38	29730365,93	28528665,56	32215862,5	32237965,69	30012993,34	29694977,3	38947652,14	37059001,83
CAYAMBE	53930170,7	45759044,15	48634960,54	49942682,96	46519797,62	46676052,13	47685528,2	55704230,45	52395051,3	54357403,4	56223114,23	54236123,34
CHOTA	11187518,56	8600005,87	9591986,18	10414546,2	9998466,61	9289510,53	9411841,4	1156060,4	18050126,68	18538882,5	16149194,8	13032961,33
COTACACHI	17174794,33	14914060,62	23485502,05	23610867,61	15556076,40	17133229,87	18129056,08	180707333,51	17518875,83	14652324,78	15123643,08	18443495,63
EL ÁNGEL	9392236,91	7961895,72	9113829,28	9189079,45	8861481,71	8623015,53	8951441,01	8675152,32	7400957,01	-229736,96	-146372,45	6369978,54
EL RETORNO	50542156,45	45896807,54	48242214,71	49718429,90	51682848,65	10460105,26	51781048,07	51493093,56	49173062,26	51338432,04	16178600,64	52579601,24
LA ESPERANZA	56584365,27	48968046,24	51728138,08	51156924,28	51645339,77	49500043,64	54359268,37	56911470,62	52494747,51	53317282,25	5174213,04	52530504,76
OTAVALO	49320816,18	47552269,94	47046738,64	43601650,82	45501616,99	42527302,58	46906841,04	47128171,43	45687201,10	46661462,61	46576695,33	46761897,52
SAN AGUSTÍN	51320190,63	47877910,82	55246618,67	50703168,85	54148154,15	50012570,05	49340906,82	52618287,36	50150482,29	48201821,46	52515284,00	54460033,94
SAN GABRIEL	35121059,42	31905054,92	35759287,39	34399749,02	18652001,23	34001364,23	18279746,13	34600675,93	33017057,93	35288564,02	35923133,22	36284935,03
SAN VICENTE	37062178,99	34472044,02	29140288,96	28107635,53	43077176,16	41178860,42	43704818,22	44735420,15	39784847,69	38016513,66	38801958,72	37126937,50
TULCÁN	41802456,05	37392172,57	41509053,51	31692403,28	41539008,99	37893604,54	7013204,50	24073185,74	28565451,41	29581543,01	29642610,46	29085271,29

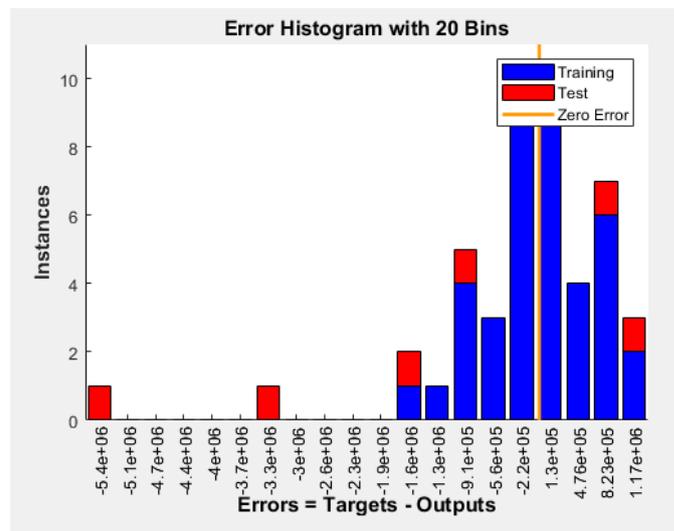
Anexo 3. Entrenamiento de la red neuronal

