



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO

APLICACIÓN DE LA RED NEURONAL ARTIFICIAL FEEDFORWARD BACKPROPAGATION PARA LA PREDICCIÓN DE DEMANDA DE ENERGÍA ELÉCTRICA EN LA EMPRESA ELÉCTRICA RIOBAMBA S.A

IVÁN FERNANDO SINALUISA LOZANO

**Trabajo de Titulación modalidad: Proyecto de Investigación y desarrollo,
presentado ante el Instituto de Postgrado y Educación Continua de la ESPOCH,
como requisito parcial para la obtención del grado de:**

**MAGÍSTER EN SISTEMAS DE CONTROL Y
AUTOMATIZACIÓN INDUSTRIAL.**

RIOBAMBA - ECUADOR

Octubre 2017

ESCUELA SUPERIOR POLITECNICA DE CHIMBORAZO

CERTIFICACIÓN

EL TRIBUNAL DE TRABAJO DE TITULACIÓN CERTIFICA QUE:

El trabajo de Titulación modalidad Proyectos de Investigación y desarrollo, denominado: “APLICACIÓN DE LA RED NEURONAL ARTIFICIAL FEEDFORWARD BACKPROPAGATION PARA LA PREDICCIÓN DE DEMANDA DE ENERGÍA ELÉCTRICA EN LA EMPRESA ELÉCTRICA RIOBAMBA S.A”, de responsabilidad del Ing. Iván Fernando Sinaluisa Lozano, ha sido minuciosamente revisado y se autoriza su presentación.

Tribunal:

Ing. Fredy Proaño Ortiz, PhD.

PRESIDENTE

Ing. Cristian David Márquez Zurita, Mg.

DIRECTOR DE TESIS

Ing. Jorge Luis Hernández Ambato, PhD.

MIEMBRO DEL TRIBUNAL

Ing. Fausto Ramiro Cabrera Aguayo, Mg.

MIEMBRO DEL TRIBUNAL

DERECHOS INTELECTUALES

Yo, Iván Fernando Sinaluisa Lozano, soy responsable de las ideas, doctrinas y resultados expuestos en este Trabajo de Titulación y el patrimonio intelectual del mismo pertenece a la Escuela Superior Politécnica de Chimborazo.

IVAN FERNANDO SINALUISA LOZANO
No. Cédula: 060311190-7

©2017, Iván Fernando Sinaluisa Lozano

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento, siempre y cuando se reconozca el Derecho de Autor.

DECLARACIÓN DE AUTENTICIDAD

Yo, Iván Fernando Sinaluisa Lozano, declaro que el presente Proyecto de Investigación, es de mi autoría y que los resultados del mismo son auténticos y originales. Los textos constantes en el documento que provienen de otra fuente están debidamente citados y referenciados.

Como autor, asumo la responsabilidad legal y académica de los contenidos de este Trabajo de Titulación de maestría.

Riobamba, 30 de octubre de 2017

IVAN FERNANDO SINALUISA LOZANO
No. Cédula: 060311190-7

DEDICATORIA

A Dios por bendecir cada momento de mi existencia, a mis padres Antonio (+) y María Juana (+) por haberme dado su apoyo incondicional a mis estudios, y por creer siempre en mis capacidades, a Raquel, Ivanna y Abigail por ser los seres que motivan mi superación y a mi familia que siempre me apoyan en cualquier nuevo emprendimiento.

Iván

AGRADECIMIENTO

El más sincero agradecimiento a la Escuela Superior Politécnica de Chimborazo por darme la oportunidad de formar parte de esta prestigiosa institución, al Mg. Cristian Márquez, PhD. Jorge Luis Hernández y Mg. Fausto Cabrera por compartir sus conocimientos, y en especial a Raquel, Ivanna y Valentina por brindar su comprensión y motivar la culminación de este trabajo de titulación.

Iván

ÍNDICE

TEMA	PAG.
RESUMEN.....	xiii
SUMMARY	¡Error! Marcador no definido.
CAPITULO I	
1 INTRODUCCIÓN.....	1
1.1 Problema de investigación.....	1
1.1.1 Planteamiento del Problema.....	1
1.1.2 Formulación del Problema	2
1.1.3 Sistematización del Problema	3
1.2 Justificación de la investigación	3
1.2.1 Justificación Teórica	3
1.2.2 Justificación Práctica.....	4
1.2.3 Justificación Metodológica	4
1.3 Objetivos de la investigación.....	5
1.3.1 Objetivo General	5
1.3.2 Objetivos Específicos.....	5
1.4 Hipótesis de la Investigación.....	5
1.4.1 Identificación de variables	6
1.4.2 Operacionalización de variables.....	6
CAPITULO II	
2 MARCO REFERENCIAL	7
2.1 Estado del arte	7
2.1.1 Predicción de la demanda de energía eléctrica en el mundo.....	7
2.1.2 Evolución histórica de la demanda de energía eléctrica en el Ecuador.....	8

2.1.3	Evolución histórica de la demanda de energía eléctrica en Chimborazo	10
2.1.4	Metodología y modelos utilizados en la actualidad.....	19
2.2	MARCO TEÓRICO.....	22
2.2.1	Neurona biológica.....	22
2.2.2	Neurona artificial	23
2.2.3	Red neuronal artificial.....	23
2.2.4	Clasificación de las Redes neuronales.....	25
2.2.5	Arquitectura de una red neuronal Feedforward	25
2.2.6	Entrenamiento, aprendizaje y ejecución.....	27
2.2.7	Algoritmo Backpropagación	28
2.4.8	Métodos del gradiente.....	34
2.4.9	Función de activación	38
2.5	MARCO CONCEPTUAL O EPISTEMOLOGICO	42
2.5.8	Energía.....	42
2.5.9	Energía eléctrica.....	42
2.5.10	Predicción	43
2.5.11	Métodos de predicción	43
2.5.12	Demanda de energía eléctrica	45
2.5.13	Pronóstico de demanda de energía eléctrica.....	46
2.5.14	Red neuronal	46
2.5.15	Aprendizaje.....	46
2.5.16	Aprendizaje automático	47

CAPÍTULO III

3.	DISEÑO DE LA INVESTIGACIÓN	49
3.1	Metodología de la investigación.....	49
3.2	Preprocesamiento de datos	51
3.2.1	Análisis de la información utilizada	51

3.2.2	Selección de variables	54
3.2.3	Detección y tratamiento de datos perdidos	57
3.2.4	Análisis y tratamiento de datos atípicos	58
3.2.5	Suavizado de la serie temporal.	65
3.3.1	Normalización y acondicionamiento de datos	66
3.3	Diseño del modelo de predicción	68
3.3.1	Arquitectura de la Red Neuronal	68
3.3.2	Aprendizaje de la Red Neuronal	73
3.4	Validación y prueba del modelo	74
3.4.1	Exactitud del modelo de predicción	74
3.4.2	Modelo basado en red neuronal Feed Fordware Backpropagation	75
3.4.3	Modelo basado en Regresión Lineal Múltiple	76

CAPÍTULO IV

4	RESULTADOS Y DISCUSIÓN	79
4.1.	Modelo RNA con datos sin pre-procesar y pre-procesados.	79
4.2.	Modelo de predicción Redes Neuronales vs. Regresión lineal múltiple.	80
4.3.	Determinación de la idoneidad del Modelo de pronóstico	84
4.3.1	Coefficientes de autocorrelación residuales	84
4.3.2	Distribución residual.....	85
4.4	Docimasia de la hipótesis	86

	CONCLUSIONES.....	89
--	--------------------------	-----------

	RECOMENDACIONES.....	90
--	-----------------------------	-----------

BIBLIOGRAFÍA

ANEXOS

INDICE DE TABLAS

Tabla 1-1: Identificación de variables:	6
Tabla 2-1: Operacionalización de variables	6
Tabla 1-2: Clasificación de las redes neuronales artificiales	25
Tabla 1-3: Materiales utilizados en la investigación.....	50
Tabla 2-3: Factores que afectan a la demanda de energía eléctrica.	55
Tabla 3-3: Valores perdidos de las variables consideradas.....	58
Tabla 4-3: Detección de valores atípicos método de los Cuartiles.....	62
Tabla 1-4: Comparación modelo con datos pre-procesados y sin pro-procesar	79
Tabla 2-4: Comparación modelos con Redes Neuronales vs Regresión lineal múltiple	81
Tabla 3-4: Estadísticos de muestras relacionadas	87
Tabla 4-4: Prueba T-student	87

INDICE DE FIGURAS

Figura 1-2: Sistema Eléctrico Nacional.....	8
Figura 2-2: Evolución de la demanda de energía eléctrica en Ecuador	9
Figura 3-2: Consumo de energía eléctrica por sectores en Ecuador	9
Figura 4-2: Crecimiento demanda de energía eléctrica Ecuador 2009 -2016	10
Figura 5-2: Acciones de la Empresa Eléctrica Riobamba S.A.....	11
Figura 6-2: Evolución de la demanda de energía eléctrica en Chimborazo	15
Figura 7-2: Consumo de energía eléctrica por sectores en Chimborazo	17
Figura 8-2: Crecimiento demanda de energía eléctrica Chimborazo 2009 -2016	18
Figura 9-2: Crecimiento de abonados de la EERSA.....	18
Figura 10-2: Cobertura servicio eléctrico en los años 2005-2014.....	19
Figura 11-2: Pronóstico vs real de demanda de energía eléctrica a nivel nacional	20
Figura 12-2: Pronóstico vs real de demanda de energía eléctrica de EERSA	21
Figura 13-2: Estructura de una Neurona Biológica	22
Figura 14-2: Estructura de una Neurona artificial simple	23
Figura 15-2: Arquitectura de una Red Neuronal	26
Figura 16-2: Red Neuronal multicapa con una capa oculta	30
Figura 17-2: Neurona en la capa de salida.....	35
Figura 18-2: Neurona de la capa oculta.....	37
Figura 19-2: Función de activación tipo escalón	39
Figura 20-2: Función de activación lineal	39
Figura 21-2: Función de activación mixta	40
Figura 22-2: Función de activación sigmoideal	41
Figura 23-2: Uso de la demanda dentro de la planificación.....	45
Figura 1-3: Metodología del trabajo de Investigación	49
Figura 2-3: Serie de tiempo demanda de energía eléctrica	52

Figura 3-3: Perfil de carga del diaria por hora del año 2014	52
Figura 4-3: Perfil de carga del diaria por día de la semana año 2014	53
Figura 5-3: Distribución de las Series de Tiempo Demanda Eléctrica y Temperatura	54
Figura 6-3: Correlación demanda de energía eléctrica vs variables calendario	56
Figura 7-3: Correlación demanda de energía eléctrica vs variables meteorológicas.....	57
Figura 8-3: Detección de valores atípicos con diagrama de cajas.....	59
Figura 9-3: Datos atípicos de la serie de tiempo demanda eléctrica	62
Figura 10-3: Datos atípicos de la serie de tiempo Temperatura.....	63
Figura 11-3: Valores atípicos demanda Eléctrica (11h00 y 12h00) noviembre de 2009.....	64
Figura 12-3: Serie de tiempo demanda eléctrica sin valores atípicos.	65
Figura 13-3: Suavizado de la serie de tiempo mediante media móvil.....	66
Figura 14-3: Series de tiempo normalizadas	67
Figura 15-3: Metodología para el diseño de del Modelo mediante Redes Neuronales	68
Figura 16-3: Proceso de generación dinámica de topologías RNA.....	70
Figura 17-3: Arquitectura de la Red Neuronal FeedForward Backpropagación.....	71
Figura 18-3: Comparación del error Regulación Bayesiana y Levenber-Marquardt	72
Figura 19-3: Rendimiento y correlación de entrenamiento de la Red Neuronal.	74
Figura 10-3: MAPE modelo basado en redes neuronales sobre el año 2016	75
Figura 21-3: Coeficiente correlación Modelo Red Neuronal.....	76
Figura 22-3: MAPE modelo basado en regresión lineal múltiple sobre el año 2016	77
Figura 23-3: Coeficiente de correlación modelo Regresión lineal Múltiple	78
Figura 1-4: Modelo con datos suavizados y no suavizados	80
Figura 2-4: Comparación entre el valor real y el pronosticado - mes de abril 2016	81
Figura 3-4: Comparación entre resultado del Modelo RNA y RLM	82
Figura 4-4: Despliegue estadístico de error de pronóstico por Mes.....	83
Figura 5-4: Despliegue estadístico de error de pronóstico por día.....	83
Figura 6-4: Autocorrelación residual del Modelo RNA	84
Figura 7-4: Distribución residual del Modelo RNA	85

RESUMEN

Esta investigación propone un modelo basado en la red neuronal Artificial *Feedforward Back propagation* capaz de predecir la demanda de energía eléctrica con un porcentaje de error absoluto inferior al generado por la metodología utilizada por una distribuidora, con lo cual se pretende contribuir con la planificación de operación y mantenimiento de las centrales eléctricas y a su vez servir de modelo para otras instituciones con similares características. Se realizó la observación de campo a las subestaciones y medidores de las tres salidas, donde se obtuvieron 70128 observaciones de los cuales 61344 se utilizó para el entrenamiento de la red y 8784 para las pruebas del modelo. Mediante preprocesamiento de datos se detectó y corrigió 406 datos perdidos y 320 datos atípicos, mismos que en su mayoría corresponden al año 2009 y 2014, se determinó que el porcentaje del error medio absoluto (MAPE) del modelo de predicción de la demanda de energía eléctrica basado en la red neuronal FeedForward Backpropagation fue del 2,63%, mientras que el basado en regresión lineal múltiple fue del 4,56%. Se concluye que el modelo de predicción de la demanda de energía eléctrica basado en la red neuronal FeedForward Backpropagation es tiene mejor rendimiento de predicción. Se recomienda antes de diseñar un modelo neuronal realizar el pre-procesamiento de los datos para corregir datos atípicos, perdidos y suavizado de la serie temporal con el fin de obtener resultados satisfactorios.

Palabras Clave: <TECNOLOGÍA Y CIENCIAS DE LA INGENIERÍA>, <CONTROL AUTOMÁTICO>, <MODELO DE PREDICIÓN>, <DEMANDA ELÉCTRICA>, <PRE-PROCESAMIENTO DE DATOS>, <REDES NEURONALES ARTIFICIALES>.

ABSTRACT

This research proposes a model based on the artificial neural network *Feedforward Back propagation* capable of predicting the demand of electric power with a percentage of absolute error lower than the one generated due to the methodology used by a distributor, with which it is intended to contribute to the planning of operation and maintenance of power plants and at the same time to serve as a model for other institutions with similar characteristics. Field observations was performed on the substations and measurers of the three outputs where 70128 observations were obtained, of which 61344 were used for the training of the network and 8784 for tests of the model. Through pre-processing of data it was detected and corrected 406 lost data and 320 atypical data, which the majority correspond to the year 2009 and 2014, it was determined that the percentage of mean absolute error (MAPE) of the prediction model of the demand electrical energy based on the neural network Feedforward Back propagation was 2.63%, while the one based on multiple linear regression was 4.56%. It is concluded that the prediction model of the demand for electrical energy based on the neural network FeedForward Backpropagation holds better prediction performance. Before designing a neural, it is recommended to perform the pre-processing of data to correct atypical data, lost and softened of the time series in order to obtain satisfactory results.

Key words: <TECHNOLOGY AND ENGINEERING SCIENCES>, <AUTOMATIC CONTROL>, <PREDICTION MODEL>, <ELECTRIC DEMAND>, <PRE-PROCESSING OF DATA>, <ARTIFICIAL NEURAL NETWORK>

CAPITULO I

1 INTRODUCCIÓN

1.1 Problema de investigación

1.1.1 Planteamiento del Problema

En los últimos años, a nivel mundial el tema energético se ha convertido en un pilar fundamental para el progreso de las naciones, razón por la cual se espera que la demanda de energía a nivel mundial aumente considerablemente en los próximos años a causa de crecimiento demográfico y el desarrollo económico.

La industria eléctrica ecuatoriana ha sufrido transformaciones muy trascendentales en su infraestructura, hecho que ha generado en el país situaciones importantes para el desarrollo, por la cual la disponibilidad de una mayor capacidad de generación eléctrica, también vendrá acompañada por un significativo incremento de la demanda de energía eléctrica (ARCONEL, 2014).

De acuerdo con datos publicados en el Plan Maestro de Electrificación 2013-2022 por el Consejo Nacional de Electricidad (CONELEC), el Ecuador pasará de un promedio del 5,5% en el incremento anual de la demanda de electricidad registrado entre el 2000 y el 2012, a tasas de crecimiento que llegarán hasta el 21,3% anual en el 2017.

La Empresa Eléctrica Riobamba S.A. (EERSA) fue fundada en el año 1963, desde entonces ha tratado de cubrir la demanda a la ciudad de Riobamba y a la provincia de Chimborazo. (EERSA, 2017) .

Es importante mencionar que a nivel nacional la predicción de la demanda energía eléctrica para el sistema de distribución se obtiene mediante modelos convencionales como el de Mínimos Cuadrados Ordinarios (MCO) con la ayuda del software E-VIEWS versión 7 (ARCONEL, 2014), y “Regresión Lineal Múltiple”, modelos que permite analizar diferentes tipos de funciones con el objeto de determinar la que

mejor se adapte y explique la evolución del consumo de energía eléctrica (CONELEC, 2013).

Desafortunadamente ninguna de estas metodologías provee de información confiable en un tiempo relativamente cercano para la toma de decisiones, toda vez que el problema de la predicción de la demanda de energía eléctrica posee una gran complejidad debido a que sus variables no son lineales.

Razón por la cual, el departamento de Planificación encargado de realizar la proyección de la demanda de energía eléctrica, a mediados de cada ciclo realiza ajustes a su proyección, dificultando la planificación de la producción de los centros de distribución y la inversión en nuevos proyectos de generación.

Ante este panorama es inherente la necesidad de un modelo de predicción de la demanda de energía eléctrica más confiables utilizando nuevas técnicas, como técnicas de inteligencia artificial, teniendo en cuenta que estos son la base para una adecuada planeación de redes de distribución de energía eléctrica debido a que se corre el riesgo de una sub generación o sobre generación de energía eléctrica ocasionando pérdidas de carácter operativos y económicos.

Es por eso y teniendo conocimiento de la problemática vigente que está atravesando la planeación de la demanda de las redes de energía eléctrica, para el presente trabajo se utilizarán datos proporcionados por la EERSA, a través de las Direcciones de planificación y operación/generación que brindaron el aval para el desarrollo del presente trabajo de titulación.

Finalmente, en el presente trabajo de titulación propone la evaluación del algoritmo *FeedForward Back Propagation* como técnica de inteligencia artificial para el pronóstico de la demanda de energía eléctrica en la EERSA, para una adecuada planificación y toma de decisiones, y además pretende solucionar un problema arraigado en el proceso de planificación de las empresas eléctrica del Ecuador.

1.1.2 Formulación del Problema

¿Un modelo de predicción basado la red neuronal Artificial *Feedforward Back propagation* minimizará el error de predicción de demanda de energía eléctrica obtenido actualmente por la Empresa Eléctrica Riobamba?

1.1.3 Sistematización del Problema

- a. ¿Cuál es la situación actual del pronóstico de la demanda de energía en la Empresa eléctrica Riobamba S.A.?
- b. ¿Un modelo de predicción basado la red neuronal Artificial Feedforward Back propagation permitirá la estimación de la demanda de energía eléctrica en la Empresa Eléctrica Riobamba S.A.?
- c. ¿El preprocesamiento y filtrado de datos contribuirá a mejorar la predicción de la demanda?
- d. ¿La evaluación de los resultados obtenidos con un modelo de predicción basado la red neuronal Artificial Feedforward Back propagation validará el rendimiento en términos de predicción de la demanda de energía eléctrica?

1.2 Justificación de la investigación

1.2.1 Justificación Teórica

El presente trabajo de investigación evaluará la aplicación de la red neuronal artificial feedforward backpropagation para la predicción de la demanda de energía eléctrica tomando como referencia los datos reales suministrados por la EERSA. Consideramos que el presente trabajo constituirá una base o punto de apoyo importante para profundizar en el estudio del modelo y herramientas de predicción de demanda de energía eléctrica.

Tomando en cuenta que según (Klimasauskas, 1991b) las redes feedforward backpropagation se han convertido en la elección estándar para modelos, predicciones y clasificaciones.

Permitirá contrastar diferentes conceptos y modelos con realidades semejantes a la empresa eléctrica en estudio, bajo la necesidad de indagar los procedimientos que se están realizando actualmente.

Además, con la aplicación de las Redes Neuronales Artificiales (RNA) en la predicción de demanda de energía eléctrica, se resuelve el problema de la complejidad de las metodologías de predicción empíricas que actualmente utiliza la EERSA.

1.2.2 Justificación Práctica

Al diseñar e implementar una red neuronal, utilizando herramientas informáticas donde se pretende simular una aplicación práctica basada en técnicas innovadoras de aprendizaje automatizado que ayude a predecir la demanda de energía eléctrica, lo que permitirá optimizar los recursos en la planificación y operación de las distribuidoras.

Desde el punto de vista energético, la predicción de la demanda de energía eléctrica resulta útil tanto para el operador del sistema de distribución como para los agentes del mercado mayorista de energía eléctrica. Así, el operador del sistema eléctrico necesita conocer con antelación suficiente, la cantidad de energía que será inyectada en la red para gestionar la potencia que deberán generar las centrales, esto con el objetivo de cubrir la demanda total del sistema.

Con los resultados obtenidos se tendrá también la posibilidad de proponer cambios en los estudios de proyección de energía eléctrica a nivel nacional, y contribuir con la matriz energética y con Plan Nacional del Buen Vivir 2013 -2017 (PNBV 2013-2017), su objetivo número 7, política número 7.4 lineamiento e: Investigar los usos potenciales de la biodiversidad para la generación y aplicación de las nuevas tecnologías que apoyen los procesos de transformación de la matriz productiva y energética del país .

1.2.3 Justificación Metodológica

Para lograr los objetivos de estudio, se acude al empleo de técnicas de investigación como la observación directa, la entrevista, la revisión bibliográfica y su procesamiento en software, para conocer los métodos adecuados para la predicción de la demanda de energía eléctrica, adquisición de datos y tratamiento de información.

Además, que con ello se podrá determinar que el modelo predictivo seleccionado es el más adecuado debido a que se ajusta la realidad de la demanda de energía en la empresa eléctrica de Riobamba. Así, los resultados de la investigación se solventan en el diseño e implementación de la red neuronal Backpropagation para la predicción de la demanda de energía eléctrica, modelo que podrá ser aplicable en entornos similares.

1.3 Objetivos de la investigación

1.3.1 Objetivo General

Proponer un modelo basado en la red neuronal Artificial *Feedforward Backpropagation* que sea capaz de predecir la demanda de energía eléctrica con el menor porcentaje de error al generado por la metodología actual, utilizando datos históricos suministrados por la Empresa Eléctrica de Riobamba.

1.3.2 Objetivos Específicos

1. Indagar sobre los modelos de predicción de demanda de energía eléctrica que utilizan actualmente en las empresas comercializadoras de energía eléctrica en el país.
2. Desarrollar el preprocesamiento de datos para el mejoramiento de la calidad de los mismos.
3. Realizar los entrenamientos de la red neuronal *FeedForward Back Propagation*, para determinar el modelo de predicción más adecuado.
4. Comparar los resultados de predicción de la red neuronal *FeedForward Back Propagation* con los resultados de la metodología utilizada actualmente por la ERRSA.

1.4 Hipótesis de la Investigación

1.4.1 Hipótesis general

El modelo de predicción de la demanda de energía eléctrica basado en la red neuronal *FeedForward backpropagation* minimiza el error de predicción respecto a la metodología empleada por la empresa Eléctrica de Riobamba.

1.4.2 Identificación de variables

Tabla 1-1: Identificación de variables:

VARIABLE	TIPO	CONCEPTO
Error de predicción de la demanda de energía eléctrica	Cuantitativa. Dependiente	Es un procedimiento sistemático que permite definir cuantitativamente la demanda futura y por ser de vital importancia debe procurarse que dicha información sea lo más exacta posible, sin olvidar la presencia de incertidumbres (ARCONEL, 2014).
Método de predicción	Cualitativa Independiente	Se refiere a los procesos, técnicas, algoritmos y operaciones encaminados a mejorar la calidad de los resultados de predicción.

1.4.3 Operacionalización de variables

Tabla 2-1: Operacionalización de variables

VARIABLE	INDICADOR	TÉCNICA	INSTRUMENTO/FUENTE
Error de predicción de la demanda de energía eléctrica	Error absoluto porcentual promedio (MAPE)	Estadística	Matlab, R Studio , SPSS, otros
Método de predicción	Eficiencia del modelo de predicción	Predicción	Matlab, R Studio , SPSS, otros

CAPÍTULO II

2 MARCO REFERENCIAL

2.1 Estado del arte

2.1.1 Predicción de la demanda de energía eléctrica en el mundo

Según la revisión bibliográfica realizada, se observa que existen avances innovadores en este campo, es así que a nivel mundial se registran una diversidad de estudios para la predicción de demanda de energía eléctrica con la utilización de redes neuronales.

En lo que respecta a la predicción de la demanda horaria de potencia eléctrica, el avance en cuanto al trabajo investigativo de la temática en las últimas dos décadas, se debe en primera instancia, a la transformación liberalizadora de la mayoría de los mercados de energía eléctrica del mundo (Gómez,1999), y en segunda, al auge de modelos basados en inteligencia artificial e identificación de sistemas, apoyados a su vez por el desarrollo en la capacidad de cálculo de los computadores de hoy en día.

Países como Estados Unidos, México, Chile y especialmente Colombia son los que más registran publicaciones relacionados con la utilización de redes neuronales para la predicción y su aplicación en la demanda de energía eléctrica.

Tema: “MÉTODOS UTILIZADOS PARA EL PRONÓSTICO DE DEMANDA DE ENERGÍA ELÉCTRICA EN SISTEMAS DE DISTRIBUCIÓN”, tesis publicada por la Universidad Tecnológica de Pereira de Colombia Agosto del 2013.

Tema: “PREDICCIÓN DE LA VELOCIDAD DEL VIENTO EN LA CIUDAD DE CÚCUTA, USANDO REDES NEURONALES IMPLEMENTADAS EN ARQUITECTURA FEED-FORWARD”, publicado por la Universidad de Pamplana de Colombia en agosto del 2013.

Tema: “PRONÓSTICO DEL PRECIO DE LA ENERGÍA ELÉCTRICA USANDO REDES NEURO-DIFUSAS”, publicado por la Universidad de Antioquia de Colombia en colaboración de la Universidad Católica de Chile en mayo del 2011.

En el Ecuador, según la revisión bibliográfica realizada, se registra en una página web no académica un trabajo realizado por la Universidad Nacional de Loja denominado “DISEÑO DE UNA RED NEURONAL ARTIFICIAL PARA LA PREDICCIÓN DE LA DEMANDA ELECTRICA”, sin embargo, a nivel nacional no se registra ningún estudio como aporte científico o académico sobre la predicción de la demanda de energía eléctrica, con la utilización de redes neuronales.

Además, en la revisión bibliográfica realizada, se registra en una página web no académica un trabajo realizado por la Universidad Nacional de Loja denominado “PREDICCIÓN METEOROLÓGICA, USANDO REDES NEURONALES”, sin embargo, a nivel nacional no se registra ningún estudio como aporte científico o académico sobre el tema.

2.1.2 Evolución histórica de la demanda de energía eléctrica en el Ecuador.

La energía generada es transmitida por medio del sistema nacional de transmisión (SNT), subestaciones y líneas de transmisión de la Corporación Eléctrica del Ecuador CELEC EP Transelectric. El proceso continúa con los sistemas de subtransmisión y distribución a través de los cuales, la distribuidora como es el caso de la EESRA suministra energía a sus clientes. (ARCONEL, 2016)

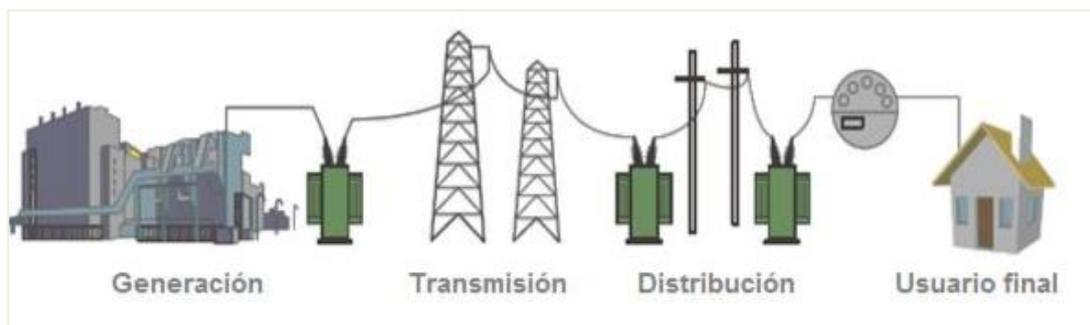


Figura 1-2: Sistema Eléctrico Nacional
Fuente: (Ortiz, 2014).

Es así que a necesidad de energía eléctrico en los sectores residenciales, comerciales, industriales e iluminación pública es atendida por las empresas distribuidoras, mismas que tienen la misión de satisfacer las necesidades de los clientes de su área o región de concesión, esto los hace mediante el abastecimiento de energía a través de la compra por contrato en el sector eléctrico nacional.

A nivel nacional se cuenta con 289 centrales, 4 de las cuales pertenecen a la provincia de Chimborazo cuyo tipo de energía es 100% renovable aportando de esta manera con 15,65 MW de potencia eléctrica que suman al sistema nacional interconectado (ARCONEL, 2015).

Desde el año 2009 hasta el 2016 en el Ecuador se incrementó el consumo de energía eléctrica en un 144%, en un promedio ponderado del 6%, denotando mayor crecimiento en los años 2008 y 2009 (ver figura 2-2). Esto a consecuencia de la transformación de la matriz productiva implementada por el gobierno nacional.

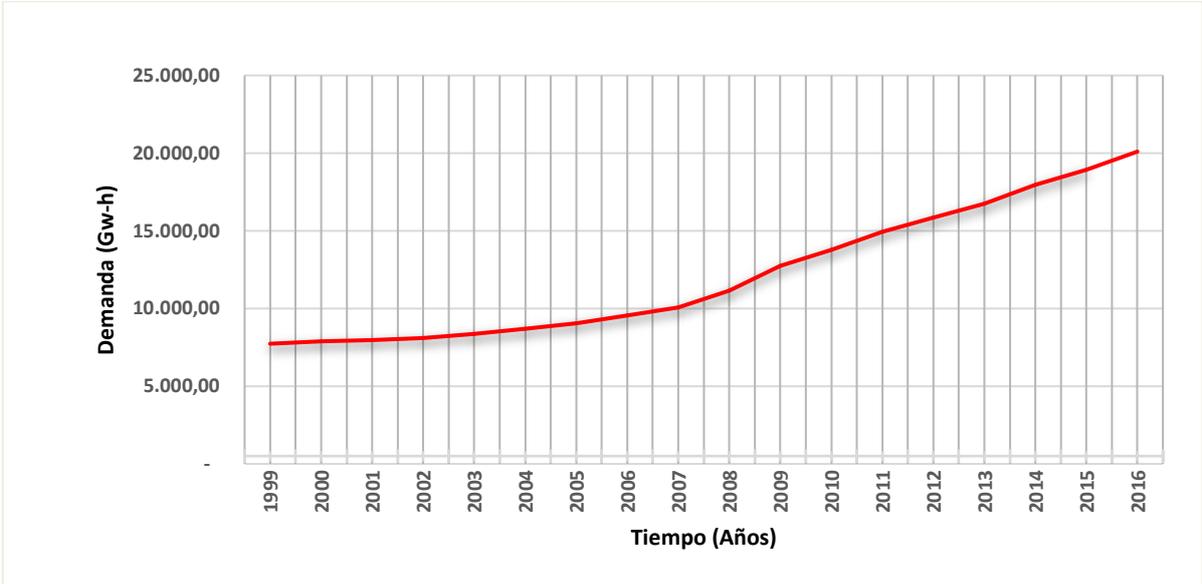


Figura 2-2: Evolución de la demanda de energía eléctrica en Ecuador
Fuente: (ARCONEL, 2015).

Tal como se muestra en la figura 3-2, en el año 2012 a nivel nacional el sector residencial fue el de mayor consumo con una participación del 35% seguido por el sector industrial con un 31%.

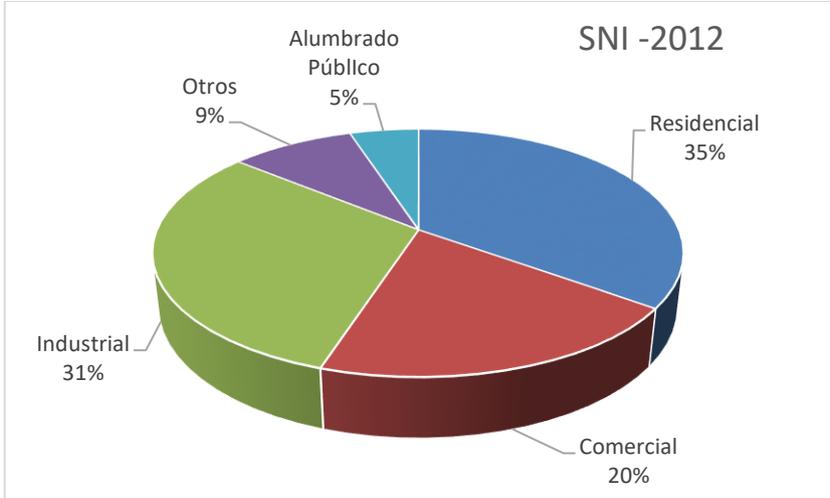


Figura 3-2: Consumo de energía eléctrica por sectores en Ecuador
Fuente: (ARCONEL, 2014)

A abril del 2017 se registra el consumo de energía eléctrica para el sector público con una participación del 32,07% del sector residencial, 17,13% comercial, 24,13% industrial, 5,13% alumbrado público y 9,4% a otros. Además, se tiene un 12% de pérdidas técnicas y no técnicas.

En el mismo estudio realizado por la Agencia Nacional de Regulación y Control de Energía evidencia que en los últimos años los sectores con mayor crecimiento son los sectores comercial e industrial con un 94% y 54% de participación respectivamente, ver figura 4-2.