Anexo 3.1 Subestación La Carolina

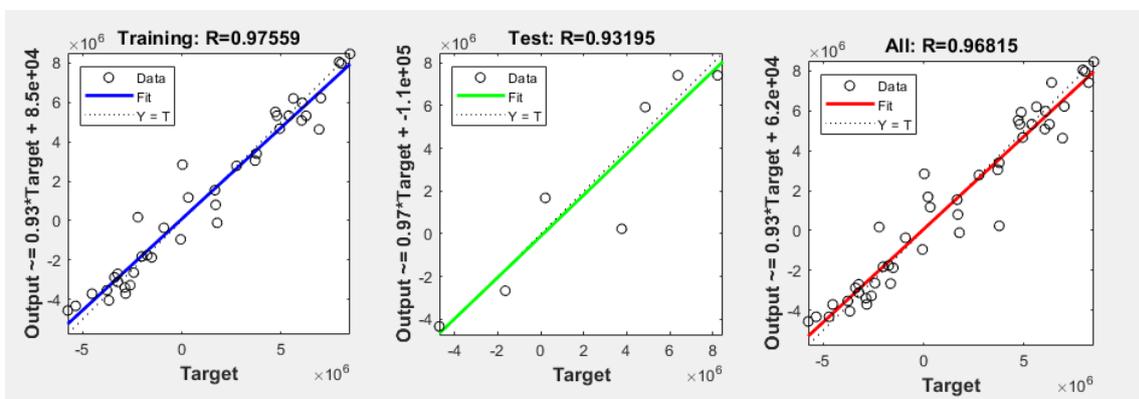
Anexo 3.1.1 Iteraciones



Anexo 3.1.2 Histograma

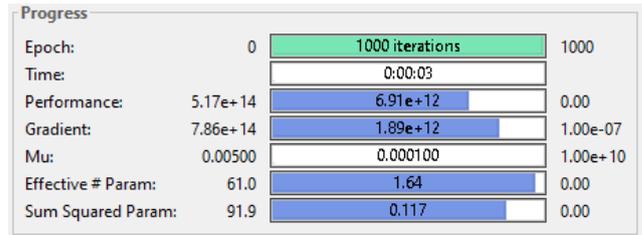


Anexo 3.1.3 Regresión

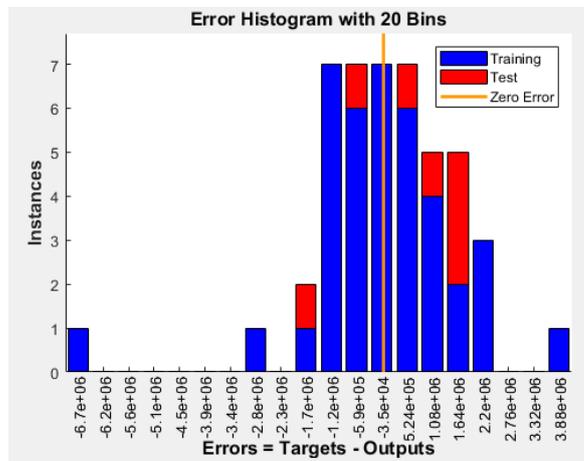


Anexo 3.2 Subestación Ajaví

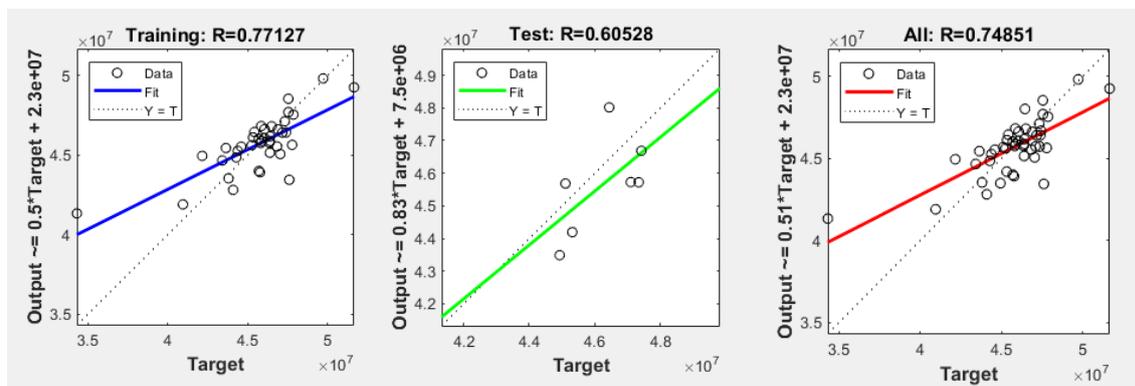
Anexo 3.2.1 Iteraciones



Anexo 3.2.2 Histograma

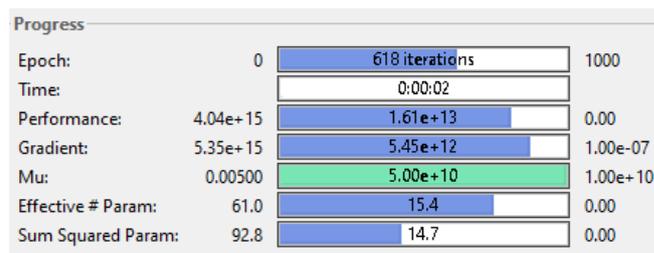


Anexo 3.2.3 Regresión

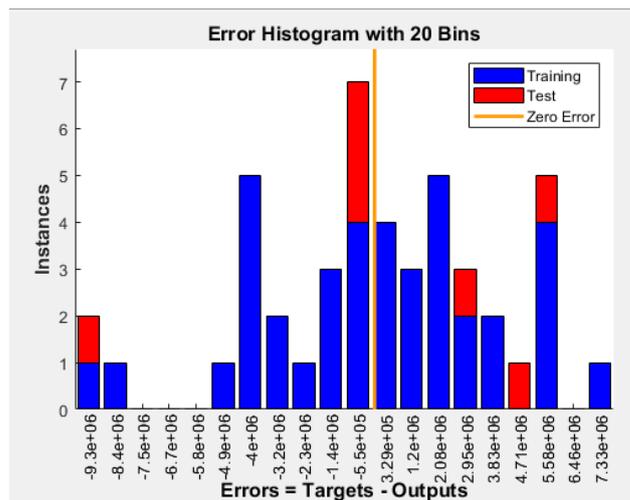


Anexo 3.3 Subestación Alpachaca

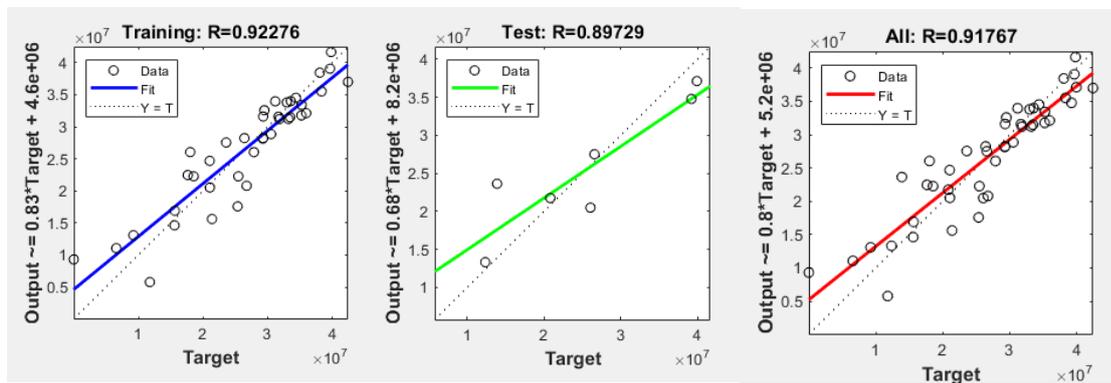
Anexo 3.3.1 Iteraciones



Anexo 3.3.2 Histograma

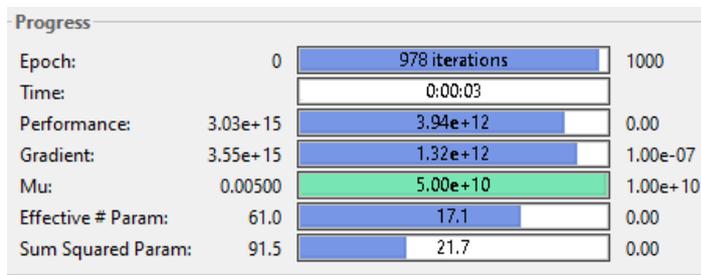


Anexo 3.3.3 Regresión

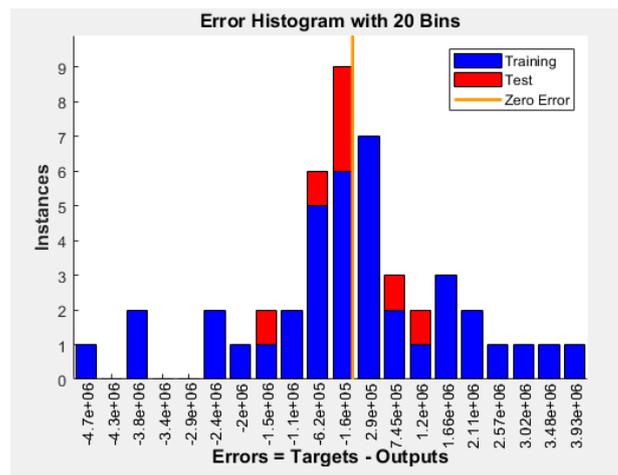


Anexo 3.4 Subestación Atuntaqui

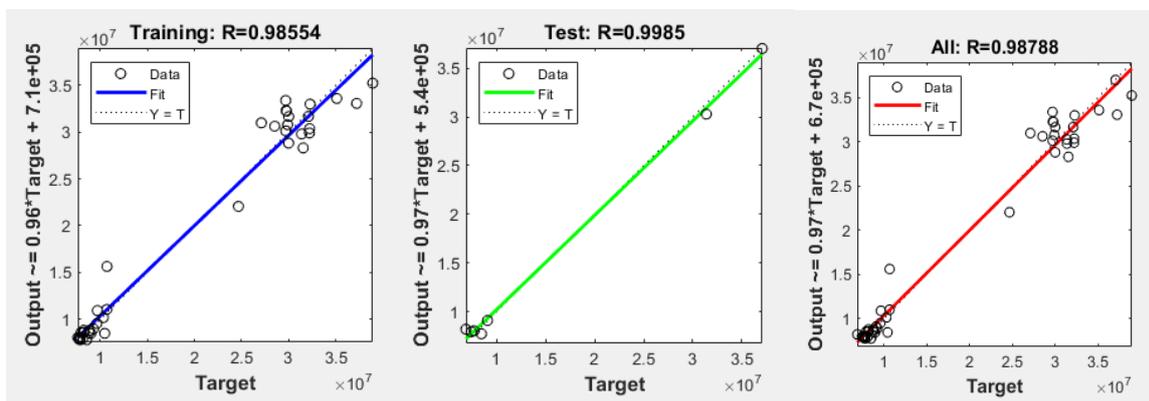
Anexo 3.4.1 Iteraciones



Anexo 3.4.2 Histograma

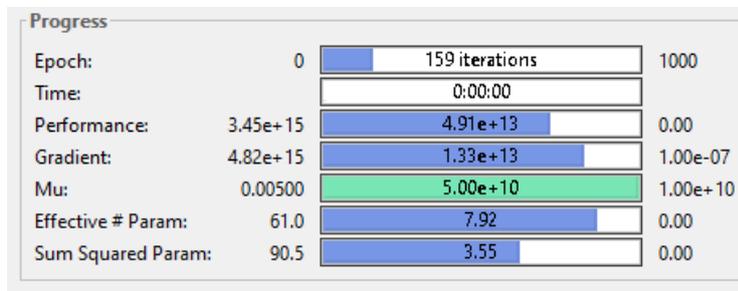


Anexo 3.4.3 Regresión

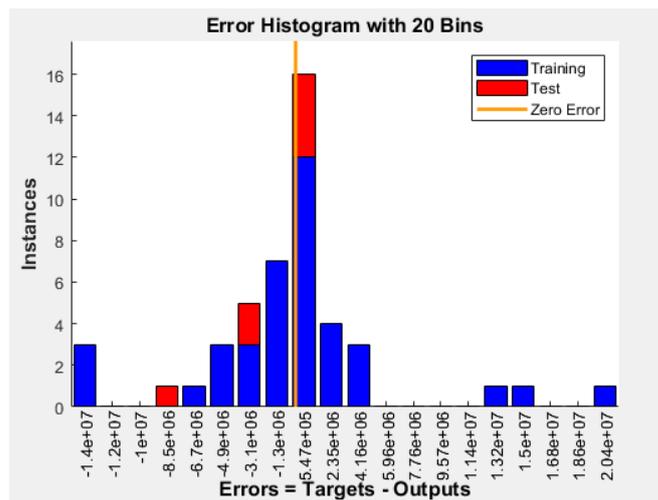


Anexo 3.5 Subestación Cayambe