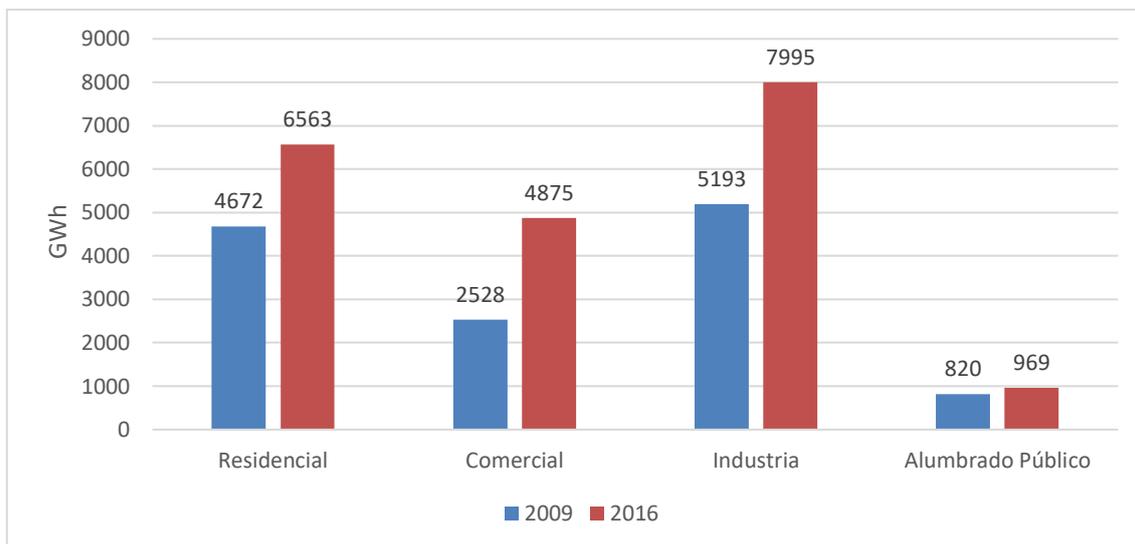


Figura 4-2: Crecimiento demanda de energía eléctrica Ecuador 2009 -2016
Fuente: (ARCONEL, 2014)

2.1.3 Evolución histórica de la demanda de energía eléctrica en Chimborazo

Dentro del contexto eléctrico la EERSA ha sido la pionera en el suministro de energía eléctrica a la provincia de Chimborazo, obedeciendo estrictamente su misión institucional: “Ser una empresa de excelencia con infraestructura tecnológica innovadora, responsabilidad social, índices de gestión referentes, talento humano capacitado y comprometido en la prestación del servicio y el cuidado del ambiente”.

siendo esta una sociedad de responsabilidad anónima cuyos accionistas son el Fondo de Solidaridad, Municipios y el Consejo Provincial del Chimborazo, siendo una compañía de economía mixta, como se muestra en la figura 5-2.

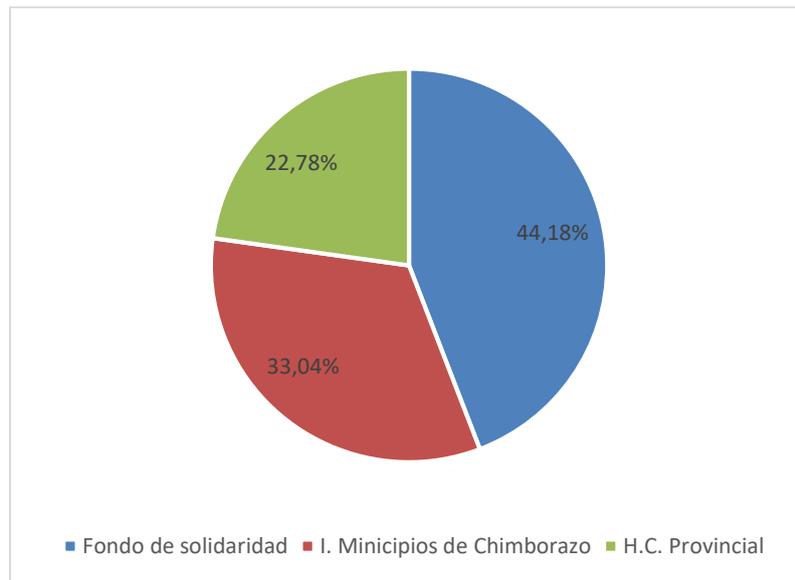


Figura 5-2: Acciones de la Empresa Eléctrica Riobamba S.A.
Fuente: (EERSA, 2017)

El origen de la compañía según la revista de la EERSA 2015, inicia en 1903 cuando se funda la primera Sociedad "Alberto Rhor y Cía." en un pequeño pueblo de nuestro Ecuador pero que a esa fecha ya veía la necesidad de contar con energía eléctrica, sin embargo, esta Sociedad quiebra en 1907. Para fortuna de Riobamba, en 1911 se funda la sociedad anónima Riobamba Electric Ligth and Power. En 1924 se crea la empresa "La Hidroeléctrica", siendo uno de los socios Hirman Foley apoderado de la Empresa Eléctrica del Ecuador Inc., empresa que se encargó algunos años de la distribución de energía eléctrica en la region. En 1953 se conforma la Empresa de Electrificación Chimborazo S. A., que tenía algunos proyectos dentro de los cuales figuraba la construcción de una Central Hidroeléctrica, proyecto ambicioso sin duda, pero que el 20 de abril de 1921 vio sus primeras luces con la inauguración de algunas obras, acto que contó con la visita oficial del presidente de la República Dr. José María Velasco Ibarra.

El 3 de abril de 1963 nace como tal la Empresa Eléctrica Riobamba S. A., que compra todos los derechos a la Empresa de Electrificación Chimborazo S.A. y para el 2 de enero de 1967 realiza la inauguración de los dos primeros grupos de turbinas de su Central Hidroeléctrica la que tomó el nombre de uno de los dos ríos de cuyas aguas se aprovecha Alao. En esta ocasión se contó con la presencia del Dr. Otto Arosemena Gómez, presidente de la República de aquel entonces.

Riobamba crecía y cada vez demandaba un mejor servicio eléctrico y con el ánimo de prestarlo, la EERSA continuó realizando las inversiones y trabajos necesarios para en el año 1977 inaugurar el tercer grupo de turbinas y para 1979 el cuarto y último grupo.

Esta Central aloja hasta la presente fecha a 4 grupos de turbina generador de 2.6 Megavatios cada una, dando un total de 10.4 megavatios. Las turbinas son de tipo Pelton con un caudal de 0.97 metros cúbicos por segundo, dos inyectores y 720 revoluciones por minuto.

Para 1972 y 1974 y posteriormente en 1976 la EERSA se fusiona con la Empresa Eléctrica Alausí que contaba con una Central Hidroeléctrica llamada Nízag de 300 KW. Esta Central fue repotenciada en el año 2009, año en el que entra en operación el nuevo grupo de generación con 0.8 MW.

Durante el año 1979 la EERSA pasó a formar parte del Sistema Nacional Interconectado para luego iniciar la construcción de la línea San Juan - Alausí y las subestaciones San Juan, Guamote y Alausí, cada una con 1 MVA.

La línea de interconexión entre las subestaciones #s. 1 y 2 además de la SE #2 con 10 MVA, se inauguran en 1981, y en 1982 se construye la línea Alausí - Multitud - Pallatanga, lo que permitió electrificar hasta la zona límite con la Costa.

Durante el período de 1990 a 1996 la economía se caracterizó por tener como actor principal a la inflación. Su presencia afectó el desarrollo y crecimiento de todas las actividades, especialmente las del sector eléctrico, ya que, por ser entidades de servicio a la comunidad, los valores de las tarifas no pudieron incrementarse de acuerdo a los índices inflacionarios.

Las medidas adoptadas por los distintos gobiernos para controlar la inflación impactaron notoriamente en nuestra economía, encareciendo importaciones de materiales, combustibles, mano de obra, la compra de energía y otros insumos que eran necesarios para la expansión, operación y mantenimiento del sistema de la EERSA. Sin embargo, la Empresa fue experimentando un adecuado desarrollo de sus actividades, que le permitieron aportar en gran medida al desarrollo de la Provincia de Chimborazo.

En estos años el crecimiento de la EERSA fue sostenido. Incorporó anualmente un promedio de cuatro mil nuevos abonados, llegando a dotar de servicio de energía eléctrica al 94% de la población de la Provincia hasta el 31 de diciembre de 1996.

Las gestiones previstas por la Dirección de la Empresa, tenían como objetivo la electrificación total de la Provincia y el mejoramiento continuo de la calidad del servicio a sus clientes a través de las inversiones en nuevos proyectos de electrificación, por lo que en 1994 se tiene la enorme satisfacción

de poner al servicio de la ciudad y Provincia la S/E No. 3 para posteriormente en 1995 poner en operación la línea Alausí-Chunchi con su respectiva subestación.

Para 1997, la EERSA inaugura la Central Hidroeléctrica Río Blanco con una potencia de 3 MW. con lo cual mejora notablemente el servicio a nuestra Ciudad y Provincia, el mismo que a esta fecha se realizaba mediante la producción de energía de Centrales propias de la EERSA y mediante energía que se adquiría al SNI a través de la línea Riobamba-Ambato, y desde 1992 directamente del anillo del SNI a través de la Subestación Riobamba, la cual contaba con una capacidad de transferencia de 90 MVA.

Entre los años 2000 a 2007 la EERSA siguió en la misma línea. Se tuvo un crecimiento sustancial en la cobertura provincial, pasando de 106.176 abonados a fines del año 2000, a 128.968 en el año 2007, lo que representó prestar el servicio de energía eléctrica al 98.75% de la población de nuestra Provincia.

En este mismo año (2007) se consolida la interconexión de datos con las agencias de todo el sistema de la EERSA mediante comunicación en línea, lo que permite que cualquier cliente de la empresa pueda acceder al pago de su planilla en la Agencia de su preferencia o de su comodidad.

No cabe duda que 2007 fue un año muy significativo para la EERSA., no solo por los avances tecnológicos y un servicio de calidad prestados a la colectividad, sino porque sus logros se vieron reconocidos por la Comisión de Integración Energética Regional (CIER), organización que año tras año realiza una Encuesta Regional de Satisfacción del Cliente, en la que EERSA fue galardonada con tres premios a saber:

- Premio CIER a Mayor Evolución del Desempeño en el Área de Atención al Cliente
- Premio CIER a Mayor Evolución del Desempeño en el Área de Suministro de Energía
- Premio CIER a Mayor Evolución del Desempeño en el Índice de Satisfacción con la Calidad percibida.

Todo un reto sin duda. El haber sido acreedores a estos premios a los que toda Empresa del Sector Eléctrico quisiera acceder, constituyó un gran compromiso.

En el año 2008 se inicia la construcción de la línea de subtransmisión Alausí Multitud, la misma que a finales del 2009 entra en operación con la correspondiente Subestación Multitud, con lo que se brinda mayor confiabilidad y calidad del servicio técnico para los cantones de Pallatanga y Cumandá.

La capacidad de transformación de la Subestación No. 2 se incrementa en el año 2010 con el cambio del transformador de potencia de 10 MVA a 15 MVA, con lo que se mejora la posibilidad de satisfacer el incremento de la demanda a nivel de usuario final.

También en el año 2010 se inicia la construcción de la línea de Subtransmisión Alao Guamote que entró en operación a mediados del 2011. Paralelamente se realizó la contratación para el equipamiento de las salidas en las Subestaciones de Alao y Guamote para interconectar la línea construida.

En fin, se ha progresado, llegando al año 2010 a cubrir una demanda de 147.116 abonados en toda la Provincia de Chimborazo, y para el 2011 alcanzar a 152.030 clientes.

Hasta el primer semestre del año 2012 cubrimos la demanda de 154.593 abonados que cuentan con un servicio de calidad los 365 días del año, las veinte y cuatro horas del día.

Durante los años 2011 y 2012, el Gobierno Nacional a través del Ministerio de Electricidad y Energía Renovable, con la participación de la EERSA, impulsó proyectos que se están llevando a cabo con éxito.

Con el fin de ilustrar de mejor manera el comportamiento de la demanda de energía eléctrica de la Empresa Eléctrica de Riobamba, en la figura 2-6, presenta los datos de la evolución de las demandas históricas correspondiente desde el año 1990 hasta el año 2016, También se agrega como dato relevante a cada serie el coeficiente de variación, que representa el cociente entre la desviación estándar de la serie y su media. Este valor es utilizado como una métrica para ver la estabilidad de la serie a través del tiempo.

Como se observa en la figura 6-2, desde el año 2009 hasta el 2016 periodo de tiempo utilizado para esta investigación en la zona de concesión de la EERSA se incrementó el consumo de energía eléctrica en un 102%, en un promedio ponderado del 5%, denotando mayor crecimiento en los años 2012 y 2013. Esto a consecuencia de la transformación de la matriz productiva implementada por el gobierno nacional.

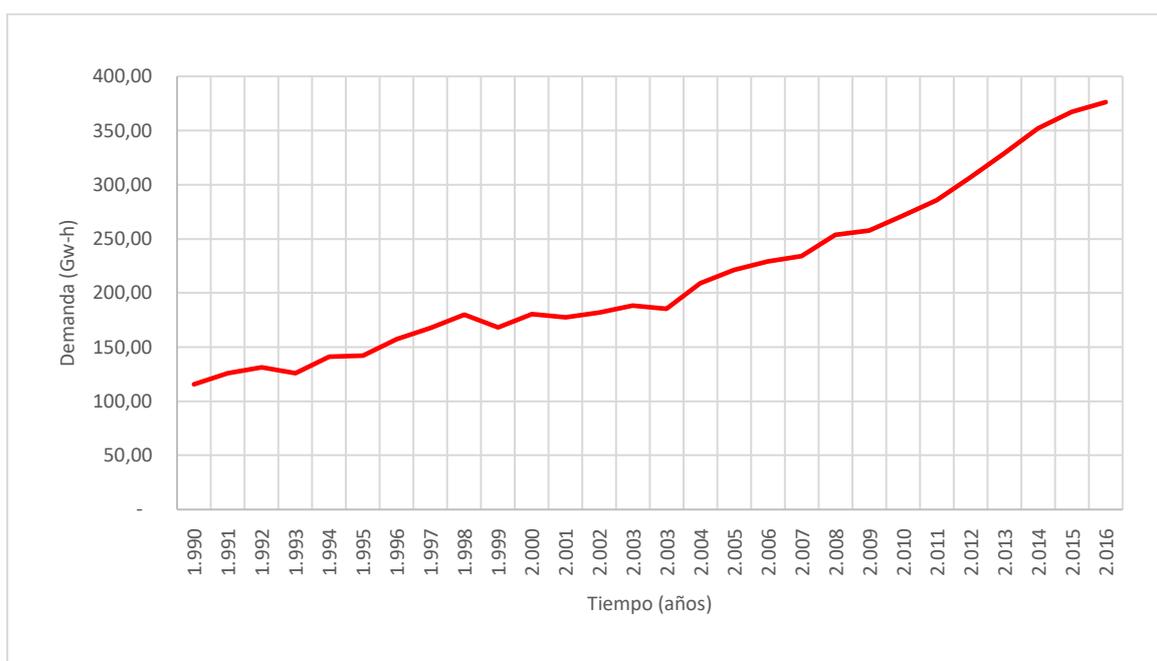


Figura 6-2: Evolución de la demanda de energía eléctrica en Chimborazo
Fuente: (ARCONEL, 2014)

Sin embargo, desde el año 1990, la demanda de energía eléctrica en el área de concesión de la EERSA muestra un mayor incremento en los años 1994, 1996, 2004 y 2008. Además, se evidencia que en los 1993 y 1999 tienen un significativo decremento del 4,2% y 6,7% respectivamente, esto debido a la recesión económica y feriado bancario de ese entonces.

En 1993, el derrumbe de la Josefina en el sur del país que, entre otras consecuencias, afectó seriamente al complejo hidroeléctrico más importante del Ecuador lo que, sumado a un estiaje particularmente severo, contribuyó a precipitar una prolongada crisis energética que hasta ahora afecta a todo el territorio nacional. (Cornejo Castro, Narando B., Pareja, y Montufar, 2010).

A estos acontecimientos fortuitos hay que sumar la permanente tensión diplomática y militar con el Perú que, en dos ocasiones durante el período (1981 y 1995), derivó en conflictos bélicos abiertos. El costo de esta anomalía de origen histórico no sólo se ha traducido en la destrucción causada por los dos enfrentamientos militares, sino también en el alto precio de mantener y renovar periódicamente un equipamiento bélico disuasivo, y los efectos perniciosos que una situación de tensión fronteriza necesariamente ha ocasionado sobre la actividad económica del país.

La pobreza en el Ecuador afecta a la mayoría de la población; 56% en 1995, último año para el cual existe información. Pero es en las zonas rurales donde su presencia es particularmente conspicua, afectando a un 76% de la población total, frente a un 42% de la población urbana.

En el 1995, la evolución del producto interno bruto en su valoración porcentual promedio anual baja del 4,3% al 2,3%.

En el año 1999 la situación de la nación sin haber resuelto el problema fiscal, el país tuvo que hacer frente, desde el primer semestre de 1999, al embate de la crisis financiera internacional, que se tradujo en una reducción de las fuentes externas de financiamiento. Esto agudizó las dificultades de la balanza de pagos, por el lado de la cuenta de capitales, y precipitó la frágil situación del sistema financiero doméstico hacia un problema de solvencia, en el marco de una insuficiente supervisión bancaria. En la práctica, 1999 fue un año marcado por la inestabilidad del sistema financiero, en medio de acciones dolosas de algunos administradores de bancos y financieras. El feriado bancario y el congelamiento de los depósitos en la banca, decretado por el Gobierno en marzo, reflejaron la gravedad de la crisis, causando a su vez un mayor deterioro de la confianza de los agentes, y exacerbando así la incertidumbre. (Cerdas, Jiménez, & Valverde, 2006)

El crecimiento de la demanda de energía en el sistema presenta a principio de la década del 2000 un crecimiento estable con un peak considerable el año 2004, siendo detectable una tendencia de crecimiento bastante estable a simple vista, así como también una estacionalidad estable a través de los años, sin variaciones muy grandes respecto de la media anual del 6%.

Sin embargo, el año 2008 y 2009 desaparece la tendencia, debido a la crisis energética que ocurre en el primero de estos años que ocasionó una baja considerable en la demanda (acompañada también de una crisis económica mundial) y además un aumento prominente en los precios de la energía dada la falta de generación en el país.

Se puede ver que posterior a la crisis se vuelve a retomar una tendencia al alza, aunque con una estacionalidad con mayor varianza, presentándose máximos más marcados en los meses de invierno. Cabe destacar también la baja en el crecimiento que ocurre el último año, que es contemporánea a una baja de crecimiento en la actividad económica del país.

El coeficiente de variación para esta serie es relativamente bajo, no obstante, ha de compararse con otras series en el largo plazo para determinar su dificultad de pronóstico, razón por la cual se analizará este ítem más adelante.