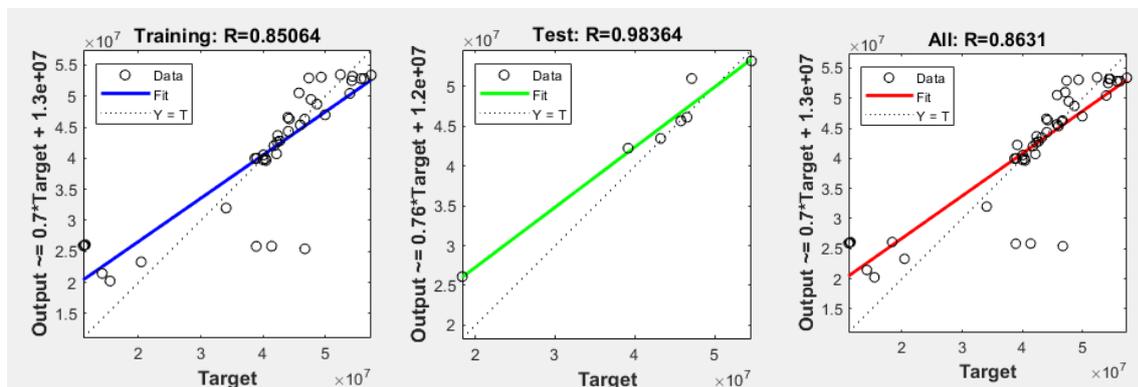
Anexo 3.5.1 Iteraciones



Anexo 3.5.2 Histograma

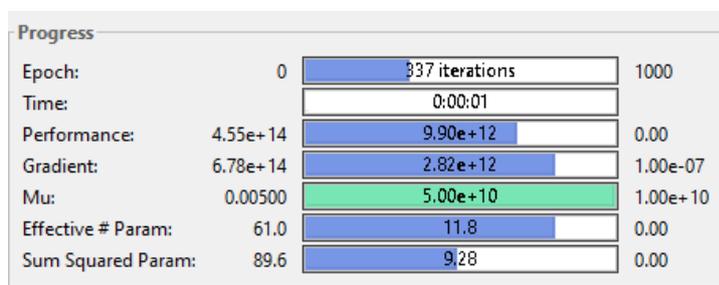


Anexo 3.5.3 Regresión

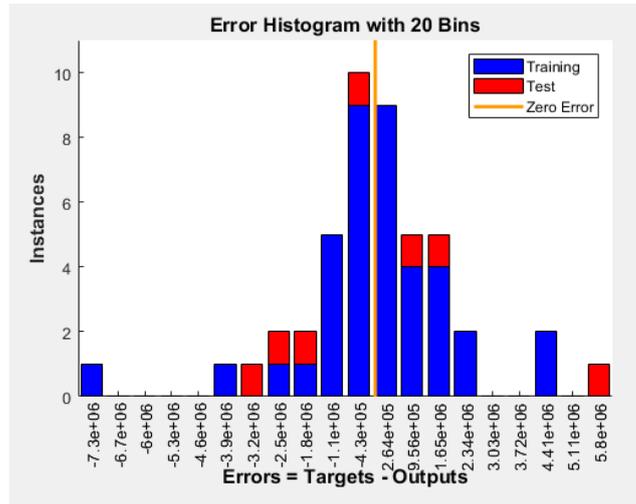


Anexo 3.6 Subestación Chota

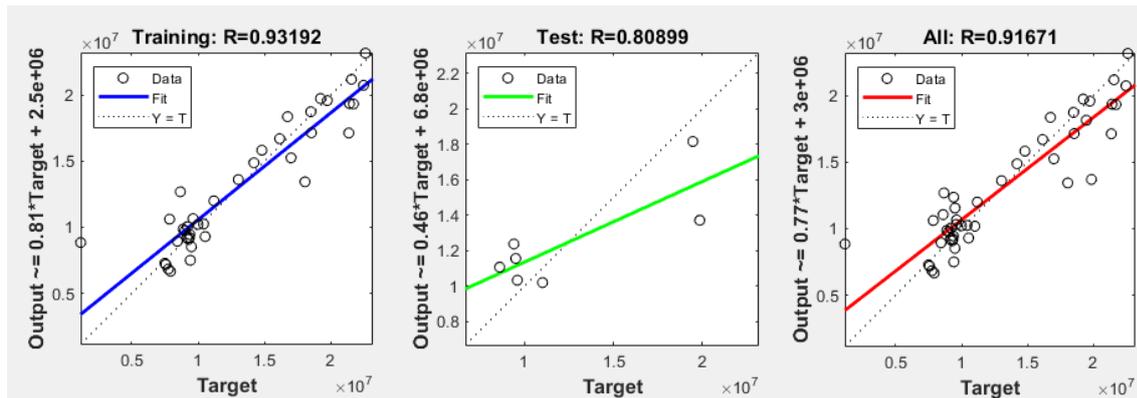
Anexo 3.6.1 Iteraciones



Anexo 3.6.2 Histograma

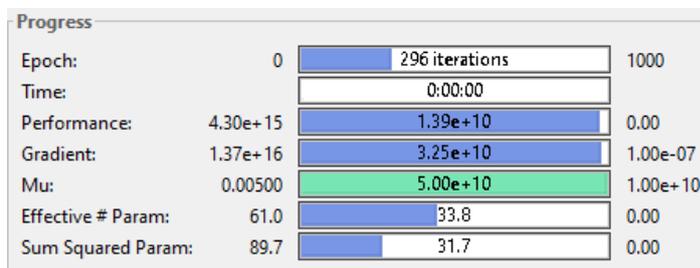


Anexo 3.6.3 Regresión

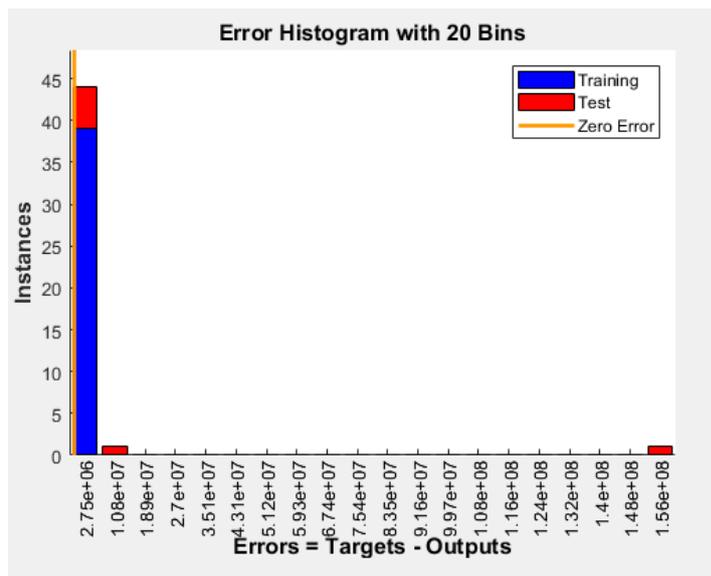


Anexo 3.7 Subestación Cotacachi

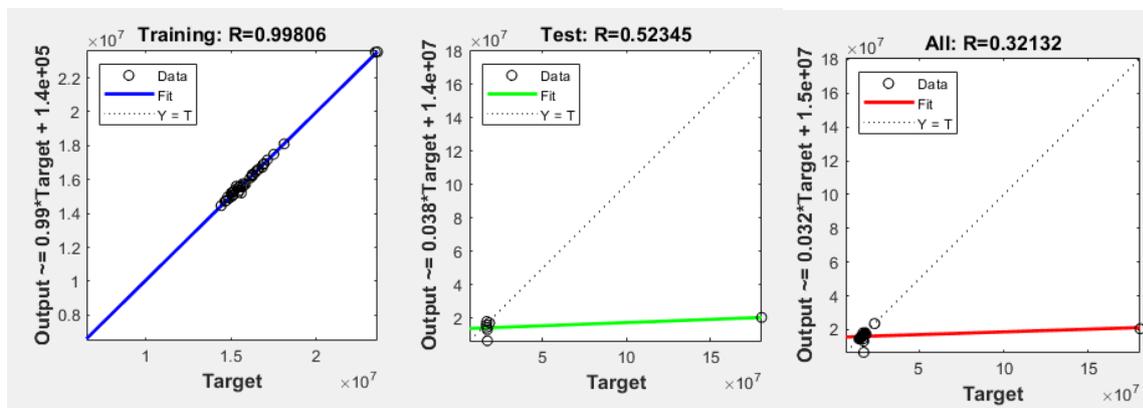
Anexo 3.7.1 Iteraciones



Anexo 3.7.2 Histograma



Anexo 3.7.3 Regresión

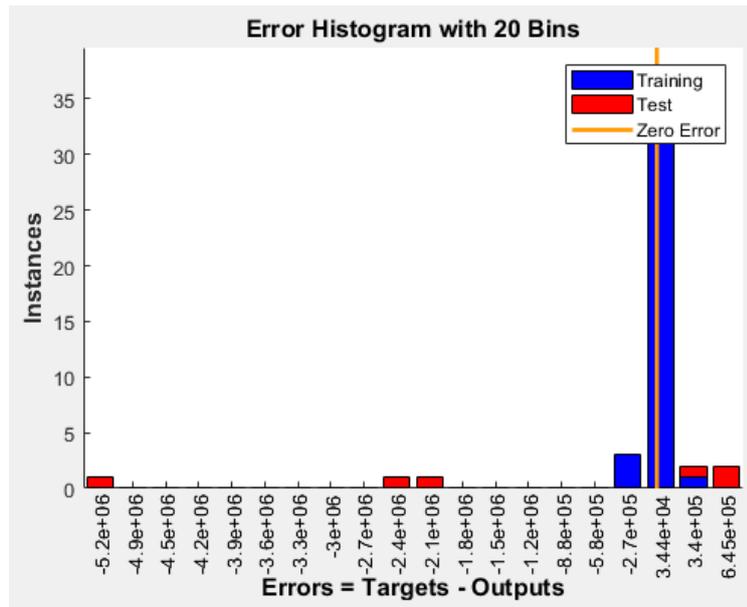


Anexo 3.8 Subestación El Ángel

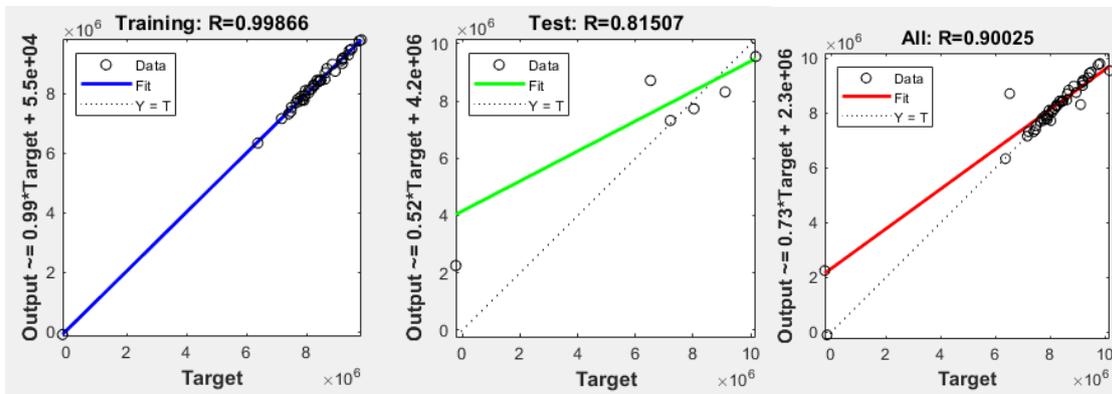
Anexo 3.8.1 Iteraciones

Progress			
Epoch:	0	1000 iterations	1000
Time:		0:00:01	
Performance:	5.30e+13	6.38e+09	0.00
Gradient:	9.77e+13	7.36e+09	1.00e-07
Mu:	0.00500	0.0500	1.00e+10
Effective # Param:	61.0	33.4	0.00
Sum Squared Param:	90.8	109	0.00

Anexo 3.8.2 Histograma

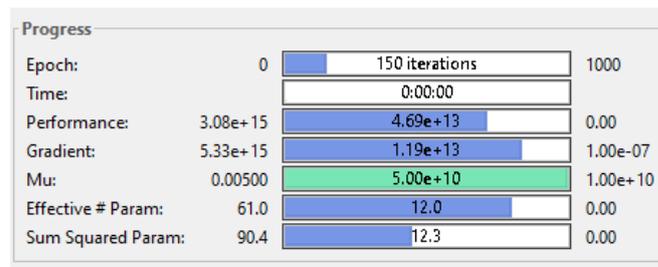


Anexo 3.8.3 Regresión

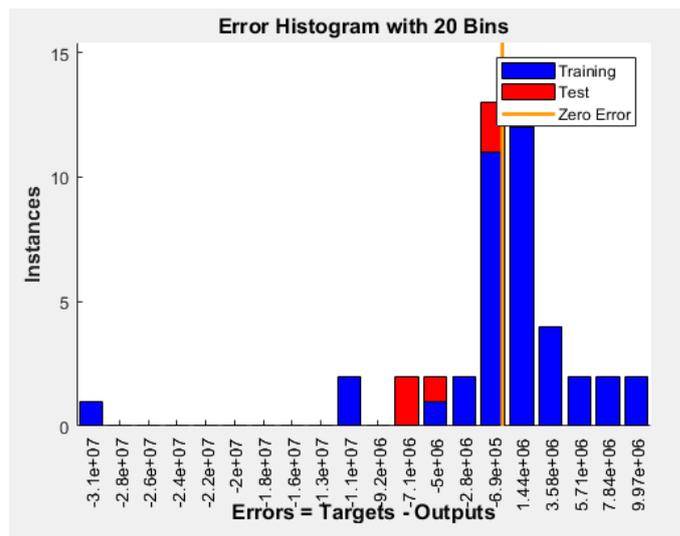


Anexo 3.9 Subestación El Retorno

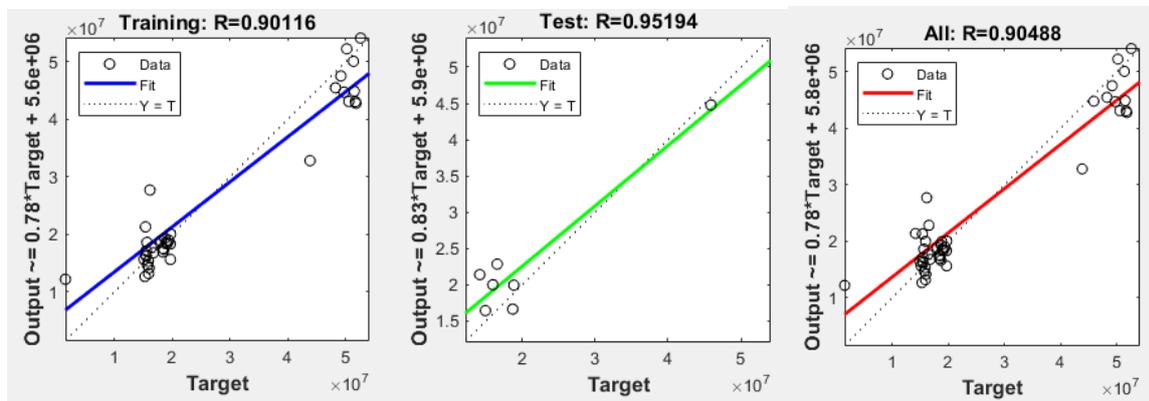
Anexo 3.9.1 Iteraciones



Anexo 3.9.2 Histograma

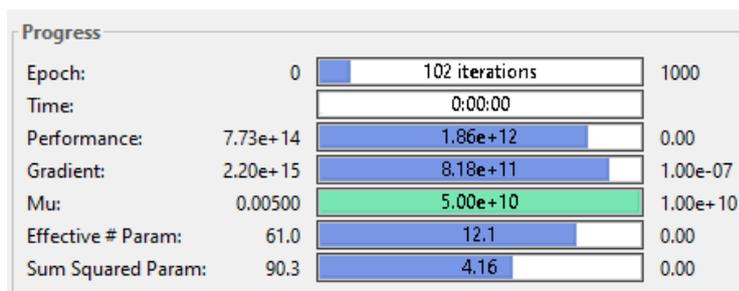


Anexo 3.9.3 Regresión

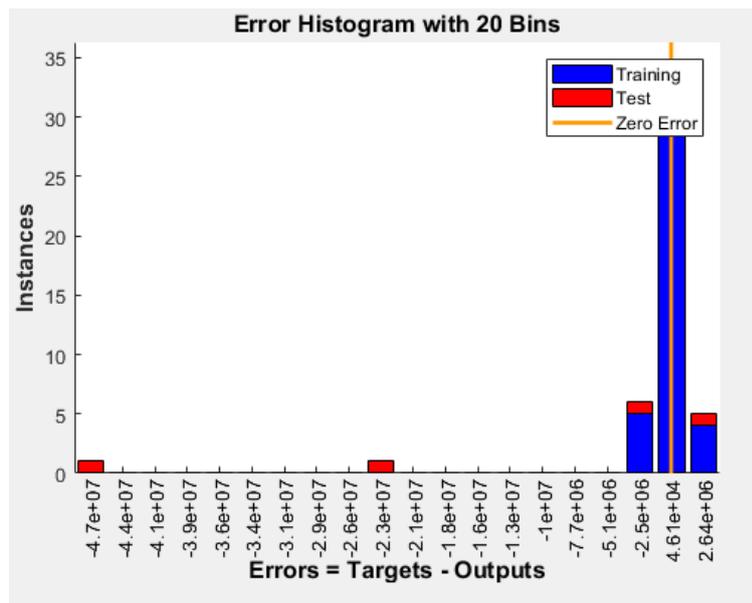


Anexo 3.10 Subestación La Esperanza

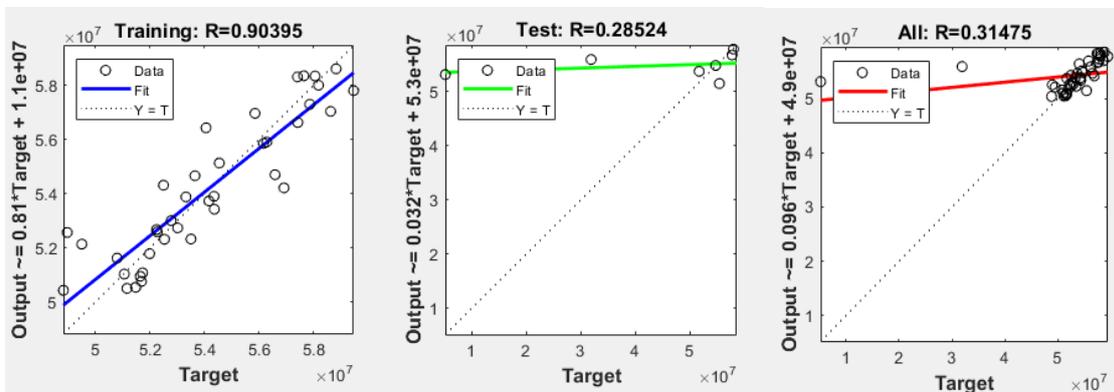
Anexo 3.10.1 Iteraciones



Anexo 3.10.2 Histograma



Anexo 3.10.3 Regresión

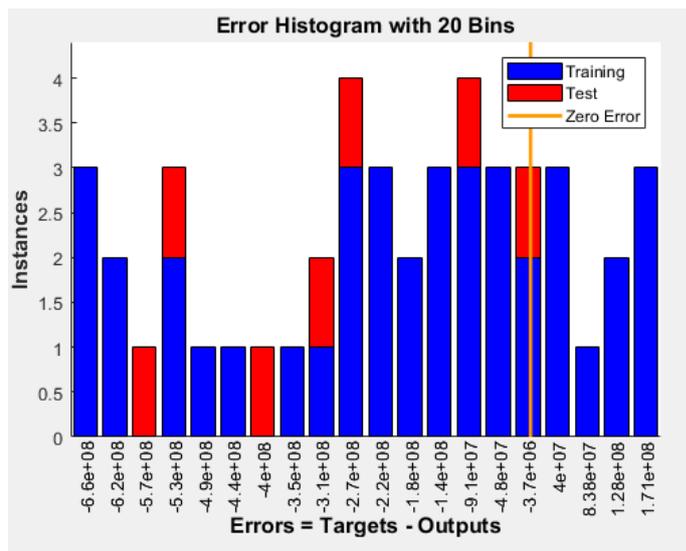


Anexo 3.11 Subestación Otavalo

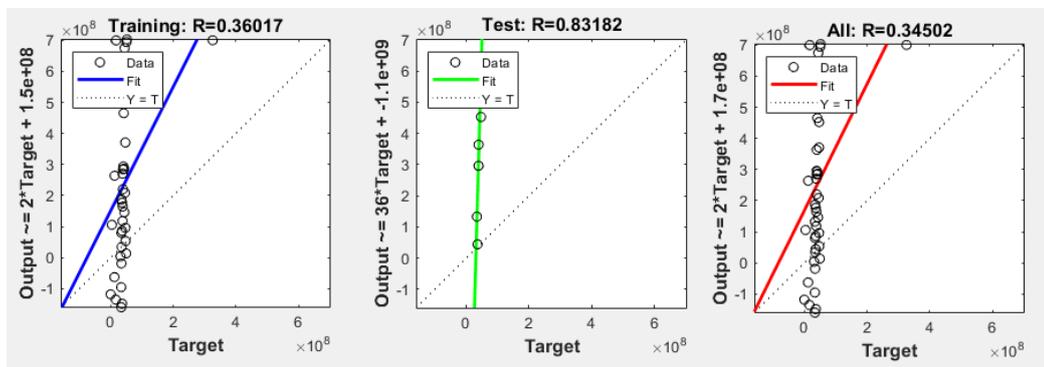
Anexo 3.11.1 Iteraciones

Progress			
Epoch:	0	1 iterations	1000
Time:		0:00:00	
Performance:	1.00e+17	1.00e+17	0.00
Gradient:	1.58e+17	1.58e+17	1.00e-07
Mu:	0.00500	5.00e+10	1.00e+10
Effective # Param:	61.0	61.0	0.00
Sum Squared Param:	91.4	91.4	0.00