Como se muestra en la figura 7-2, la demanda de energía eléctrica de la EERSA de igual manera también se clasifica por sectores: residencial, comercial, industrial, alumbrado público y otros, en el año 2016 se registra una participación de los sectores, evidenciándose que el sector residencial registrado mayor consumo con un 43%, seguido por el industrial con una participación del 23%.

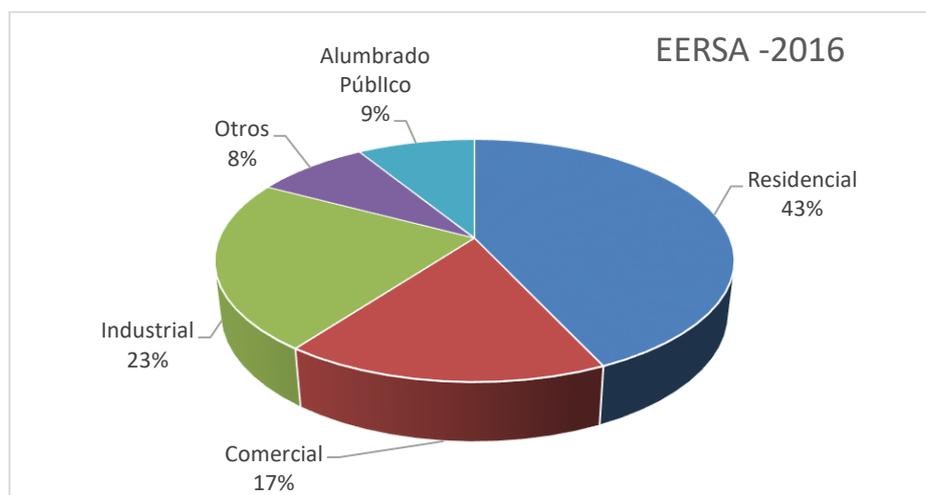


Figura 7-2: Consumo de energía eléctrica por sectores en Chimborazo
Fuente: (EERSA, 2017)

Además, el sector residencial registra un incremento del 3% con respecto al año 2012, mientras que los sectores comercial, industrial y alumbrado público decremantan el 1%.

En la figura 8-2 se observa que el sector que mayor crecimiento entre los años 2009 y 2016 fue el comercial con un incremento del 64%, seguido por el residencial con un 62%.

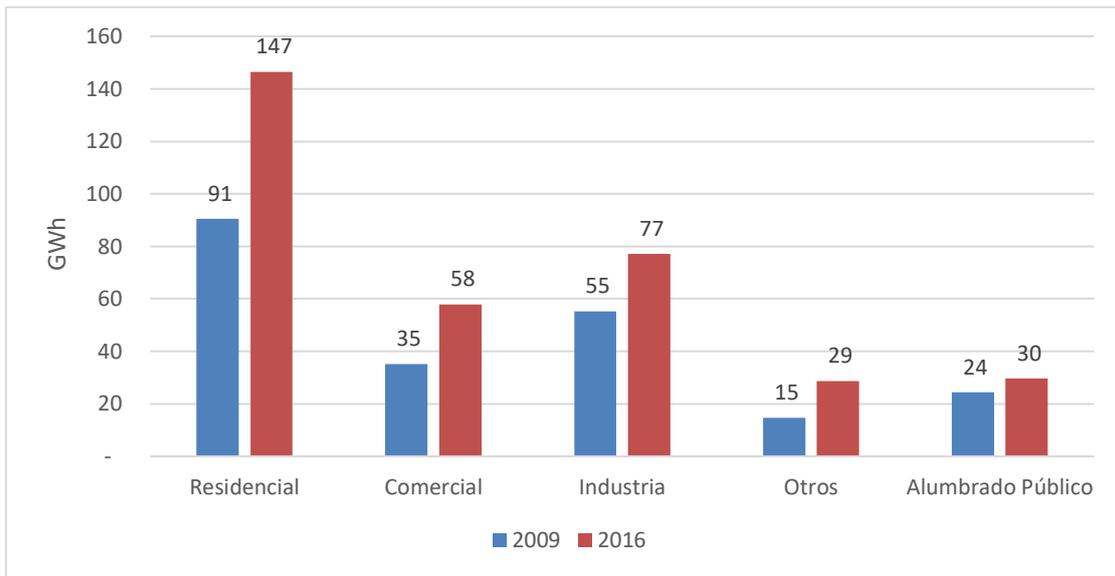


Figura 8-2: Crecimiento demanda de energía eléctrica Chimborazo 2009 -2016
Fuente: (EERSA, 2016)

En el año 1989 la EERSA contaba con 58.130 abonados mientras que en el año 2016 contaba con 169.095 con incremento del 186% y un promedio por año del 4%, como se muestra en la figura No. 9-2.

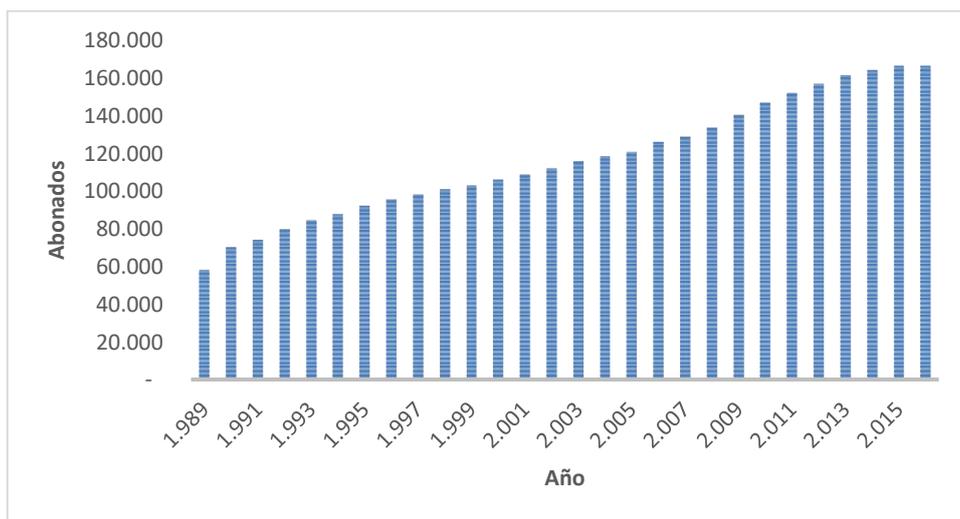


Figura 9-2: Crecimiento de abonados de la EERSA
Fuente: (EERSA, 2016)

Además, la cobertura del servicio eléctrico a nivel nación para el 2014 fue del 97,4%, para la provincia de Chimborazo fue del 94,26% mientras que para el año 2016 fue del 98% de su población, ver figura 10-2.

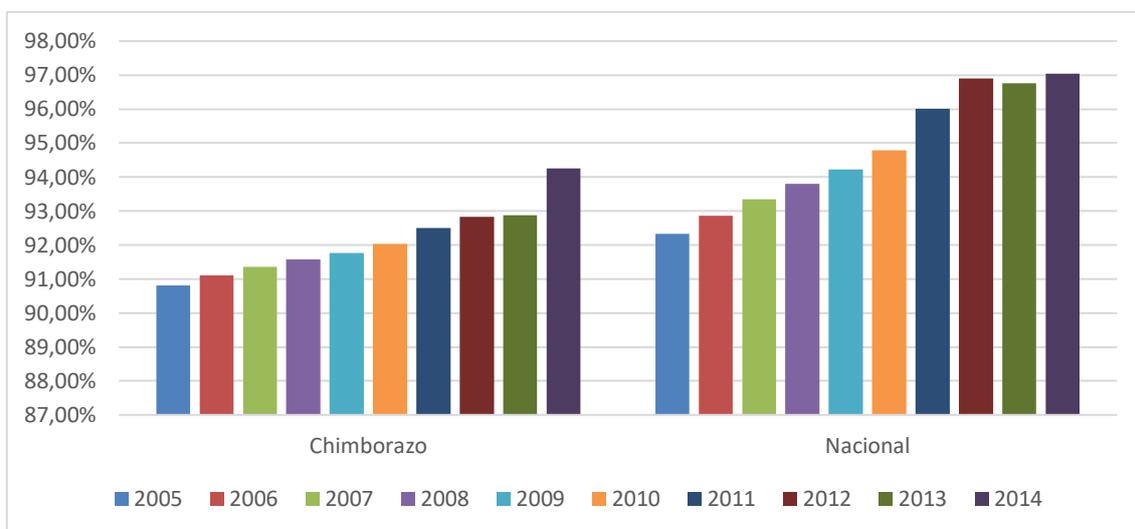


Figura 10-21: Cobertura servicio eléctrico en los años 2005-2014
Fuente: (ARCONEL, 2014)

2.1.4 Metodología y modelos utilizados en la actualidad.

La proyección de la demanda eléctrica, es una herramienta indispensable para orientar las decisiones de inversión y operación, así como para la formulación y desarrollo de proyectos que permitan asegurar la oferta de electricidad en condiciones de seguridad y confiabilidad (Electricidad, 2011).

A nivel nacional en el sector eléctrico para predecir la demanda de energía eléctrica existen muchas propuestas, sin embargo, estas están basadas en métodos estadísticos utilizando técnicas de regresión, distribución de probabilidad y series de tiempo para ello el estado ecuatoriano a través del Concejo Nacional de Electricidad en base al análisis de estimación de demanda estableció los siguientes métodos en la proyección de la demanda de electricidad para el uso en el Ecuador:

- Modelos econométricos
- Análisis de periodos anteriores
- Evolución tendencial
- Impulsores y esquemas analíticos.

Dentro del plan maestro de electricidad 2012 – 2021 ARCONEL uno del modelo fue el econométrico dentro del cual el método de estimación que ha sido utilizado en el de los Mínimos Cuadrados Ordinarios (MCO), mediante software especializado E-VIEWA versión 7.

Este modelo permite mediante la estimación de una relación, expresar la variable a explicar. Esta técnica tiene la ventaja de permitir llevar a cabo pruebas p test para evaluar estadísticamente la bondad del ajuste del modelo a los datos reales, además establece la capacidad de predicción de modelos y cuantificar el error de la predicción.

Una vez que se tiene los datos reales de consumo de energía eléctrica y comparados con el periodo pronosticado es decir desde el año 2002 al 2016, se muestra en la figura 11-2 el porcentaje de error medio absoluto del pronóstico fue del 8% calculado, evidenciándose que el mayor error detectado fue del 15% y 17% correspondientes a los años 2005 y 2007, mientras que el mínimo error cometido fue del 2% en los años 2001, 2010 y 2011.

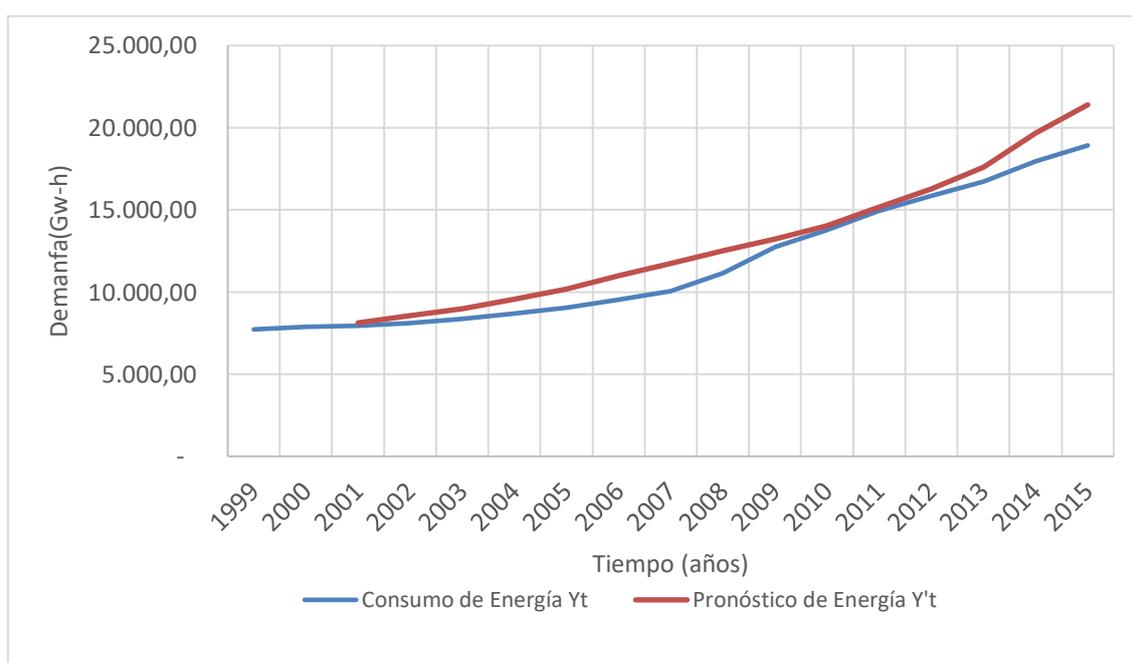


Figura 11-22: Pronóstico vs real de demanda de energía eléctrica a nivel nacional
Fuente: (ARCONEL, 2016)

El Operador Nacional de Electricidad o Centro Nacional de Control de Energía (CENACE) para la estimación de la demanda de energía eléctrica utiliza el paquete estadístico para las ciencias sociales SPSS con la opción predicciones, misma que estima valores para cada día de la semana que sirve para la cumplir con su misión.

En el caso de la EERSA mediante entrevista al personal claves en la planificación institucional se evidenció para la proyección de la demanda de electricidad utilizan el método de análisis de periodos

anteriores que consiste en determinar la tasa de crecimiento de los cinco últimos años complementado con Regresión Lineal Múltiple (CONELEC, 2013).

El porcentaje de error durante el periodo 2007 – 2016 fue del 8% calculado con porcentaje de error medio absoluto tal como se muestra en la figura 12-2, evidenciándose que el mayor error detectado fue los años 2007 y 2013 del 19% y 15% respectivamente, mientras que el error mínimo cometido en el año 2012 del 1%.

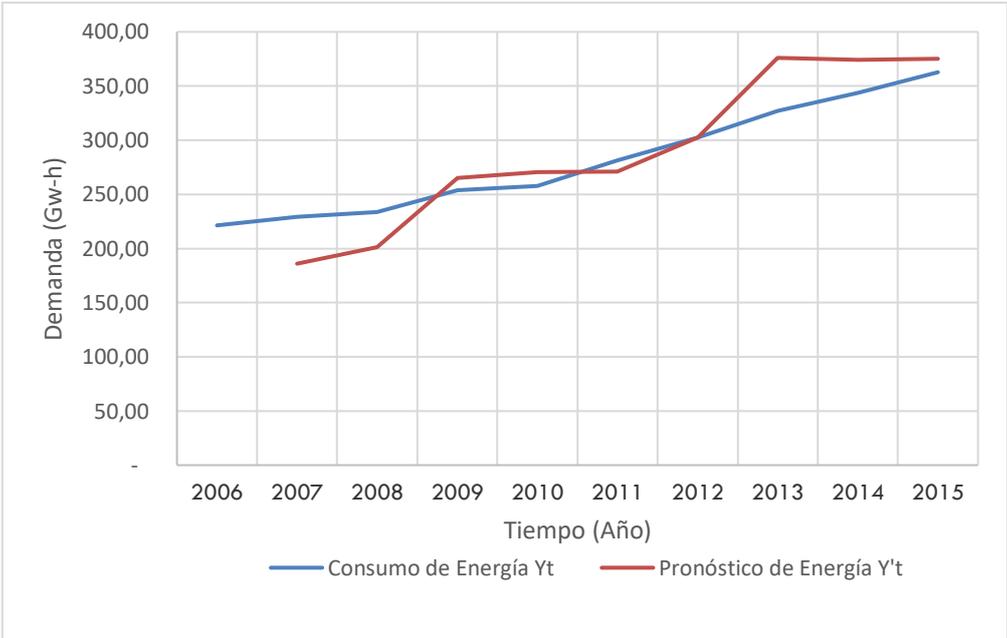


Figura 12-2 Pronóstico vs real de demanda de energía eléctrica de EERSA
Fuente: (EERSA, 2017)

2.2 MARCO TEÓRICO

2.2.1 *Neurona biológica*

Según (Rodolfo Llinás, 2003), la historia de las redes neuronales artificiales comenzó con el científico aragonés Santiago Ramón y Cajal, descubridor de la estructura neuronal del sistema nervioso. Ramón y Cajal, demostró que el sistema nervioso está compuesto por una red de células individuales, las neuronas, ampliamente conectadas entre sí. Estableció que la información fluye en la neurona desde las dendritas hacia el axón, atravesando el soma. Este descubrimiento fue básico en el desarrollo de la neurociencia en el siglo XX.

Se estima que el sistema nervioso contiene alrededor de cien mil millones de neuronas. Las neuronas constituyen procesadores de información sencillos y están formadas por tres componentes principales: dendritas, el cuerpo celular y el axón (ver figura 13-2).

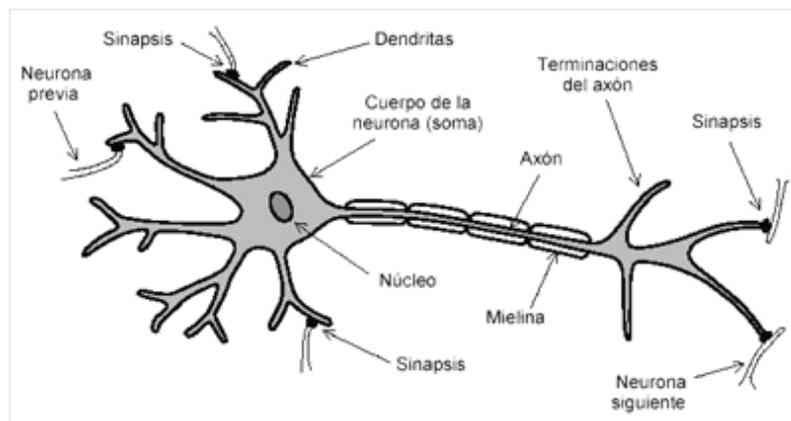


Figura 13-23: Estructura de una Neurona Biológica

Fuente: (Trujillano, March, & Sorribas, 2004)

Las dendritas son como un árbol de redes de fibras nerviosas que llevan señales eléctricas al cuerpo de la célula (canal de entrada de información). El cuerpo celular, contiene el núcleo que es donde se ejecutan todas las transformaciones necesarias para la vida de la neurona (órgano de cómputo).

El axón transmite la señal de salida a otras neuronas (canal de salida), el intercambio químico de información entre una neurona y otra se hace a través de la sinapsis, la cual es el punto de interconexión entre neuronas.

2.2.2 Neuron artificial

Según (Diego Andina, A Vega-Corona, J Seijas, & J Torres, 2007, pág. 57), las RNA actuales se basan en el modelo matemático de neurona, propuesto por McCulloch y Pitts en 1943. Se denomina neurona a un modelo simple de cálculo que a partir de un vector de entrada $\{x_1, x_2, \dots, x_D\}$ que procede del exterior o de otras neuronas, que proporciona una única respuesta o salida y .

Dentro de una RNA existen numerosas conexiones entre las distintas neuronas que la forman. Estas conexiones simulan las conexiones neuronales del cerebro y al igual que estas pueden establecerse con mayor o menor intensidad. En el caso de las RNA estas intensidades son llamadas pesos sinápticos, de modo que cada entrada x_i de una neurona se encuentra afectada por un peso w_i , (ver figura 14-2).

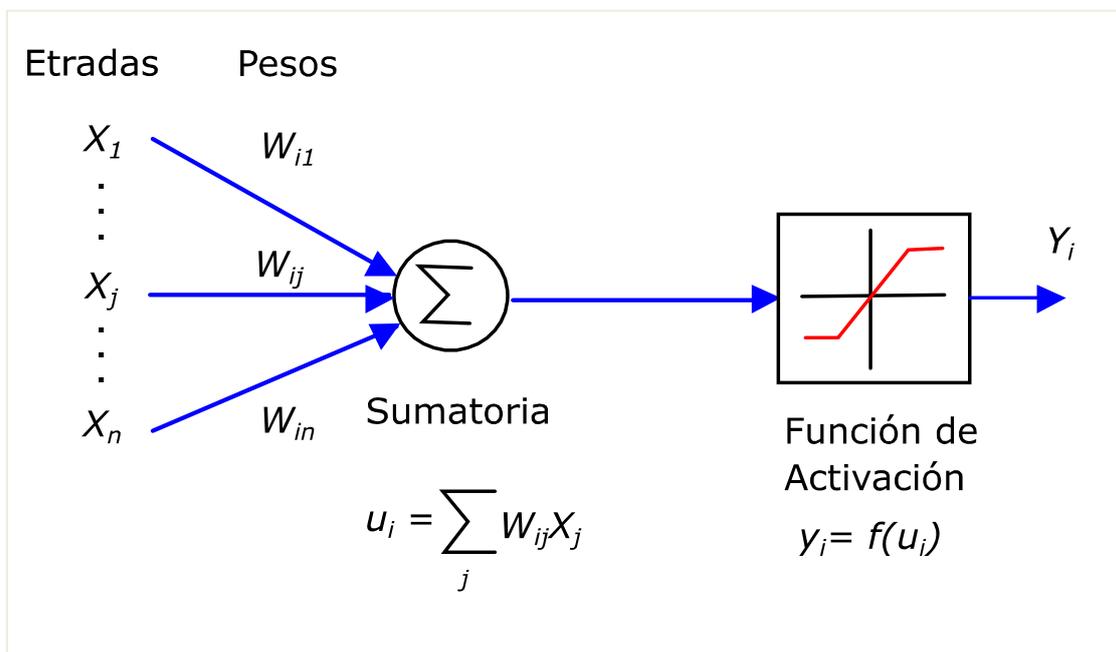


Figura 14-2: Estructura de una Neurona artificial simple
Fuente: Ponce P.; inteligencia artificial con aplicaciones a la ingeniería; 2010.

2.2.3 Red neuronal artificial

Una de las ramas más destacadas del campo científico de la Inteligencia Artificial es la que corresponde a las Redes Neuronales Artificiales (RNAs) entendiendo como tales aquellas redes en las que existen elementos procesadores de información de cuyas interacciones locales depende el comportamiento del conjunto del sistema (Hilera & Martinez, 1995).

Las Redes de Neuronas Artificiales (RNA) son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso. Se trata de un sistema de interconexión de neuronas que colaboran entre sí para producir un estímulo de salida (Mitchel, 1997).

Una red neuronal se compone de unidades llamadas neuronas. Cada neurona recibe una serie de entradas a través de interconexiones y emite una salida.

Esta salida viene dada por tres funciones:

Una función de propagación (también conocida como función de excitación), que por lo general consiste en el sumatorio de cada entrada multiplicada por el peso de su interconexión (valor neto). Si el peso es positivo, la conexión se denomina excitatoria; si es negativo, se denomina inhibitoria.

Una función de activación, que modifica a la anterior. Puede no existir, siendo en este caso la salida la misma función de propagación.

Una función de transferencia, que se aplica al valor devuelto por la función de activación. Se utiliza para acotar la salida de la neurona y generalmente viene dada por la interpretación que queramos darles a dichas salidas. Algunas de las más utilizadas son la función sigmoidea (para obtener valores en el intervalo $[0,1]$) y la tangente hiperbólica (para obtener valores en el intervalo $[-1,1]$).

Para la creación y aplicación de una red neuronal a un problema concreto, se debe distinguir los siguientes pasos:

- Conceptualización del modelo para el estudio del problema concreto. Se deben señalar las entradas, salidas y la información de que se dispone.
- Adecuación de la información de que se dispone a la estructura de la red a crear. Es decir, construir los patrones de aprendizaje, donde parte de la información va a ser utilizada como validación de la red.
- Fase de aprendizaje. Se le van presentando a la red los patrones adecuados y la red proporciona salidas, este proceso se repite un cierto número de etapas, estas salidas se comparan con las salidas esperadas y los diversos algoritmos de aprendizaje de la red y los patrones de validación.
- Fase de validación. Se presenta a la red entrenada el conjunto de patrones de validación, y se ve el error cometido por la red en este conjunto, este error es una medida de la bondad de la red.

- Fase de generalización. Cuando se ha conseguido la red adecuada se utiliza la red como modelo predictor, aportándole una nueva entrada, la procesará y entregará una salida.

2.2.4 Clasificación de las Redes neuronales

En función de cómo está constituido el mecanismo de aprendizaje, se clasifican como: redes supervisadas, redes no supervisadas e híbridas, La tabla 1-2 muestra la clasificación de las RNA.

Tabla 1-2: Clasificación de las redes neuronales artificiales

SUPERVISADO	UNIDIRECCIONAL	Perceptrón	Rosenblatt	1958
		Adaline	Widrow y Hoff	1960
		Perceptrón Multicapa Backpropagation	Rumelhart, Hinton y Wilians	1986
		Correlación en cascada	Fahiman y Lebeire	1990
		Máquina de Bolzman	Ackel, Hinton y Sejnowski	1985
		Learning Vector Quantinzation	Kohonen	1988
		General Regreción Neural Network	Specht	1991
	RECURRENTES	Recurrent bacpropagation	Pineda	1989
		Brian Sate in a Box	Andersan, Silverstein, Titz y Jones	1977
		Jordan	Jordan	1986
NO SUPERVISADO	UNIDIRECCIONALES	Neocognitrón	Fukushima, Miyake e Ito, Fukushima	1983; 1988
		Principal Component Analysis	Oja; Hertz	1982; 1991
		Mapa autoorganizado	Kohonen	1982; 1995
	RECURRENTES	Red de Hopfield	Holfield	1982
		Resonancia Adaptativa(ART)	Carpenter, Grossberg y Rosen	1987; 1990 1991
		Bidirectional Associative Memory	Kosko	1992
		Radial Bassic Fuction	Bromheard y Love; Moody y Darken	1988; 1989
HIBRIDO	Contrapropagación	Hetcht - Nielsen	1990	

Fuente: (P. López Álvarez, R.Velo Sabín, & F. Maseda Eimil, 2007)

Realizado por: Iván Sinaluisa

2.2.5 Arquitectura de una red neuronal Feedforward

La topología o arquitectura de una RNA hace referencia a la organización y disposición de las neuronas en la red formando capas de procesadores interconectados entre sí a través de sinapsis unidireccionales la arquitectura de una red neuronal artificial depende de cuatro parámetros principales: Número de capas del sistema, numero de neuronas por capa, grado de conectividad entre las neuronas y el tipo de

conexiones neuronales. Por su parte la conectividad entre los nodos de la red está relacionada con la forma de transmisión de las salidas de las distintas unidades y su transformación en inputs de otros procesadores (Ariza, 2013).

Según (P. López Álvarez, R.Velo Sabín, y F. Maseda Eimil, 2007), la arquitectura de la red neuronal es la interconexión entre las distintas neuronas. Estas se agrupan en capas, cada una de ellas con un conjunto de neuronas de número variable y comportamiento similar. Sin embargo, la forma en que están estructuradas las neuronas de una red neuronal está íntimamente ligada con el algoritmo de aprendizaje (Haykin, 2008).

Las redes alimentadas hacia delante o “feedforward” como su nombre lo indica las conexiones siempre están dirigidas hacia delante, es decir las neuronas de una capa se conectan con las neuronas de la siguiente capa.

Dentro de las redes feedforward podemos identificar en tres clases de configuraciones: Redes Feedforward de capa simple, multicapas y recurrentes, sin embargo, la red más utilizada en la práctica es la red Feedforward multicapa. Como se muestra en la figura 15-2, cada capa está conectada a la inmediata posterior total o parcialmente, excepto la última capa que constituye la salida de la red (Haykin, 2008).

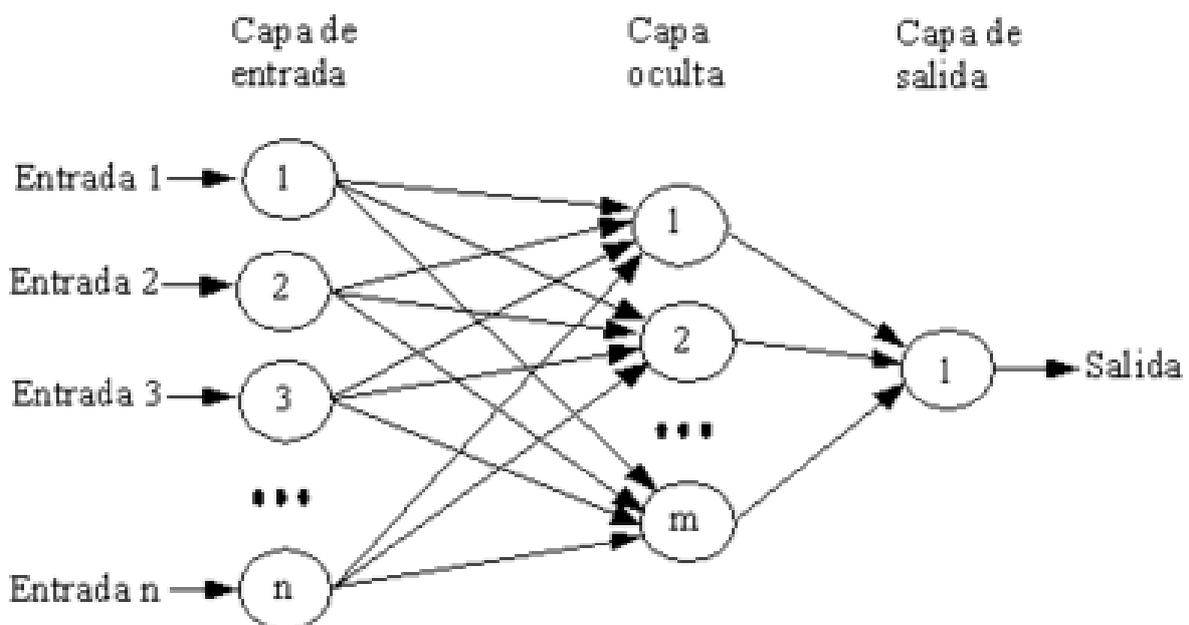


Figura 15-2: Arquitectura de una Red Neuronal
Fuente: (Haykin, 2008)

La figura 15-2 muestra la arquitectura de Perceptrón multicapa que se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles. Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida (Peréz, 2013).

Capa de entrada: El número y tipo de neuronas de esta capa depende de los datos del problema que se esté abordando. Esta capa recibe los datos o señales procedentes del entorno, recibe los vectores de entrada y los redistribuye a las neuronas de la capa intermedia sin realizar ningún tipo de procesamiento sobre los datos, es sólo una receptora de información.

Capas intermedias u ocultas: Pueden ser más de una dependiendo del problema, estas capas no tienen conexión directa con el entorno y mediante el tratamiento adecuado de estas capas se consigue la extracción de características, adaptabilidad, generalización..., es decir, esta capa proporciona a la red grados de libertad adicionales que le permitirán encontrar representaciones internas de determinados rasgos del entorno. Transforma los vectores de entrada en vectores intermedios, que caracterizan los patrones de entrenamiento.

Capa de salida: El número de neuronas de esta capa depende de la salida de la red, es decir, sus neuronas proporcionan la respuesta de la red neuronal a partir de un estímulo de la capa intermedia.

Así de acuerdo a su estructura en capas se tendrían:

- Redes mono capa constituidas por una única capa de neuronas
- Redes multicapa.

Las redes multicapa tienen la habilidad de caracterizar los patrones de entrenamiento generando su propio modelo de representación. Este tipo de redes multicapa sólo necesita una única capa intermedia para modelar una proyección no lineal entre los espacios de entrada y de salida, pues el aumento del número de neuronas en la red conlleva un aumento en la variación. Una red con una única capa intermedia tiene menos variación y proporciona mayor capacidad de generalización (Haykin, 2008).

2.2.6 Entrenamiento, aprendizaje y ejecución

Para una red neuronal, la habilidad de modificar sus pesos $w = (w_1, w_2, \dots, w_n)$ en dependencia de las señales de entrada $x = (x_1, x_2, \dots, x_p)$ que ella recibe se denomina aprendizaje (Cisco, 2010).

Las RNA son capaces de realizar un cálculo a partir de un conjunto de patrones de entrenamiento o ejemplos, siendo esta capacidad de aprendizaje una de sus principales características, que permite que

la red modifique su propia estructura, es decir, que cambie sus pesos, adaptándolos hasta conseguir la respuesta deseada.

El entrenamiento es el procedimiento mediante el cual la red aprende y el aprendizaje es el resultado final de este proceso. El aprendizaje se realiza a partir de todo el conjunto más que por la aportación individual de cada elemento.

El proceso de entrenamiento es normalmente iterativo, actualizándose los pesos una y otra vez hasta que se alcanza el objetivo deseado. Una vez que la red ha sido entrenada se pasa al modo de ejecución o recuerdo, que consiste en mantener fijos los pesos de la red y procesar datos, es decir, la red es capaz de responder ante entradas no vistas con anterioridad.

Se pueden distinguir los siguientes tipos de aprendizaje (Martínez Albaladejo, 2001):

- **Aprendizaje supervisado:** La red aprende a partir de ejemplos de entrenamiento, es decir, la red es entrenada a partir de la entrada y la salida aprendiendo la relación entre ellos sin necesidad de disponer de una forma funcional de partida, ajustando los pesos a partir de la información del error que se comete en cada paso.
- **Aprendizaje no supervisado:** El conjunto de entrenamiento está constituido sólo por la entrada, sin la salida esperada para estos elementos. El aprendizaje se realiza a través de la asociación de la información recibida con la almacenada y como consecuencia reconociendo regularidades en el conjunto de datos, es decir, la red es capaz de extraer las características, estableciendo una clasificación o categorización.
- **Aprendizaje híbrido:** Es una mezcla de los anteriores tomando la regla de aprendizaje supervisado para casos maestros, conocidos y generales. Normalmente el aprendizaje supervisado y no supervisado tienen lugar en capas distintas.
- **Aprendizaje reforzado:** está a medio camino entre el supervisado y no supervisado, la información del error es sólo global (bien, mal) y no se suministra la salida deseada.

2.2.7 Algoritmo Backpropagación

El algoritmo Backpropagation para redes multicapa es una generalización del algoritmo de mínimos cuadrados. Ambos algoritmos realizan su labor de actualización de pesos y ganancias con base en el error medio cuadrático. La red Backpropagation trabaja bajo aprendizaje supervisado y por tanto necesita un conjunto de instrucciones de entrenamiento que le describa cada salida y su valor de salida esperado.

El algoritmo Backpropagation utiliza el método del descenso de gradiente, que forma parte de los métodos de primer orden. Basa la adaptación de los pesos y umbrales, siguiendo una dirección de búsqueda que es el negativo del gradiente de la función de error.

La modificación de los pesos y los umbrales, está definida por la ecuación 1-2 y la ecuación.

$$\theta(k + 1) = \theta(k) - \eta \frac{\partial J(x, \theta)}{\partial \theta} \quad (1-2)$$

Donde $J(x, \theta)$ representa la función de costo o función objetivo. En este método se propone adaptar los parámetros atendiendo al cuadrado del error, o sea:

$$J(x, \theta) = \frac{1}{2} (d(x) - y)^2 \quad (2-2)$$

donde $d(x)$ es la salida deseada.

Entonces, en una red neuronal multicapa (MNN) con el método de aprendizaje backpropagation (propagación del error hacia atrás), se distinguen en dos fases del cálculo:

Fase 1: Cálculo hacia delante (Feedforward).

De las entradas de la red $x_i, i = 1, \dots, p$, son primero calculadas las salidas de la primera capa oculta. Luego, usando estos valores como entradas a la segunda capa oculta, son calculadas las salidas de esta capa, y así sucesivamente. Finalmente, es obtenida la salida de la red. Esta es la salida calculada.