Anexo 3.11.2 Histograma

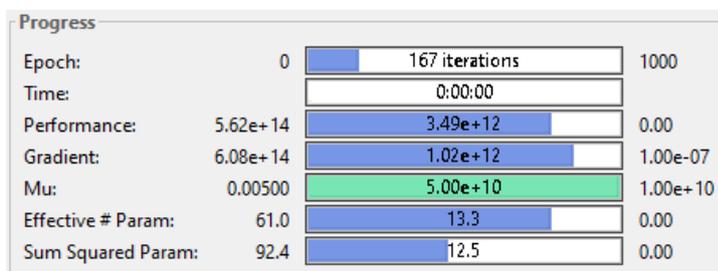


Anexo 3.11.3 Regresión

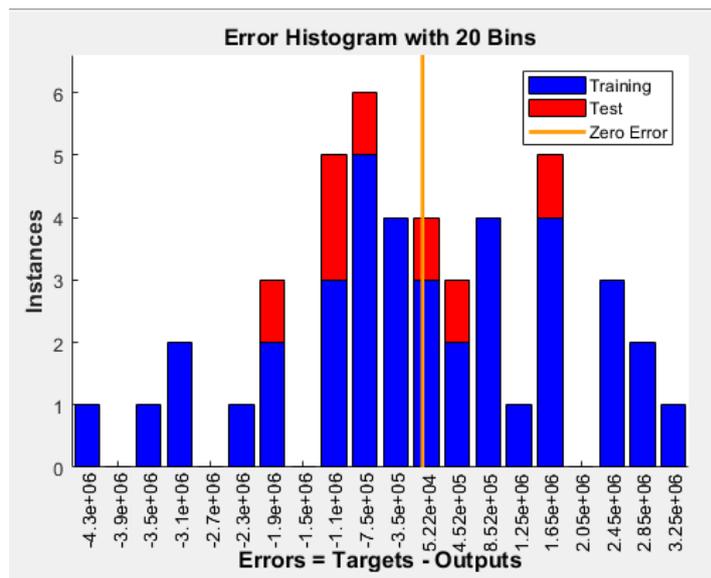


Anexo 3.12 Subestación San Agustín

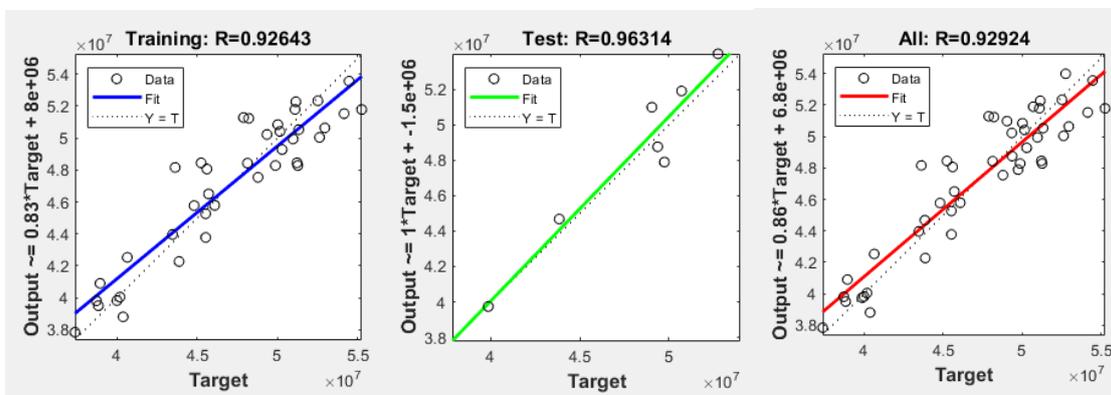
Anexo 3.12.1 Iteraciones



Anexo 3.12.2 Histograma

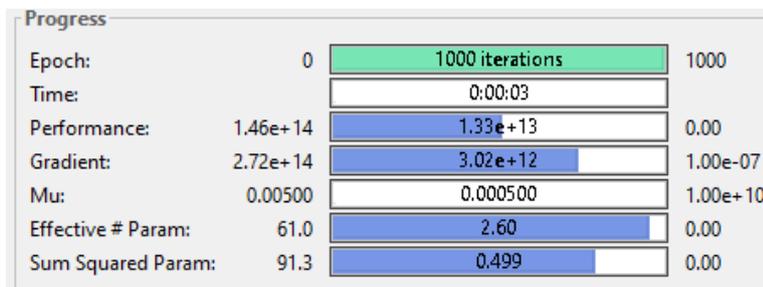


Anexo 3.12.3 Regresión

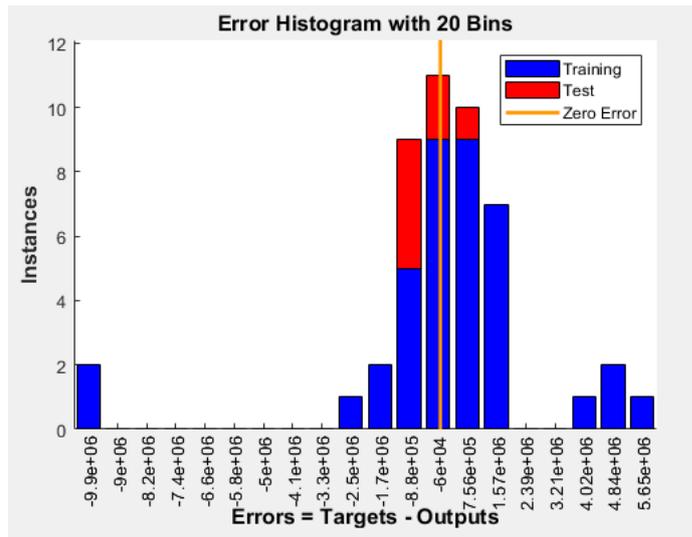


Anexo 3.13 Subestación San Gabriel

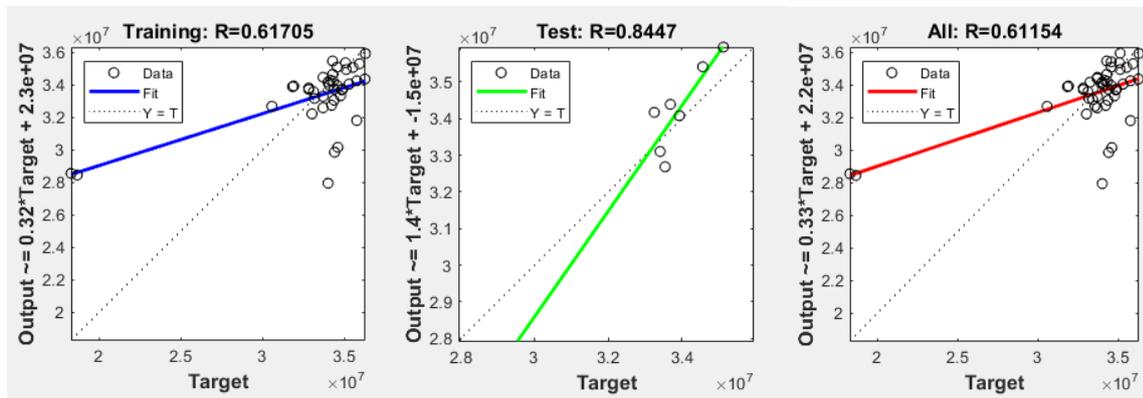
Anexo 3.13.1 Iteraciones



Anexo 3.13.2 Histograma

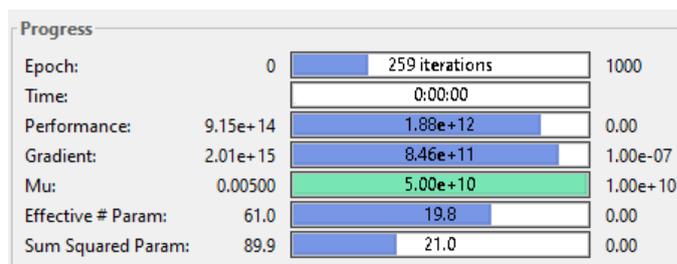


Anexo 3.13.3 Regresión

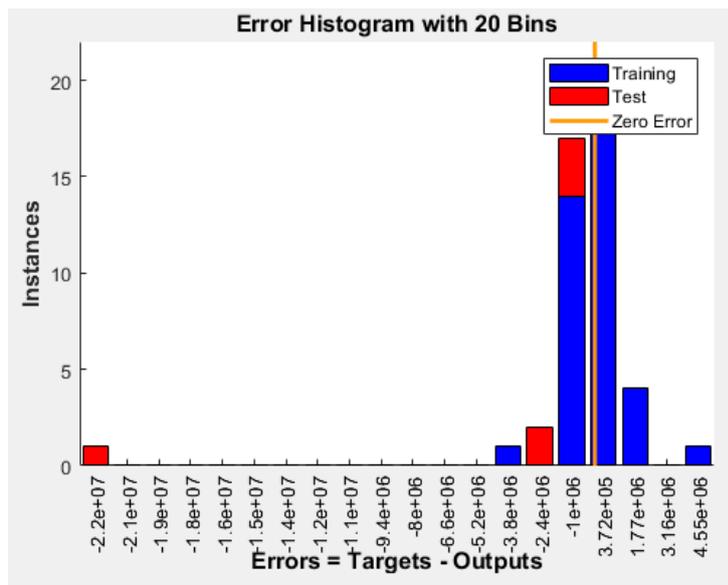


Anexo 3.14 Subestación San Vicente

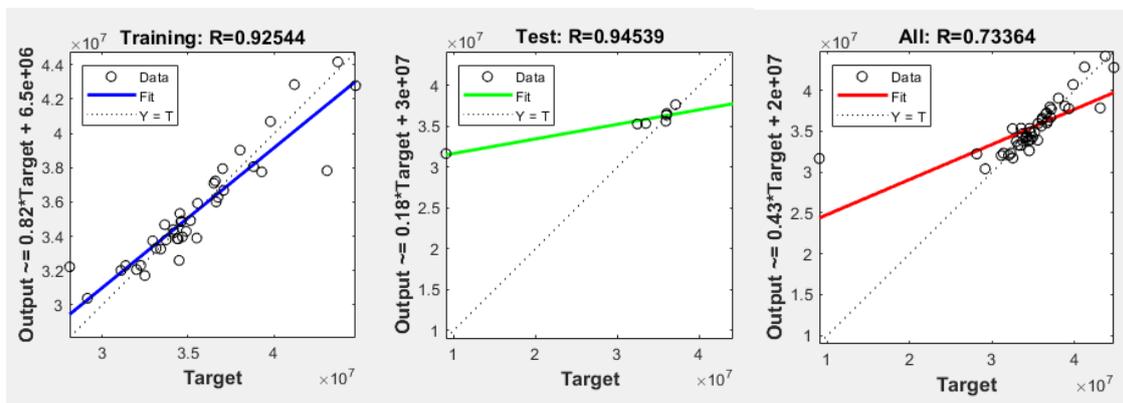
Anexo 3.14.1 Iteraciones



Anexo 3.14.2 Histograma

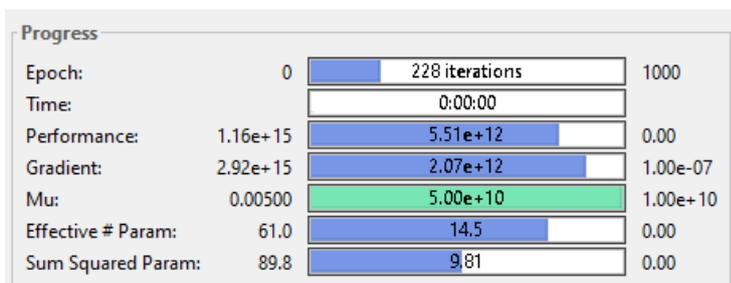


Anexo 3.14.3 Regresión

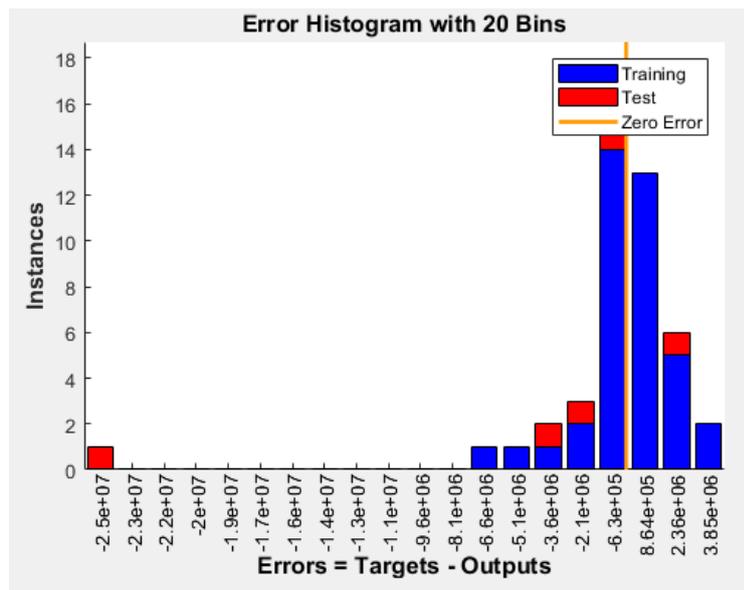


Anexo 3.15 Subestación Tulcán

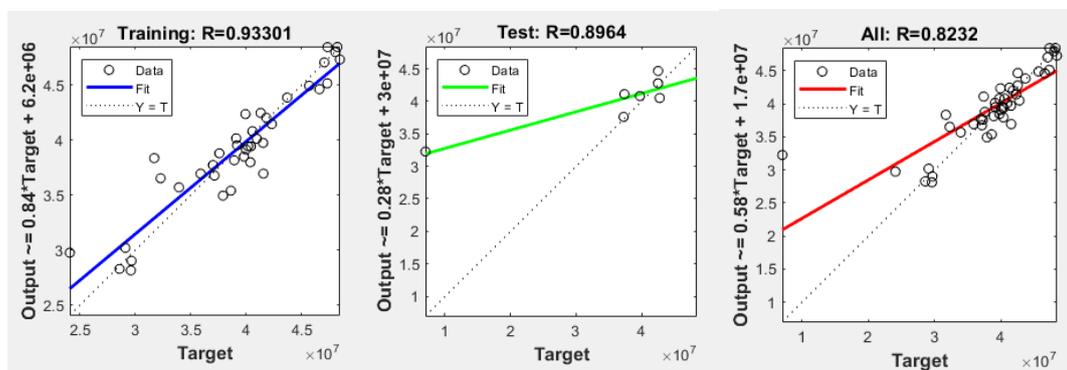
Anexo 3.15.1 Iteraciones



Anexo 3.15.2 Histograma



Anexo 3.15.3 Regresión



Anexo 4. Pronósticos por subestación

Anexo 4.1 Subestación La Carolina

LA CAROLINA				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	-3716646,39	-2109028,7	-2708239,5
	FEBRERO	5327386,27	-1396951,24	-2996887,5
	MARZO	5981952,998	-3165315,04	-3991943,4
	ABRIL	-1763116,62	-5905656,96	-8450945,6
	MAYO	-3396464,74	-6273956,5	-7731232,8
	JUNIO	3400861,44	-3747583,09	-5251292,8

	JULIO	1678510,60	112390,7	-1633283,4
	AGOSTO	-3283125,14	3076830,17	1583911,3
	SEPTIEMBRE	-3124679,78	4264227,88	1861102,4
	OCTUBRE	230420,75	2688431,44	-272053,8
	NOVIEMBRE	-1824169,29	-102803,34	-5356792,8
	DICIEMBRE	-4336685,05	-3775492,39	-474314,1
2021	ENERO	-3712552,72	-2109028,7	-3565240,1
	FEBRERO	-2706796,45	-1396951,24	-3876405,3
	MARZO	-1875645,01	-3165315,04	-5869305,1
	ABRIL	-4570437,46	-5905656,96	-9056395,6
	MAYO	-4334361,29	-6273956,5	-7583092,3
	JUNIO	-2668504,46	-3747583,09	-4780807,7
	JULIO	1167873,70	112390,7	-1738437,4
	AGOSTO	-3540889,10	3076830,17	1332007,4
	SEPTIEMBRE	-2642936,59	4264227,88	565065,7
	OCTUBRE	796914,02	2688431,44	-24422176,8
	NOVIEMBRE	4665481,76	-102803,34	-7509617,3
	DICIEMBRE	-954254,97	-3775492,39	-7101078,6

Anexo 4.2 Subestación Ajaví

AJAVÍ				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	45538350,49	46803596,66	49510043
	FEBRERO	45639657,26	42726165,67	45580338
	MARZO	44659709,02	46822741,85	42535458
	ABRIL	41898547,63	45737922,11	45725259
	MAYO	44946442,53	47121281,91	45781200
	JUNIO	45438669,88	46508873,65	48989866
	JULIO	45145040,22	47818749,23	49538220
	AGOSTO	43915591,87	46236900,61	45425049

	SEPTIEMBRE	45061106,29	44795402,19	44410320
	OCTUBRE	45719813,99	43931446,24	37316812
	NOVIEMBRE	45610045,87	46195420,65	44354275
	DICIEMBRE	45525158,72	47143271,1	44721369
2021	ENERO	45877232,25	46803596,66	45502722
	FEBRERO	46807188,81	42726165,67	42979512
	MARZO	45774878,51	46822741,85	44100857
	ABRIL	46173254,89	45737922,11	45166586
	MAYO	46684496,82	47121281,91	45576202
	JUNIO	48537341,68	46508873,65	45354717
	JULIO	45258694,78	47818749,23	48244968
	AGOSTO	46109201,41	46236900,61	45211765
	SEPTIEMBRE	46820364,35	44795402,19	44695369
	OCTUBRE	49812756,37	43931446,24	41411476
	NOVIEMBRE	44193910,53	46195420,65	45366022
	DICIEMBRE	45879099,26	47143271,1	43416426

Anexo 4.3 Subestación Alpachaca

ALPACHACHA				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	31779634	32108091,65	25903469
	FEBRERO	26045506,8	26832813,88	24159720
	MARZO	26048250	33880252,86	28288522
	ABRIL	31488169,9	37252585,06	28918558
	MAYO	32582881	37208442,62	28774850
	JUNIO	28234277,8	33714777,87	24360020
	JULIO	32120224,4	15791793,18	6703496
	AGOSTO	34525303	15785743,36	12303236

	SEPTIEMBRE	34003459,1	11320723,4	8582636
	OCTUBRE	31575800,3	23397923,53	18527190
	NOVIEMBRE	37123653,8	27179166,79	24877867
	DICIEMBRE	39057210,2	28135562,09	25111543
2021	ENERO	35511920,7	32108091,65	21817896
	FEBRERO	33971075,2	26832813,88	20509532
	MARZO	38445402	33880252,86	26059035
	ABRIL	41659777,6	37252585,06	25476016
	MAYO	34780718,9	37208442,62	23881423
	JUNIO	31191989,7	33714777,87	17952258
	JULIO	33411699,4	15791793,18	-2373876
	AGOSTO	37010384,1	15785743,36	7144268
	SEPTIEMBRE	28854723,5	11320723,4	4202051
	OCTUBRE	20797087,7	23397923,53	16333741
	NOVIEMBRE	22275645,1	27179166,79	21091638
	DICIEMBRE	27551249,1	28135562,09	21254163

Anexo 4.4 Subestación Atuntaqui

ATUNTAQUI				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Aditivo de Winters)	RSTUDIO
2020	ENERO	8463411,54	38524888,63	33184635
	FEBRERO	28828346,3	37353515,01	39559213
	MARZO	8235271,24	40672488,83	37677197
	ABRIL	7975018,35	43529483,29	39769534
	MAYO	10906144,5	44043308,95	40317990
	JUNIO	31001858,1	43006252,68	40325372
	JULIO	7983071,76	44789216,75	47073873
	AGOSTO	8539265,48	44962583,47	45774441
	SEPTIEMBRE	15627382,8	44281406,83	42297401

	OCTUBRE	33081103,3	44311481,11	53573762
	NOVIEMBRE	7773163,16	46220105,88	50861542
	DICIEMBRE	8579515,44	45967907,55	46848970
2021	ENERO	22052536,8	47433672,08	49041136
	FEBRERO	33600374,8	46262298,46	47567762
	MARZO	7836207,23	49581272,29	51600587
	ABRIL	8456374,01	52438266,75	48795641
	MAYO	28315729,4	52952092,41	47655779
	JUNIO	32308686,3	51915036,14	54283612
	JULIO	8020150,01	53698000,21	52427076
	AGOSTO	8546007,69	53871366,93	48780616
	SEPTIEMBRE	32251307,1	53190190,28	55744826
	OCTUBRE	30636747,2	53220264,56	51130895
	NOVIEMBRE	8079015,81	55128889,34	54325243
	DICIEMBRE	8761067,72	54876691	52796539

Anexo 4.5 Subestación Cayambe

CAYAMBE				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	43464572,6	56948610,98	53680361
	FEBRERO	50441106,6	52093362,8	52388003
	MARZO	39996523,2	54708911,32	54669837
	ABRIL	25804105	46909583,02	54737059
	MAYO	43665012	46159716,48	55757281
	JUNIO	50511135	46963561,88	55261199
	JULIO	39647420,9	46832882,02	55232185
	AGOSTO	25841078,7	58548193,89	58567042
	SEPTIEMBRE	45363883,7	50916596,86	59098820
	OCTUBRE	48708478,2	52918266,12	59423436

	NOVIEMBRE	39743672	52505520,11	61592615
	DICIEMBRE	25903705,3	55499806,25	60364849
2021	ENERO	46339740	56948610,98	60648612
	FEBRERO	46985630	52093362,8	59286034
	MARZO	39927342	54708911,32	60782874
	ABRIL	25997259,8	46909583,02	61225704
	MAYO	44337683,7	46159716,48	61692336
	JUNIO	46118739,5	46963561,88	61091658
	JULIO	39965966,2	46832882,02	63106483
	AGOSTO	26096682,4	58548193,89	65371428
	SEPTIEMBRE	42004614,5	50916596,86	65287437
	OCTUBRE	46301569,2	52918266,12	65642322
	NOVIEMBRE	40542581,6	52505520,11	67493772
	DICIEMBRE	26058406,2	55499806,25	67132133

Anexo 4.6 Subestación Chota

CHOTA				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	19360410,8	16030782,7	13490917
	FEBRERO	12001074,8	13667542,65	14564348
	MARZO	19735437,7	13126259,32	19674478
	ABRIL	19579819,1	7588868,31	15510314
	MAYO	15828556,8	7659483,36	16646739
	JUNIO	11055293,4	8134962,88	13949638
	JULIO	17130668,3	10361226,21	16113804
	AGOSTO	13702280,3	8632623,58	16258891
	SEPTIEMBRE	12364941,7	12105392,88	16515616
	OCTUBRE	10316405,1	11644150,35	14952987