Fase 2: Adaptación de los pesos.

La salida de la red es comparada con la salida deseada, la diferencia de estos dos valores, llamado el error, es entonces usado para ajustar los pesos, primero en la capa de salida, luego en la capa anterior, y así sucesivamente, a fin de disminuir el error. Este recorrido del cálculo del error de la salida hacia la entrada es llamado la retro-propagación (backpropagation) del error.

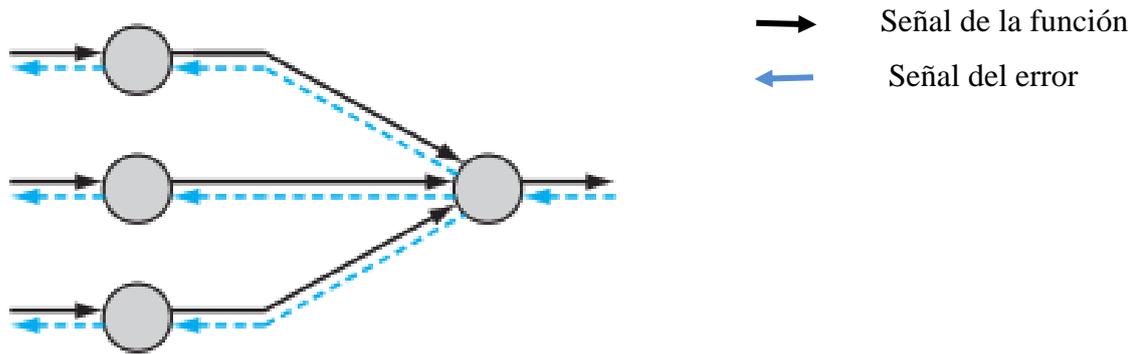


Figura 16 2: Aprendizaje Backpropagation
 Fuente: (Haykin, 2008)

El cálculo hacia delante (Feedforward)

Por simplicidad, se considera una red neuronal de tres capas (con una capa oculta), como la mostrada en la Figura 16-2

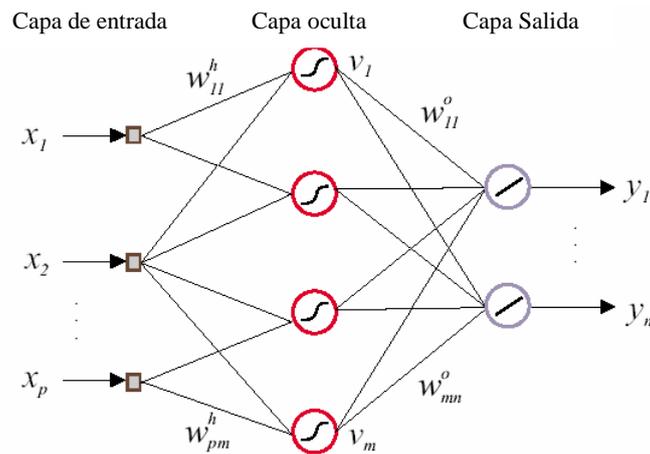


Figura 16-2: Red Neuronal multicapa con una capa oculta
 Fuente: (Cisco, 2010)

Las neuronas de la capa de entrada no realizan ningún cálculo, ellas simplemente distribuyen las entradas x_i a los pesos w_{ij}^h de la capa oculta. Las neuronas en la capa oculta contienen la función de activación \tanh , en tanto que las neuronas de salida son lineales. Los pesos de la capa de salida son denotados por w_{ij}^o .

El cálculo feedforward procede en tres pasos:

1. Calcular las activaciones z_j de las neuronas de la capa oculta:

$$z_j = \sum_{i=1}^p w_{ij}^h x_i + b_j^h \quad (3-2)$$

$z_j, j = 1, \dots, m$, representa la salida de la función de activación de la neurona j -ésima debido a todas las entradas $x_i, i = 1, \dots, p$. El super índice h en los pesos se refiere a los pesos de capa oculta (*hidden*).

2. Cálculo de las salidas v_j de las neuronas de la capa oculta:

$$v_j = \sigma(z_j) \quad j = 1, \dots, m \quad (4-2)$$

3. Cálculo de las salidas y_l de las neuronas de la capa de salida (y así de la red completa):

$$y_l = \sum_{j=1}^m w_{jl}^o v_j + b_l^o \quad (5-2)$$

$y_l, l = 1, \dots, n$, representa la salida de la neurona l -ésima de la capa de salida. El super índice o en los pesos se refiere a los pesos de capa de salida (*output*).

Los tres pasos para el cálculo feedforward pueden ser escritos en una notación matricial compacta:

$$Z = X_b W^h \quad V = \sigma(Z) \quad Y = V_b W^o \quad (6-2)$$

Donde X_b son los datos de entrada, incluyendo el "bias", y Y las correspondientes salidas de la red.

$$X_b = [X \ 1] \quad (7-2)$$

$$X = \begin{pmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_n^T \end{pmatrix} \quad (8-2)$$

$$Y = \begin{pmatrix} y_1^T \\ y_2^T \\ \vdots \\ y_n^T \end{pmatrix} \quad (9-2)$$

$$V_b = [V \ 1] \quad (10-2)$$

N representa el número de patrones u observaciones. La matriz de los pesos de la capa oculta es:

$$W^h = \begin{bmatrix} w_{11} & \cdots & w_{1j} \cdots & w_{1m} \\ w_{21} & \cdots & w_{2j} \cdots & w_{2m} \\ \vdots & \ddots & \vdots \ddots & \vdots \\ w_{p1} & \cdots & w_{pj} \cdots & w_{pm} \\ b_1 & \cdots & b_j \cdots & b_m \end{bmatrix} \quad (2-11)$$

La matriz de los pesos de la capa de salida tiene una estructura similar.

Entrenamiento por retro-propagación del error

Asuma que está disponible un conjunto de N datos patrones

$$X = \begin{bmatrix} x_1^T \\ x_2^T \\ \vdots \\ \vdots \\ x_N^T \end{bmatrix} \quad D = \begin{bmatrix} d_1^T \\ d_2^T \\ \vdots \\ \vdots \\ d_N^T \end{bmatrix} \quad (12-2)$$

Aquí, x es la entrada a la red y d es la salida deseada.

El entrenamiento procede en dos pasos:

1. *Cálculo Feedforward.*

Desde las entradas de red $x_i, i=1, \dots, N$, son calculadas en forma progresiva: las activaciones de capa oculta, las salidas de la capa oculta y las salidas de la red:

$$\begin{aligned} Z &= X_b W^h & X_b &= [X \ 1] \\ V &= \sigma(Z) \\ Y &= V_b W^0 & V_b &= [V \ 1] \end{aligned} \tag{13-2}$$

2. *Adaptación de los pesos.*

La salida de la red es comparada con la salida deseada. La diferencia de estos dos valores, llamado el error, es:

$$E = D - Y \tag{14-2}$$

Este error es usado para ajustar los pesos en la red vía la minimización de la función de costo siguiente:

$$\begin{aligned} J(w) &= \sum_{k=1}^N \sum_{j=1}^n e_{kj}^2 \\ w &= [W^h - W^0] \end{aligned} \tag{15-2}$$

El entrenamiento de una red neuronal multicapa es formulado entonces como *un problema de optimización no lineal* con respecto a los pesos. Varios métodos pueden ser aplicados:

- Backpropagation del error (gradiente de primer orden).
- Métodos de Newton, o de Levenberg-Marquardt (gradiente de segundo orden).
- Gradientes conjugados.
- Algoritmos genéticos,
- Proyección variable.
- muchos otros...

2.4.8 Métodos del gradiente

Métodos del gradiente de primer orden

Los métodos del gradiente de primer orden usan la siguiente regla de actualización para los pesos:

$$w(n + 1) = w(n) - \alpha(n)\nabla J(w(n)) \quad (16-2)$$

donde $w(n)$ es el vector con los pesos en la iteración n , $\alpha(n)$ es la velocidad de aprendizaje (variable) y $\nabla J(w)$ es el Jacobiano de la red.

$$\nabla J(w) = \left[\frac{\partial J(w)}{\partial w_1}, \frac{\partial J(w)}{\partial w_2}, \dots, \frac{\partial J(w)}{\partial w_M} \right]^T \quad (17-2)$$

El problema de optimización no lineal se soluciona entonces usando únicamente el primer término de la expansión en la serie de Taylor del gradiente.

Métodos del gradiente de segundo orden

Los métodos del gradiente de segundo orden hacen también uso del segundo término (la curvatura) de la expansión en la serie de Taylor del gradiente:

$$J(w) \approx J(w_0) + \nabla J(w_0)^T (w - w_0) + \frac{1}{2} (w - w_0)^T H(w_0) (w - w_0) \quad (18-2)$$

Donde $H(w_0)$ es la matriz Hessiana en un punto dado w_0 en el espacio de los pesos. Después de algunos pasos algebraicos, se puede encontrar que la regla de actualización para los pesos es:

$$w(n + 1) = w(n) - H^{-1}(w(n))\nabla J(w(n)) \quad (19-2)$$

La diferencia entre (16-2) y (18-2) es básicamente el tamaño del paso del descenso por el gradiente. Los métodos de segundo orden son por lo general más eficaces que los de primer orden.

El método Backpropagation

El método de Backpropagation es un método del gradiente de primer orden. El algoritmo backpropagation fue propuesto independientemente por Werbos (1974) y Rumelhart, et al. (1986).

La idea principal de backpropagation (BP) puede ser expresada como sigue:

La idea principal de backpropagation (BP) puede ser expresada como sigue:

- Calcular los errores en las salidas,
- Ajustar pesos de salida,
- Propagar el error hacia atrás por la red y ajustar pesos de las capas ocultas.

El cálculo hacia delante de los errores en las salidas es sencillo y no tiene dificultad alguna. Consideraremos a continuación la propagación del error hacia atrás. Derivaremos el método BP procesando el conjunto de datos patrón por patrón, que es apropiado tanto para el aprendizaje en línea (on-line) como para el aprendizaje fuera de línea (off-line). Primero, se consideran los pesos de la capa de salida y luego los de la capa oculta.

Los pesos de la capa de salida.

Considere una neurona en la capa de salida como se representa en la Figura 17-2.

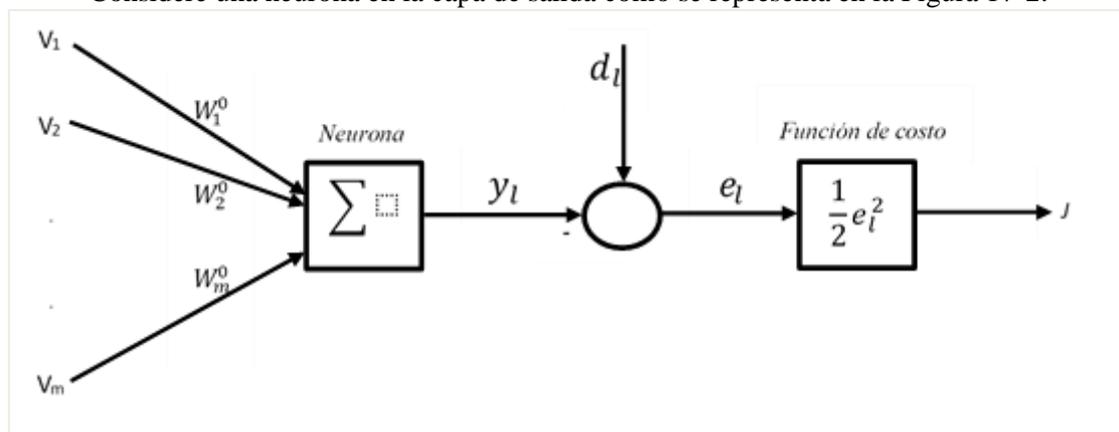


Figura 17-2: Neurona en la capa de salida

Fuente: Elaborado por Iván Sinaluisa a partir de (Cisco, 2010)

La función de costo está dada por:

$$J = \frac{1}{2} \sum_{l=1}^n e_l^2, \quad \text{con } e_l = d_l - y_l, \quad y_l = \sum_{j=1}^m w_{jl}^0 v_j \quad (20-2)$$

Al calcular la Jacobiana por la regla de la cadena; es:

$$\frac{\partial J}{\partial w_{jl}^0} = \frac{\partial J}{\partial e_l} \cdot \frac{\partial e_l}{\partial y_l} \cdot \frac{\partial y_l}{\partial w_{jl}^0} \quad (21-2)$$

Con las derivadas parciales:

$$\frac{\partial J}{\partial e_l} = e_l; \quad \frac{\partial e_l}{\partial y_l} = -1; \quad \frac{\partial y_l}{\partial w_{jl}^0} = v_j \quad (22-2)$$

Por lo tanto, para la capa de salida, la Jacobiana es:

$$\frac{\partial J}{\partial w_{jl}^0} = -v_j e_l \quad (23-2)$$

De la ecuación (16-2), la ley de adaptación para los pesos de salida es:

$$w_{jl}^0(n+1) = w_{jl}^0(n) + \alpha(n)v_j e_l \quad (24-2)$$

Los pesos de la capa oculta

Considere una neurona en la capa oculta como es muestra en la figura 18-2.

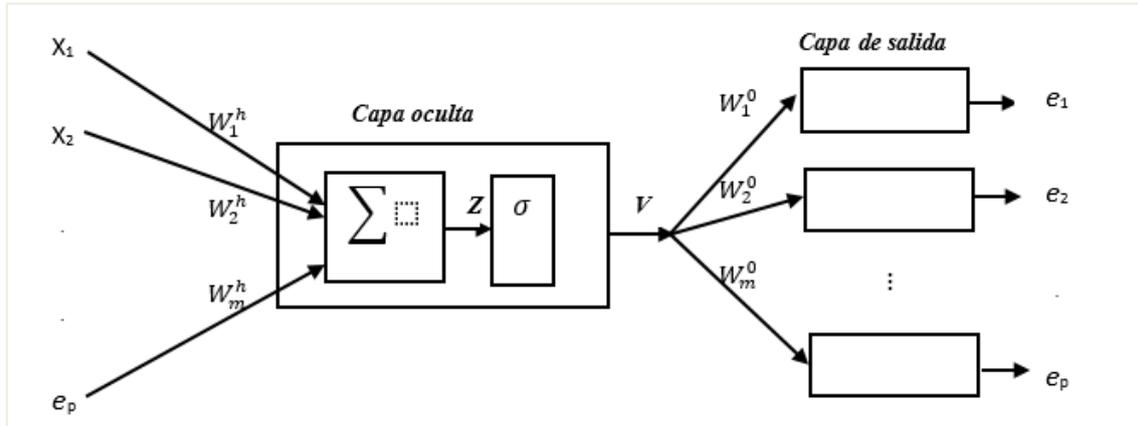


Figura 18-24: Neurona de la capa oculta
Fuente: Elaborado por Iván Sinaluisa a partir de (Cisco, 2010)

La Jacobiana es:

$$\frac{\partial J}{\partial w_{ij}^h} = \frac{\partial J}{\partial v_j} \cdot \frac{\partial v_j}{\partial z_j} \cdot \frac{\partial z_j}{\partial w_{ij}^h} \quad (25-2)$$

Con las derivadas parciales (después de algunos cálculos de (2-20)):

$$\frac{\partial J}{\partial v_j} = \sum_l -e_l w_{jl}^0 ; \quad \frac{\partial v_j}{\partial z_j} = \sigma_j'(z_j) ; \quad \frac{\partial z_j}{\partial w_{ij}^h} = x_i \quad (26-2)$$

La derivación de la anterior expresión es directa. Sustituyendo en (25-2) da el Jacobiano,

$$\frac{\partial J}{\partial w_{ij}^h} = -x_i \cdot \sigma_j'(z_j) \cdot \sum_{l=1}^n e_l w_{jl}^0 \quad (27-2)$$

De (16-2), la ley de actualización para los pesos de la capa oculta es:

$$w_{ij}^h(n+1) = w_{ij}^h(n) + \alpha(n) x_i \cdot \sigma_j'(z_j) \cdot \sum_{l=1}^n e_l w_{jl}^0 \quad (28-2)$$

Resumen del Algoritmo de backpropagation

Inicialice los pesos (aleatoriamente).

Paso 1: Presente las entradas y las salidas deseadas.

Paso 2: Calcule las salidas actuales y los errores.

Paso 3: Calcule los gradientes y la actualización de los pesos:

$$w_{jl}^0(n+1) = w_{jl}^0(n) + \alpha(n)v_j e_l \quad (24-2)$$

$$w_{ij}^h(n+1) = w_{ij}^h(n) + \alpha(n)x_i \cdot \sigma_j'(z_j) \cdot \sum_l^n e_l w_{jl}^0 \quad (28-2)$$

Repita desde el *Paso 1*.

En la aproximación que se acaba de exponer, cada dato de los datos de entrenamiento es presentados uno tras otro (para el aprendizaje). Esto es conveniente, sobre todo, para el aprendizaje en línea. Por supuesto, puede ser aplicado aun si un “batch” completo de datos está disponible para el aprendizaje.

La presentación del conjunto completo de los datos es llamada una época (en inglés, epoch). Por lo general, deben ser aplicados varios epochs de aprendizaje a fin de conseguir un ajuste adecuado. Desde un punto de vista computacional, es más eficaz presentar el conjunto completo de datos como un “batch”. Las fórmulas del aprendizaje backpropagation son aplicados entonces a vectores de datos en lugar de a muestras individuales.

El algoritmo de retropropagación proporciona una "aproximación" a la trayectoria en el espacio de peso calculado por el método de descenso más pronunciado. Cuanto más pequeño hacemos el aprendizaje el parámetro α más pequeños serán los cambios en los pesos sinápticos en la red de una iteración a la siguiente, y el más suave será la trayectoria en el espacio de peso. Esta mejora, sin embargo, se logra a costa de una tasa de aprendizaje más lenta. Si, por otro lado, hacemos que el parámetro de tasa de aprendizaje sea demasiado grande para acelerar la tasa de aprendizaje, los grandes cambios resultantes en los pesos sinápticos asumen una forma que la red puede volverse inestable (es decir, oscilatoria) (Haykin, 2008).