	NOVIEMBRE	12686153,7	12849765,84	18349634
	DICIEMBRE	9235708,41	14004089,9	15123987
2021	ENERO	10656288,7	16030782,7	15353567
	FEBRERO	10249080,8	13667542,65	15714343
	MARZO	8942101,48	13126259,32	16758524
	ABRIL	9860830,19	7588868,31	15696505
	MAYO	10186478,5	7659483,36	10775783
	JUNIO	10218259,1	8134962,88	18279214
	JULIO	7183287,42	10361226,21	19100558
	AGOSTO	14876156,9	8632623,58	17343240
	SEPTIEMBRE	9208818,66	12105392,88	16991056
	OCTUBRE	9089570,85	11644150,35	15781787
	NOVIEMBRE	6841162,8	12849765,84	15529757
	DICIEMBRE	20738840	14004089,9	19289651

Anexo 4.7 Subestación Cotacachi

COTACACHI				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	16209600,4	14822143,46	13538136
	FEBRERO	6525023,65	13626346,29	14821314
	MARZO	14755637,2	16736018,06	19589764
	ABRIL	14460802,1	16386780,75	14881504
	MAYO	15286137,9	14737123,03	16769627
	JUNIO	14906680,5	14764568,93	14434721
	JULIO	15577636,3	15182435,31	16253845
	AGOSTO	15564113,7	56028832,87	17032441
	SEPTIEMBRE	16717323,3	15128307,27	16995607
	OCTUBRE	23521059,6	14804241,6	15471654
	NOVIEMBRE	15264252,7	14648001,43	17525842

	DICIEMBRE	15424179,7	15703424,52	14800867
2021	ENERO	16321911,8	14822143,46	15552467
	FEBRERO	23537798,5	13626346,29	15822799
	MARZO	15365825,9	16736018,06	16974201
	ABRIL	15730535,8	16386780,75	15718940
	MAYO	14471920,4	14737123,03	9100527
	JUNIO	15609717,8	14764568,93	17825841
	JULIO	14982354,4	15182435,31	20367008
	AGOSTO	15633085,2	56028832,87	17708688
	SEPTIEMBRE	16290613	15128307,27	18211241
	OCTUBRE	13134825,5	14804241,6	15943203
	NOVIEMBRE	15231947,4	14648001,43	15450653
	DICIEMBRE	15035219,9	15703424,52	19328973

Anexo 4.8 Subestación El Ángel

EL ÁNGEL				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	7934994,02	5012302,31	6047121,7
	FEBRERO	9303657,4	4542008,95	3668821,1
	MARZO	8160956,69	3627642,62	1138985
	ABRIL	7161232,61	4923968,5	5197424,7
	MAYO	7916493,49	4951973,16	5627677,7
	JUNIO	8107462,23	4712471,1	4318944,1
	JULIO	7729956,28	5145763,49	4955161
	AGOSTO	7748419,4	5447710,51	5727731,8
	SEPTIEMBRE	7944830,19	5371471,03	4546515
	OCTUBRE	8315626,59	3542712,23	5045359,9
	NOVIEMBRE	7536905,3	2790631,39	5121354,8
	DICIEMBRE	7908417,26	4870471,54	3730593,5
2021	ENERO	8302117,97	5012302,31	4303634,9

	FEBRERO	9012381,43	4542008,95	5087065,8
	MARZO	7397939,16	3627642,62	3652001,6
	ABRIL	7779132	4923968,5	4062943,8
	MAYO	8484310,09	4951973,16	2251622,1
	JUNIO	8991122,56	4712471,1	2103498,9
	JULIO	7320354,57	5145763,49	3975008,6
	AGOSTO	7811511,29	5447710,51	4231772,9
	SEPTIEMBRE	8452929,42	5371471,03	1325136
	OCTUBRE	8700894,44	3542712,23	-2208081,4
	NOVIEMBRE	7693920,91	2790631,39	-1150604,2
	DICIEMBRE	7801782,6	4870471,54	372109,1

Anexo 4.9 Subestación El Retorno

EL RETORNO				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Aditivo de Winters)	RSTUDIO
2020	ENERO	21325971	46366450,45	28075251,1
	FEBRERO	43093704,4	44529634,9	43765740,1
	MARZO	12224694,6	50500459,9	30091153,9
	ABRIL	16808251,6	50150326,76	35577919,7
	MAYO	21403565,9	51432047,05	50809755
	JUNIO	44779605,6	40694302,98	-31810850,2
	JULIO	15666550,3	51390429,55	12620635,5
	AGOSTO	17551877,5	50555133,3	11160157,2
	SEPTIEMBRE	20007594,4	49617957,9	835817,7
	OCTUBRE	45466373,2	50521928,47	12853999,7
	NOVIEMBRE	18512954,8	41051166,74	-35328604,1
	DICIEMBRE	17729283,1	57652140,41	563884
2021	ENERO	17167859,8	54838230,67	-24639314,2
	FEBRERO	44712598,8	53001415,12	-2629718,1
	MARZO	20040253,9	58972240,12	-24798761,3

	ABRIL	17426179,1	58622106,98	-56791633,6
	MAYO	14189451,1	59903827,27	-3687070,5
	JUNIO	43067111,3	49166083,21	-108086647
	JULIO	19952904,8	59862209,77	-66591996,5
	AGOSTO	16967718	59026913,53	-54517861,2
	SEPTIEMBRE	12702714,2	58089738,12	-81089477,8
	OCTUBRE	42077954,7	58993708,69	-63538245,4
	NOVIEMBRE	19000614,5	49522946,96	-140698316,8
	DICIEMBRE	16650882,7	66123920,63	-96992238,4

Anexo 4.10 Subestación La Esperanza

LA ESPERANZA				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	56627264	52752312,1	57476827
	FEBRERO	54700604,7	47892878,29	30326616
	MARZO	52675639,6	50338315,7	60751928
	ABRIL	51621293,5	49631718,9	28604520
	MAYO	56430220,2	50211525,31	33099744
	JUNIO	52568491,8	48723927,8	53335752
	JULIO	51785772,1	51825863,26	52923194
	AGOSTO	52325987,9	52893212,51	39197700
	SEPTIEMBRE	57037521,4	44958317,83	36542251
	OCTUBRE	51077581,9	51688309,41	51798277
	NOVIEMBRE	51034081	38782869,73	30577732
	DICIEMBRE	53007090,5	51245452,6	42470926
2021	ENERO	57852724,7	52752312,1	-7488245
	FEBRERO	50503375,7	47892878,29	29767125
	MARZO	50544114,2	50338315,7	49834276
	ABRIL	53731355	49631718,9	-2134225

	MAYO	58343719,6	50211525,31	30723760
	JUNIO	50949527,1	48723927,8	-1527516
	JULIO	50433128,7	51825863,26	-5608637
	AGOSTO	54660934,6	52893212,51	27553603
	SEPTIEMBRE	58311838,4	44958317,83	23993903
	OCTUBRE	52139456,6	51688309,41	10168353
	NOVIEMBRE	50759597,6	38782869,73	-24300548
	DICIEMBRE	55906673,9	51245452,6	10633403

Anexo 4.11 Subestación Otavalo

OTAVALO				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	105921880,2	34849240,73	-122459127
	FEBRERO	13857631,69	41279901,23	-44626260
	MARZO	-159510290,8	37065446,84	36863620
	ABRIL	3917391,87	37368517,24	-165328480
	MAYO	176942243,4	35255349,14	-181951642
	JUNIO	53514869,39	42913027,41	-351197044
	JULIO	-148297518	33165842,23	-225444763
	AGOSTO	44091518,98	45084222,98	-212782884
	SEPTIEMBRE	263958821,9	115509243,3	-178077832
	OCTUBRE	96114689,32	47754352	-343878243
	NOVIEMBRE	-134904251,7	46686020,63	-348342016
	DICIEMBRE	80258450,96	39279597,33	-163786547
2021	ENERO	363326463	34849240,73	-194281868
	FEBRERO	146217180,7	41279901,23	-196283344
	MARZO	-117876105,3	37065446,84	-240551354
	ABRIL	118021451,1	37368517,24	-247060711
	MAYO	465358961,1	35255349,14	-192737994

	JUNIO	208651966,2	42913027,41	-182002289
	JULIO	-94851991,62	33165842,23	-239943965
	AGOSTO	164595604,1	45084222,98	-244211895
	SEPTIEMBRE	556507578,6	115509243,3	-307845894
	OCTUBRE	285351869	47754352	-255782848
	NOVIEMBRE	-62600887,05	46686020,63	-231710500
	DICIEMBRE	220415381,8	39279597,33	-285124265

Anexo 4.12 Subestación San Agustín

SAN AGUSTÍN				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Aditivo de Winters)	RSTUDIO
2020	ENERO	47889219,6	52722075,84	53553921
	FEBRERO	50531886,6	49351046,57	50236578
	MARZO	37835899,7	54582833,9	56022513
	ABRIL	42528876	51132514,77	51589162
	MAYO	48065287,2	54198196,47	55922132
	JUNIO	51290261,9	52329397,89	53683099
	JULIO	38798553	51112833,07	49551840
	AGOSTO	43772869,5	53909445,43	53669942
	SEPTIEMBRE	48281726,7	53665621,93	53732526
	OCTUBRE	51793940,2	55478257,86	54826126
	NOVIEMBRE	39499886,5	55520992,29	55834023
	DICIEMBRE	44678497,2	57579101,63	53904227
2021	ENERO	48447906,7	56219587,87	54985155
	FEBRERO	51899681,1	52848558,6	53315030
	MARZO	39822191,2	58080345,93	58247085
	ABRIL	45261702,4	54630026,8	53778439
	MAYO	48452833,3	57695708,5	57701399
	JUNIO	51534599,7	55826909,92	54991880
	JULIO	39803813,3	54610345,1	52782480

	AGOSTO	45771505,3	57406957,46	56459459
	SEPTIEMBRE	48285532,4	57163133,96	54260882
	OCTUBRE	50848066,4	58975769,89	53366642
	NOVIEMBRE	39742246,1	59018504,32	57252832
	DICIEMBRE	46503657,4	61076613,66	56457712

Anexo 4.13 Subestación San Gabriel

SAN GABRIEL				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (ARIMA (0,0,2) (0,0,0))	RSTUDIO
2020	ENERO	34943499,6	33927160,63	53473001
	FEBRERO	35950236,4	34894814,04	50068264
	MARZO	34463145,7	33589693,08	55987200
	ABRIL	32678035,2	33589693,08	51343205
	MAYO	33884453	33589693,08	55799448
	JUNIO	33933846,2	33589693,08	53974106
	JULIO	34360129	33589693,08	49844882
	AGOSTO	32738103,8	33589693,08	53688391
	SEPTIEMBRE	33324422,5	33589693,08	53411010
	OCTUBRE	31804850,8	33589693,08	54520368
	NOVIEMBRE	34215551,5	33589693,08	55373690
	DICIEMBRE	33167966,9	33589693,08	54215791
2021	ENERO	33285161,6	33589693,08	55145970
	FEBRERO	29852263,7	33589693,08	53372171
	MARZO	33965949,3	33589693,08	58663861
	ABRIL	33749436,4	33589693,08	54090754
	MAYO	33690147	33589693,08	58337826
	JUNIO	28445147,4	33589693,08	56011562
	JULIO	33580282,8	33589693,08	53499847
	AGOSTO	34168726,1	33589693,08	57072850

	SEPTIEMBRE	34388316,9	33589693,08	55137221
	OCTUBRE	27938290,5	33589693,08	55225557
	NOVIEMBRE	33101387,2	33589693,08	57790894
	DICIEMBRE	34278008,2	33589693,08	56624407

Anexo 4.14 Subestación San Vicente

SAN VICENTE				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	34208691,7	37416391,85	39765535
	FEBRERO	36676744,5	35299507,07	39449006
	MARZO	35298802	29499568,84	25404923
	ABRIL	32011215,9	34644267,8	40783744
	MAYO	32061660,1	38999083,92	41315456
	JUNIO	32595066,8	37535256,18	44179275
	JULIO	33303664,5	40385346,01	44917017
	AGOSTO	33899213,4	41296158,74	45269682
	SEPTIEMBRE	31655073,9	39635155,71	45296318
	OCTUBRE	30387251,5	39541398,24	44857498
	NOVIEMBRE	32302690,8	38705128,88	43210711
	DICIEMBRE	34679541,9	38276747,21	42990809
2021	ENERO	33255230	37416391,85	4245860
	FEBRERO	32218114,7	35299507,07	43828545
	MARZO	31710636,9	29499568,84	33834978
	ABRIL	33965195,7	34644267,8	38751130
	MAYO	34852238,8	38999083,92	49610696
	JUNIO	37827231,4	37535256,18	46865672
	JULIO	32297191,5	40385346,01	49558626
	AGOSTO	33737942,8	41296158,74	50245188

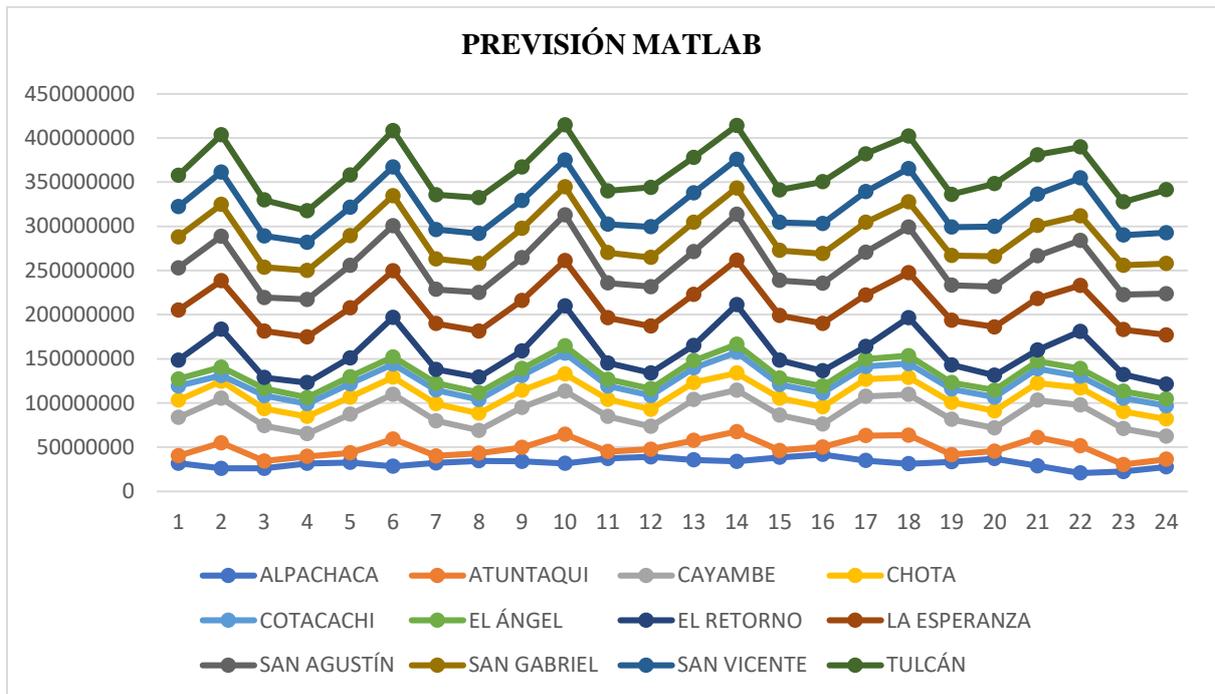
	SEPTIEMBRE	35345554,4	39635155,71	46371187
	OCTUBRE	42849835,1	39541398,24	46810884
	NOVIEMBRE	34290190,9	38705128,88	46411847
	DICIEMBRE	34923840,6	38276747,21	42533497

Anexo 4.15 Subestación Tulcán

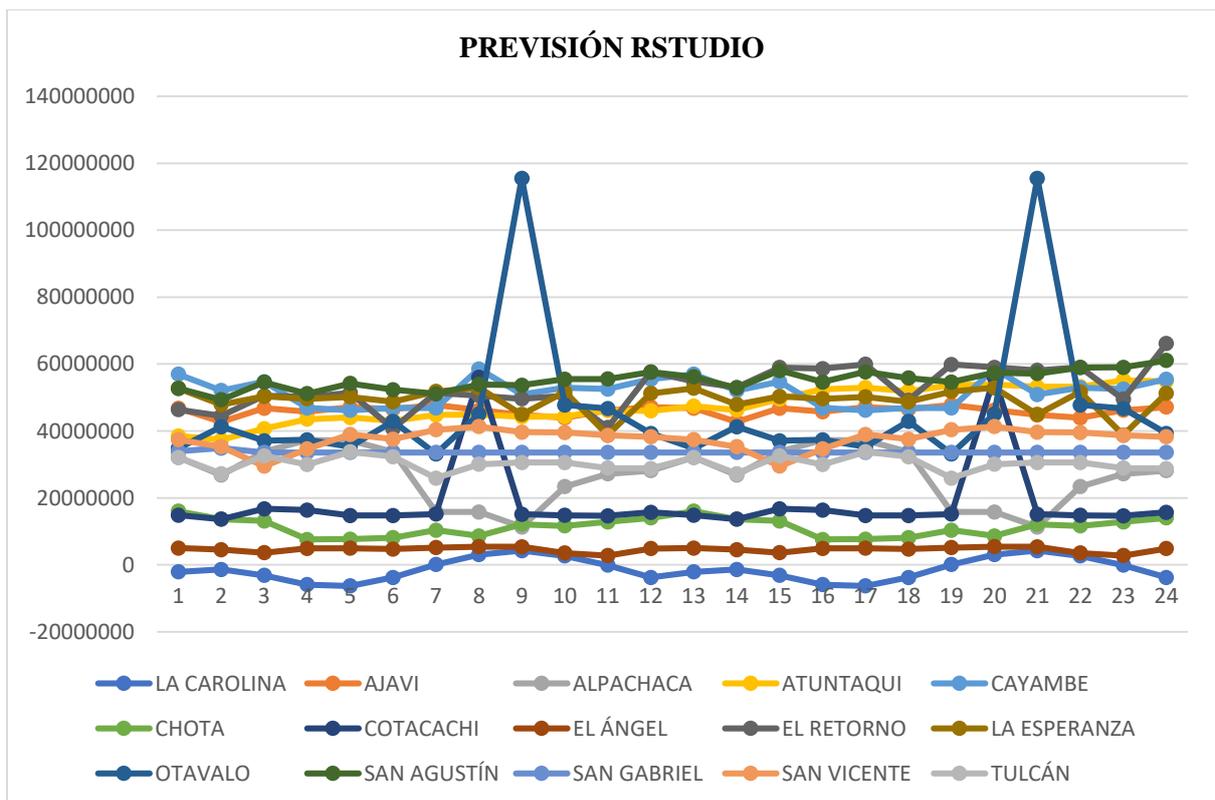
TULCÁN				
HORIZONTE DE TIEMPO		PREVISIÓN		
AÑO	MES	MATLAB	SPSS (Estacional simple)	RSTUDIO
2020	ENERO	35392088,2	32126034,11	35480199,3
	FEBRERO	42021185,3	27220870,98	24479150,7
	MARZO	40813325,8	32588890,09	35221660,5
	ABRIL	35691949,9	29980957,75	28991835,2
	MAYO	36517911,8	33791087,97	16895674,8
	JUNIO	41109356,2	32294125,28	24516883,8
	JULIO	39418875,1	25928081,62	14468670
	AGOSTO	40512707,5	30062944,93	26067081,3
	SEPTIEMBRE	37972603,5	30559801,48	11835501,2
	OCTUBRE	39733919,8	30575125,76	18574210,8
	NOVIEMBRE	37723922,7	28910561,67	22988267,7
	DICIEMBRE	44616631,6	28785548,94	-20019690,6
2021	ENERO	40149522,9	32126034,11	2323457,7
	FEBRERO	38350744,9	27220870,98	4234077,3
	MARZO	36766729,7	32588890,09	-12333990,1
	ABRIL	47311628,5	29980957,75	-5456266,3
	MAYO	42779084,6	33791087,97	-8060891,4
	JUNIO	36944217,3	32294125,28	4212404,1
	JULIO	36941408,9	25928081,62	-8550870,6
	AGOSTO	48438991,3	30062944,93	-343940,9
	SEPTIEMBRE	44673578,6	30559801,48	-1299827,1
	OCTUBRE	34938576,9	30575125,76	-28579069
	NOVIEMBRE	37615003	28910561,67	-9627285,8
	DICIEMBRE	48451405,3	28785548,94	-24768107,6

Anexo 5. Comportamiento Previsión

Anexo 5.1 Previsión MATLAB



Anexo 5.2 Previsión RSTUDIO



Anexo 5.2 Previsión IBM SPSS