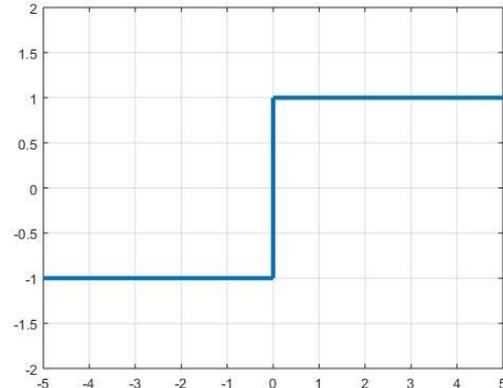
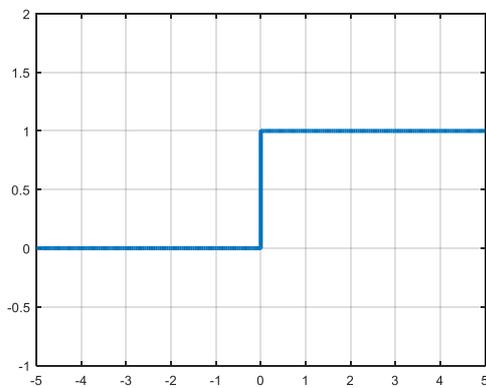
2.4.9 Función de activación

Una neurona biológica puede estar activa (excitada) o inactiva (no excitada); es decir, que tiene un “estado de activación”. Las neuronas artificiales también tienen diferentes estados de activación; algunas de ellas solamente dos, al igual que las biológicas, pero otras pueden tomar cualquier valor dentro de un conjunto determinado (Matich, 2001).

Algunas de las funciones más usadas son las siguientes.

Función escalón

Se asocia a neuronas binarias en las cuales, cuando la suma de las entradas es mayor o igual a umbral de la neurona, la activación es 1, pero si es menor, la activación es 0 o -1.



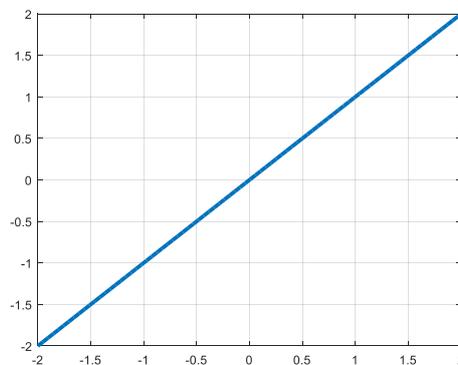
$$F_k(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$$

$$F_k(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ -1 & \text{si } x < 0 \end{cases}$$

Figura 18-2: Función de activación tipo escalón
Fuente: Elaborado por Iván Sinaluisa a partir de (Ponce, 2010)

Función lineal o identidad

La función de identidad devuelve directamente el valor de la activación de la neurona, se utiliza en redes de baja complejidad como el modelo Adaline.

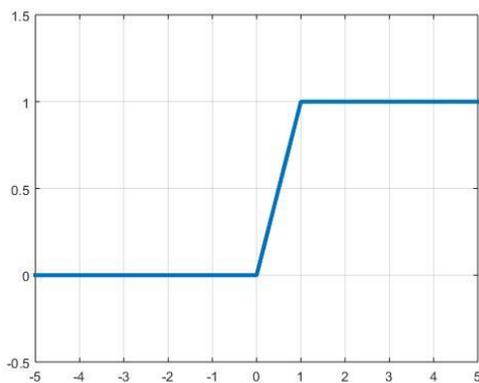


$$F_k(x) = x$$

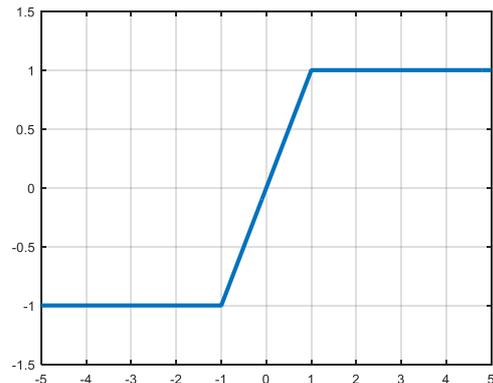
Figura 20-2: Función de activación lineal
Fuente: Elaborado por Iván Sinaluisa a partir de (Ponce, 2010)

Función de activación Mixta o Lineal a tramos

Es una variante progresiva de la función escalón. Si la activación de la unidad es menor que un límite inferior preestablecido, la salida se asocia con determinado valor; si la activación es igual o superior que un límite superior la salida se asocia con otro valor. Si el nivel de activación se encuentra comprendido entre ambos limites se aplica la función de identidad o lineal. Esta alternativa puede considerarse como una función lineal saturada en sus extremos, siendo de gran sencillez computacional y resultando más plausible desde el punto de vista biológico



$$F_k(x) = \begin{cases} 1 & \text{si } x < -c \\ 0 & \text{si } x > c \\ ax & \text{en otros casos} \end{cases}$$

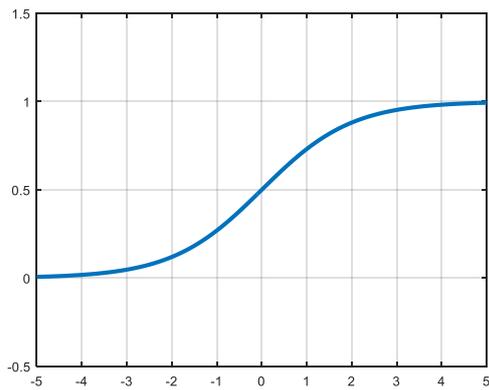


$$F_k(x) = \begin{cases} 1 & \text{si } x < -c \\ 0 & \text{si } x > c \\ \frac{x}{c} + \frac{1}{2} & \text{en otros casos} \end{cases}$$

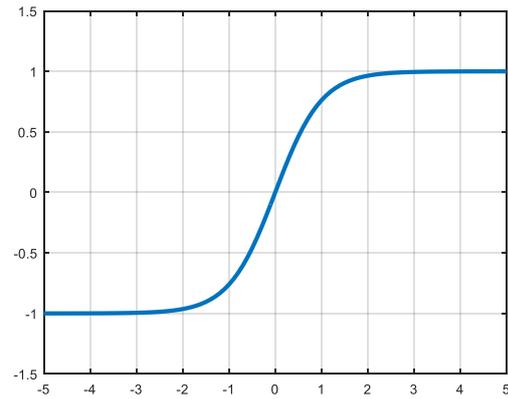
Figura 21-2: Función de activación mixta
Fuente: Elaborado por Iván Sinaluisa a partir de (Ponce, 2010)

Función de activación Sigmoidal

Con la función Sigmoidal el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace que, en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoide. De hecho, cuando la pendiente es elevada, esta función tiende a la función escalón. Sin embargo, la importancia de la función Sigmoidal es que su derivada siempre es positiva y cercana a cero para los valores grandes positivos o negativos; además, toma su valor máximo cuando $x = 0$. Esto hace que se puedan utilizar reglas de aprendizaje definidas para las funciones escalón, con la ventaja, respecto a esta función, de que la derivada está definida en todo el intervalo.



$$F_k(u) = \frac{1}{1+e^{-u}}$$



$$F_k(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}}$$

Figura 22-2: Función de activación sigmoideal

Fuente: Elaborado por Iván Sinaluisa a partir de (Ponce, 2010)

Función Tangente Hiperbólica

Es semejante a la función logística o Sigmoideal, pero su salida está entre -1 y 1 . Se utiliza con frecuencia en redes multicapas.

2.5 MARCO CONCEPTUAL O EPISTEMOLOGICO

2.5.8 *Energía*

La energía es la capacidad de los cuerpos o conjunto de éstos para efectuar un trabajo, todo cuerpo material que pasa de un estado a otro produce fenómenos físicos que no son otra cosa que manifestaciones de alguna transformación de la energía (McGraw-Hill, 1991).

De igual manera para (Omega, 1979) energía es la capacidad de un cuerpo o sistema para realizar un trabajo, por lo que puede transformarse en trabajo mecánico en cualquier forma (Eléctrica, mecánica, nuclear, química, calor, ...)

Otros autores como (Twidell & Weir, 2006), la definen como “la energía obtenida de las continuas o repetitivas corrientes de energía recurrentes en el entorno natural”.

La Directiva 2009/28/CE (IDAE, 2010) define la energía procedente de fuentes renovables como “aquella que procede de fuentes renovables no fósiles, es decir, energía eólica, solar, aerotérmica, geotérmica, hidro térmica y oceánica, hidráulica, biomasa, gases de vertedero, gases de plantas de depuración y biogás”.

2.5.9 *Energía eléctrica*

Según (Centrosur, 2016) es la potencia eléctrica que ha sido utilizada durante un determinado período de tiempo, utiliza como unidad el Kilovatio Hora (kWh).

Mientras que para (McGraw-Hill, 1991) la energía eléctrica es la energía de cargas eléctricas en virtud de su posición en un campo eléctrico y energía de corrientes eléctricas en virtud de su posición en un campo magnético.

Para (Quintela & Redondo, 2005) es la relacionada con la corriente de partículas llamadas electrones, y se define como el producto de la potencia eléctrica (kW) por el tiempo. Por lo tanto, la energía eléctrica se mide en kilowatt-hora (kWh).

La distribución de la energía eléctrica será realizada por empresas conformadas como sociedades anónimas para satisfacer, en los términos de su contrato de concesión, toda demanda de servicios de electricidad que les sea requerida. El CONELEC otorgará la concesión de distribución, manteniendo un solo distribuidor por cada una de las áreas geográficas fijadas en el Plan Maestro de Electricidad. En el contrato de concesión se establecerán los mecanismos de control de los niveles de calidad de servicio,

tanto en lo técnico como en lo comercial, y de identificación de las mejoras de cobertura. En ningún caso el Estado garantizará la rentabilidad del negocio, ni establecerá tratamientos tributarios especiales o diferentes a los que rijan al momento de la celebración del contrato (CELEC, 1996).

2.5.10 Predicción

Según (Bunge, 2000) las predicciones guardan relación con teorías y datos científicos (o tecnológicos), es decir, la predicción es una aplicación de la teoría científica.

La predicción científica anticipa nuevo conocimiento, es una contrastación de la teoría y una guía de acción. Desde el punto de vista cognoscitivo, la predicción puede considerarse como "visión anticipada".

La predicción es, en primer lugar, una manera eficaz de poner a prueba las hipótesis; pero también es la clave del control o aun de la modificación del curso de los acontecimientos.

La predicción científica, en contraste con la profecía se funda sobre leyes y sobre informaciones fidedignas, relativas al estado de las cosas actual o pasado.

La predicción científica se caracteriza por su perfectibilidad antes que por su certeza. Más aun, las predicciones se hacen con la ayuda de reglas empíricas son a veces más exactas que las predicciones penosamente elaboradas con herramientas científicas (leyes, informaciones específicas y deducciones). Pero en tanto que la profecía no es perfectible y no puede usarse para poner a prueba una hipótesis, la predicción es perfectible y, si falla, nos obliga a corregir nuestras suposiciones, alcanzando así una inteligencia más profunda.

2.5.11 Métodos de predicción

Para predecir la demanda a nivel global el concejo nacional de electricidad del Ecuador menciona que el estudio de análisis, estimación y proyección de la demanda eléctrica implica un proceso donde deben cumplimentarse diferentes etapas (ARCONEL, 2014):

- Análisis de la situación actual de la demanda,
- Elección del método de proyección,
- Proyección de la demanda.

Elección del método de estimación y proyección

La elección del método y la validez de los resultados obtenidos (outputs) están íntimamente vinculadas a la disponibilidad y calidad de los datos de entrada (inputs).

El método de estimación y proyección depende no solo del objetivo de la proyección sino del horizonte del estudio y de las características de la información disponible. Esto es, la longitud y el comportamiento (estable o errático) de las series históricas a proyectar y de sus determinantes en el período histórico; la disponibilidad y calidad de valores de los determinantes en el período de proyección.

Modelos econométricos

Los modelos econométricos permiten explicar el comportamiento de una o más variables en función de otras a través de la estimación de una relación matemática. En el modelo sólo se incluyen variables que se pueden cuantificar o valorar y que están disponibles.

Este tipo de modelos cuenta con una parte determinística (relación) y con una componente estocástica que se denomina residuo o error. En dicha componente se encuentran comprendidas aquellas variables que se consideran irrelevantes, o variables que si bien tienen influencia no es posible medir y los errores de medición. Esto es, el residuo representa la variación que no es explicada por el modelo.

En los casos que fueron posible, se estima la demanda empleando modelos econométricos desarrollados en base a información histórica de frecuencia anual. La formulación de los modelos econométricos se basa en una especificación del tipo lineal en logaritmos, como se expresa a continuación:

$$\ln Y_t = \ln \alpha + \beta_1 \ln X_{1t} + \beta_2 \ln X_{2t} + \dots + \beta_k \ln X_{ik} \quad (2-29)$$

Donde:

\ln : Modelo lineal a estimar

Y_t : es la variable a explicar.

X_t : son las variables explicativas.

e_t : es el término de error aleatorio.

En cuanto a los coeficientes:

α : es la ordenada al origen.

β : representan las elasticidades de Y_t con respecto a las X_t . La elasticidad mide el cambio porcentual que se produce en la variable Y_t ante un cambio del 1% en cualquiera de las variables explicativas.

Los parámetros del modelo, α y β , conjuntamente con la variabilidad de ϵ_t son desconocidos, por lo tanto, deben estimarse en base a los datos disponibles de X_t e Y_t .

El método de estimación de los modelos econométricos usualmente empleado, y que ha sido utilizado por las empresas eléctricas del Ecuador, es el de Mínimos Cuadrados Ordinarios (MCO). En esta oportunidad, el software E-VIEWS versión 7 fue utilizado para correr las regresiones (ARCONEL, 2014).

2.5.12 Demanda de energía eléctrica

La proyección de demanda futura de energía constituye una acción primaria, básica y esencial en el proceso de decisión de las posibles alternativas de inversión sectorial y de desarrollo a nivel país, ver figura 23-2. Asimismo, constituye un insumo para la elaboración de presupuestos, estudios de pérdidas e inversiones y la realización de cálculos tarifarios (ARCONEL, 2014).

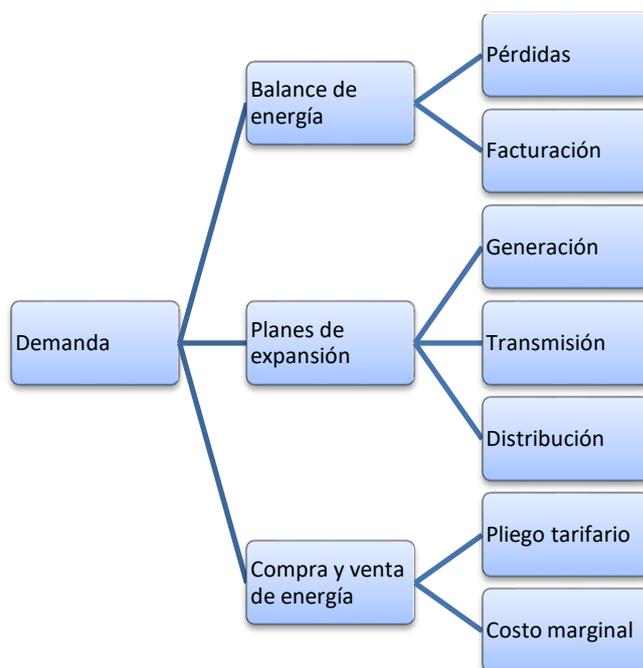


Figura 23-25: Uso de la demanda dentro de la planificación
Fuente: (ARCONEL, 2014)

Según (Harper, 2004) la demanda de energía eléctrica es la cantidad de potencia que un consumidor utiliza en un periodo de tiempo. La demanda de una instalación eléctrica en los terminales receptores, es tomada como un valor medio en un intervalo determinado.

Mientras que (Secretaría de energía de México, 2005) define como requerimiento instantáneo a un sistema eléctrico de potencia, normalmente expresado en mega vatios (MW) o kilowatts (kW).

Por último (Centrosur, 2016) define con la potencia eléctrica promedio consumida en un intervalo de 15 minutos, por lo que para establecer una demanda es indispensable indicar el intervalo de demanda ya que sin él no tendría sentido práctico, por lo tanto, se puede expresar en kWh,

2.5.13 Pronóstico de demanda de energía eléctrica

El pronóstico de la demanda de energía eléctrica puede ser de dos formas, energía (utiliza demanda de electricidad en unidades de Wh) y potencia (Demanda eléctrica en unidades de W), usualmente los OR realizan proyecciones de potencia horaria (energía) en el orden de los MWh (Universidad Tecnológica de Pereira, 2013)

El pronóstico de la demanda de energía eléctrica es un procedimiento sistemático que permite definir cuantitativamente la demanda futura y por ser de vital importancia debe procurarse que dicha información sea lo más exacta posible, sin olvidar la presencia de incertidumbres (ARCONEL, 2014).

2.5.14 Red neuronal

(Cortina Januchs, 2012) Manifiesta que, las RNA son modelos matemático-computacionales que poseen una elevada capacidad de generalización y de tratamiento de problemas tanto lineales como no lineales, no requiere un conocimiento exhaustivo de la distribución de las variables en estudio.

Las RNA tratan de emular el sistema nervioso, de forma que son capaces de reproducir algunas de las principales tareas que desarrolla el cerebro humano, al reflejar las características fundamentales de comportamiento del mismo. Lo que realmente intenta modelizar las redes neuronales, es una de las estructuras fisiológicas de soporte del cerebro, la neurona y los grupos estructurados e interconectados de varias de ellas, conocidos como redes de neuronas. De este modo, construyen sistemas que presentan un cierto grado de inteligencia.

2.5.15 Aprendizaje

Según (Bruner, 2001), Aprendizaje es el proceso de interacción en el cual una persona obtiene nuevas estructuras cognoscitivas o cambia antiguas ajustándose a las distintas etapas del desarrollo intelectual.

El aprendizaje como proceso interno implica para Bruner cuatro momentos o etapas por las cuales un sujeto aprende:

a) **Predisposiciones:** Constituyen los motivos internos que mueven al sujeto para iniciar y mantener el proceso de aprendizaje.

b) **Exploración de alternativas:** Constituyen las estrategias internas que, activadas por la predisposición se mantienen en la búsqueda hasta lograr, mediante distintos ensayos descubrir lo que se buscaba.

c) **Salto intuitivo:** Es un estado, logrado generalmente de manera súbita como resultado del proceso del pensamiento. No es expresable verbalmente, a veces es muy rápido, otras lento, y extendido en el tiempo.

d) **Refuerzo:** Es el momento en que el que aprende considera valiosos sus hallazgos, válidas sus hipótesis, se corrige y se perfecciona.

(Knowles y otros, 2001:15) se basan en la definición de Gagné, Hartis y Schyahn, para expresar que el aprendizaje es en esencia un cambio producido por la experiencia, pero distinguen entre: El aprendizaje como producto, que pone en relieve el resultado final o el desenlace de la experiencia del aprendizaje. El aprendizaje como proceso, que destaca lo que sucede en el curso de la experiencia de aprendizaje para posteriormente obtener un producto de lo aprendido. El aprendizaje como función, que realza ciertos aspectos críticos del aprendizaje, como la motivación, la retención, la transferencia que presumiblemente hacen posibles cambios de conducta en el aprendizaje humano.

2.5.16 Aprendizaje automático

Según (Antonio Moreno y otros, 1994), Una metáfora habitual en el área del aprendizaje automático dentro de la Inteligencia Artificial es considerar la resolución de problemas como un tipo de aprendizaje que consiste una vez resuelto un tipo de problema en ser capaz de reconocer la situación problemática y reaccionar usando la estrategia aprendida.

El aprendizaje automático, también llamado aprendizaje artificial (Plaza, 1992), se dice que un sistema que aprende de forma automatizada (o aprendiz) es un artefacto (o un conjunto de algoritmos) que, para resolver problemas, toma decisiones basadas en la experiencia acumulada en los casos resueltos anteriormente para mejorar su actuación. Estos sistemas deben ser capaces de trabajar con un rango muy amplio de tipos de datos de entrada, que pueden incluir datos incompletos, inciertos, ruido, inconsistencias, etc.

2.5.17 Entrenamiento

Conceptualmente, (Sánchez-Bañuelos, 1993), desde una perspectiva científica, define al entrenamiento como “*una actividad de búsqueda continua de los límites físicos a los que puede llegar el ser humano en el contexto de la competición deportiva, bajo el método científico y el abandono sistemático del método empírico*”, lo cual lleva consigo:

- Una actitud de duda sistemática y de autocrítica constante y su relación con los procesos cíclicos en el entrenamiento deportivo.
- La identificación de los problemas pertinentes y su definición precisa. La formulación tentativa de hipótesis sobre la solución de los mismos.
- Los datos empíricos, los procesos de interpretación inductivos y deductivos y el sometimiento a las reglas formales.
- Metodología del entrenamiento basada en la selección y priorización del trabajo.

(P. López Álvarez, R.Velo Sabín, y F. Maseda Eimil, 2007), manifiestan que, el entrenamiento es el procedimiento mediante el cual la red neuronal aprende y el aprendizaje es el resultado final de este proceso. El aprendizaje se realiza a partir de todo el conjunto más que por la aportación individual de cada elemento.

El proceso de entrenamiento es normalmente iterativo, actualizándose los pesos una y otra vez hasta que se alcanza el objetivo deseado. Una vez que la red ha sido entrenada se pasa al modo de ejecución o recuerdo, que consiste en mantener fijos los pesos de la red y procesar datos, es decir, la red es capaz de responder ante entradas no vistas con anterioridad.

CAPÍTULO III

3. DISEÑO DE LA INVESTIGACIÓN

Basado en el marco teórico descritos en el Capítulo II, en el presente capítulo se enunciará la metodología, método y materiales utilizados para el desarrollo del modelo de predicción basado en Redes Neuronales FeedForward Backpropagación, el mismo que enmarco en las siguientes etapas: Preprocesamiento de datos históricos, entrenamiento de la red neuronal, validación y pruebas de los modelos.

3.1 Metodología de la investigación

En la figura 1-3 muestra la metodología utilizada en el presente trabajo de investigación:

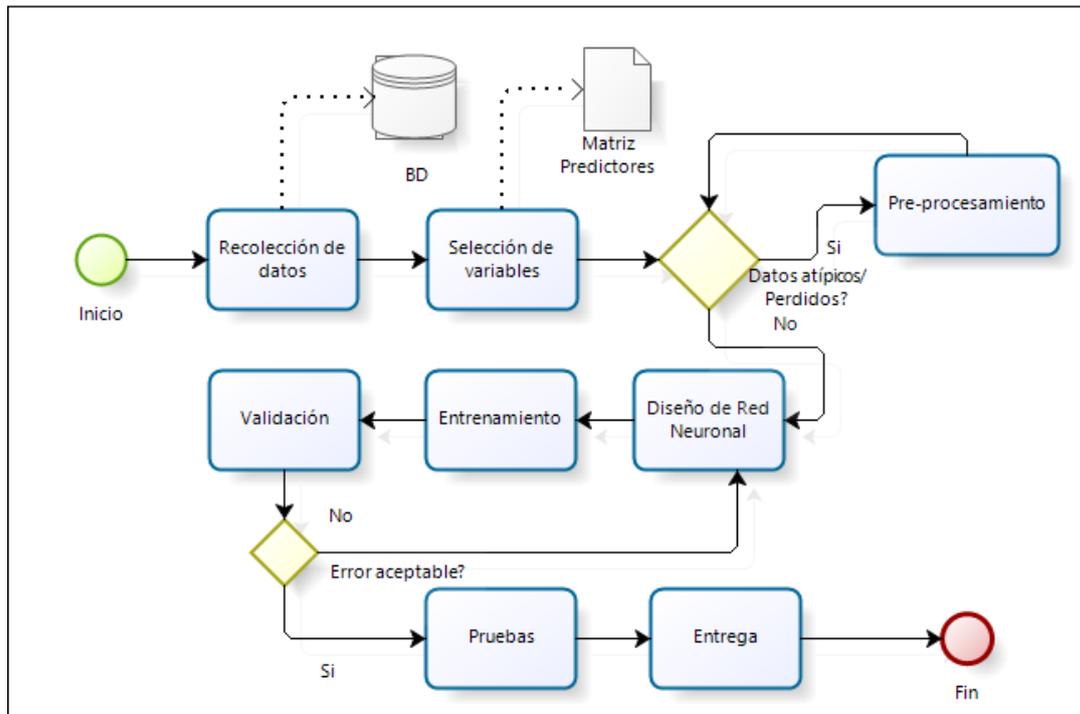


Figura 1-3: Metodología del trabajo de Investigación

Fuente: Iván Sinaluisa a partir de (Hanke & Wichem, 2006)

Sin embargo, el enfoque en el que se orienta este trabajo investigativo es el cuantitativo debido a que se toma como centro del proceso de investigación las mediciones numéricas, además utiliza la observación del proceso en forma de recolección de datos y los analiza para llegar a responder la pregunta de investigación y probar la hipótesis planteada.

Los métodos de investigación científica que se aplicó es el experimental y el descriptivo debido a que el investigador pretende establecer el posible efecto de una causa que se manipula, adicionalmente se describirán y explicarán los procesos que enmarquen los modelos de aprendizaje automático (Sampieri, 2010).

Finalmente se utiliza técnicas estadísticas debido a que los resultados finales serán cuantitativos debido a que se obtendrá, se analizará, interpretará y se comparará el porcentaje de error de predicción de la demanda de energía eléctrica.

Los materiales utilizados son:

Tabla 1-3: Materiales utilizados en la investigación

ITEM	DESCRIPCION
1	Personal
2	Equipos, software y servicios técnicos
3	Materiales y suministros
4	Transporte, salida a campo
5	Gastos diversos
6	Imprevistos
7	Insumos para memoria de tesis

Elaborado: Iván Sinaluisa

Las principales fuentes que se utilizó en el presente estudio de investigación son:

Primaria:

- Información original obtenida por el investigador mediante visitas de campo con el fin de contrastar la hipótesis.

Secundaria:

- Artículos publicados en revistas científicas indexadas y no indexadas serias.
- Tesis de postgrado publicadas a nivel nacional e internacional con temas afines al investigado.

- Conferencias académicas, congresos, seminarios.
- Páginas de internet que brinden información confiable y especializada.
- Libros especializados en la biblioteca y electrónicos.
- Revistas electrónicas.

3.2 Preprocesamiento de datos

En este apartado se realizó el análisis de los datos obtenidos de demanda eléctrica para determinar su comportamiento, además se detecta y se corrige los valores atípicos (outliers) tomando una muestra para su análisis a través de los métodos de diagrama de cajas y de Grubbs. Por último, se realiza el suavizado y discretización de los datos para un adecuado entrenamiento de la red neuronal FeedForward Backpropagation.

Los datos fueron proporcionados por la EERSA de los contadores de energía de las tres salidas perteneciente a la compañía Celec Ep Transelectric empresa encargada de la transmisión de energía eléctrica del sistema nacional interconectado. Del total de las observaciones de la base de datos recogida se dividió en dos grupos: 61344 (2009 -2015) observaciones para preprocesamiento y 8784 (2016) para pruebas de funcionamiento del modelo.

3.2.1 *Análisis de la información utilizada*

Como se mencionó anteriormente para la ejecución del preprocesamiento de datos se utilizó la información de siete años (2009 – 2015).

En la figura No. 2-3 se presenta la serie de tiempo de la demanda de energía eléctrica, para una mejor presentación solo se muestra 6000 observaciones, donde se evidencia a simple vista que existen valores atípicos (outliers) y perdidos que serán analizados y corregidos en el siguiente apartado para mejorar la calidad de la serie.

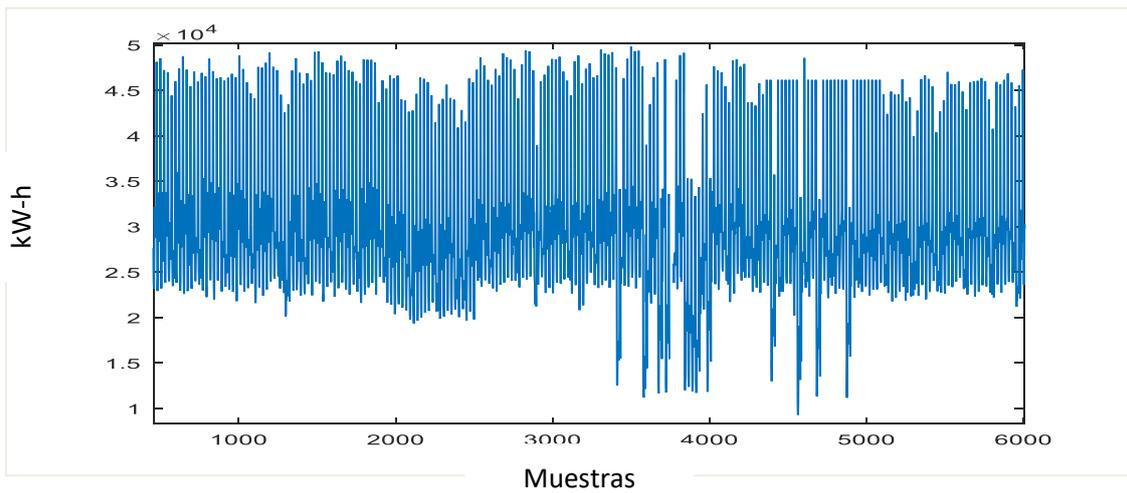


Figura 2-3: Serie de tiempo demanda de energía eléctrica
 Fuente: Realizado por: Iván Sinaluisa

Con el fin de analizar la demanda de energía eléctrica se graficó el perfil de demanda diario de toda la serie de tiempo en un periodo de 24 horas, donde se evidenció que la hora de mayor consumo (hora pico) es a las 20H00, como se muestra en la figura 3-3.

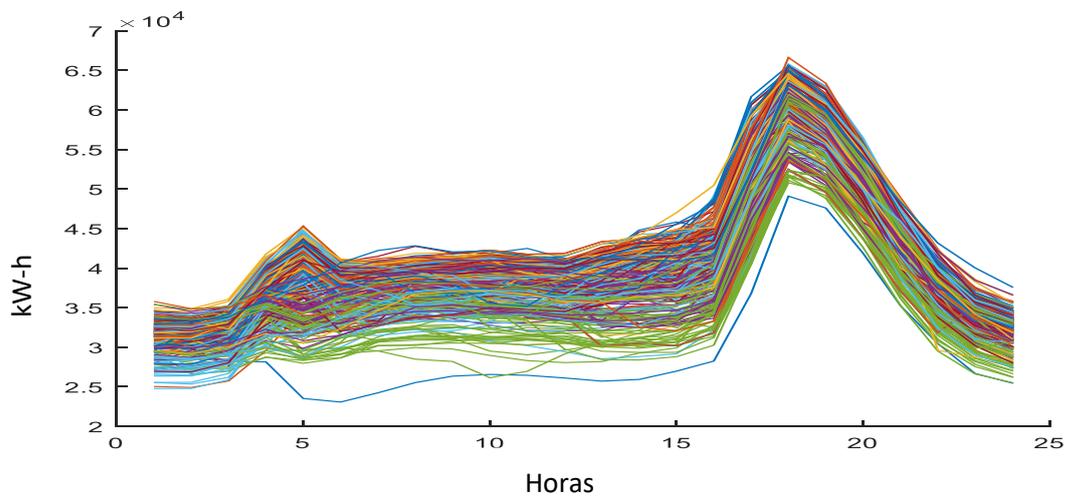


Figura 3-1: Perfil de carga del diaria por hora del año 2014
 Fuente: Realizado por: Iván Sinaluisa

La demanda de energía eléctrica, durante los días de descanso es decir sábados y domingo tienden a decrecer aproximadamente en un 10 % con relación a los días laborables esto da debido a que las instituciones públicas y pequeña fabricas no laboran en estos días, ver figura 4-3.

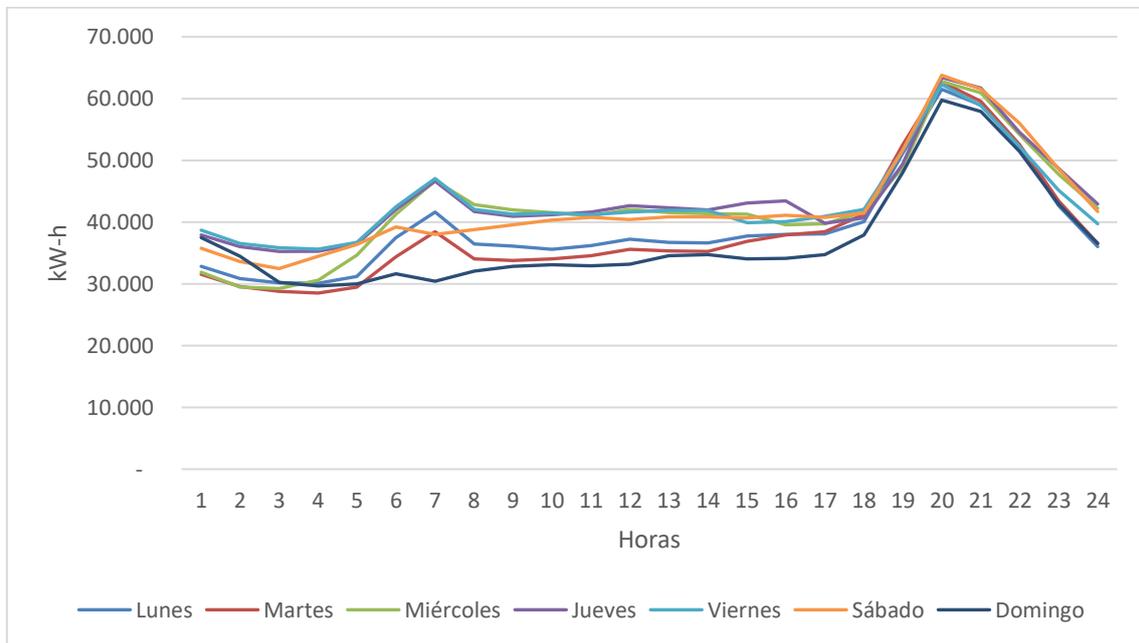


Figura 4-3: Perfil de carga del diaria por día de la semana año 2014
Fuente: Realizado por: Iván Sinaluisa

Sin embargo, también se detectó la existencia de valores perdidos o no registrados, por ejemplo, para el caso del año 2009 faltan datos del 6 de junio, en el año 2012, en el 20013 faltan datos del 01 de junio y 01 de septiembre, mientras que en el 2014 faltan datos del 17 de enero, 23 de febrero, 12, 13, 14, 15 y 16 de marzo, 5 de octubre y 31 de diciembre y por último en el año 2015 no se dispone de los días 19, 20, 21, 22 y 23 de julio.

Para determinar la distribución de frecuencias de los valores contenidos en la serie de tiempo demanda eléctrica se utilizó el histograma, además de que es una primera representación gráfica o panorama de la distribución de los datos de consumo de energía eléctrica. En la figura No.5-3 se puede apreciar que

la campana de gauss es muy simétrica con una media de 35840,34, máximo de 71315,00, mínimo de 2976,1 y una desviación estándar de 8755,6.

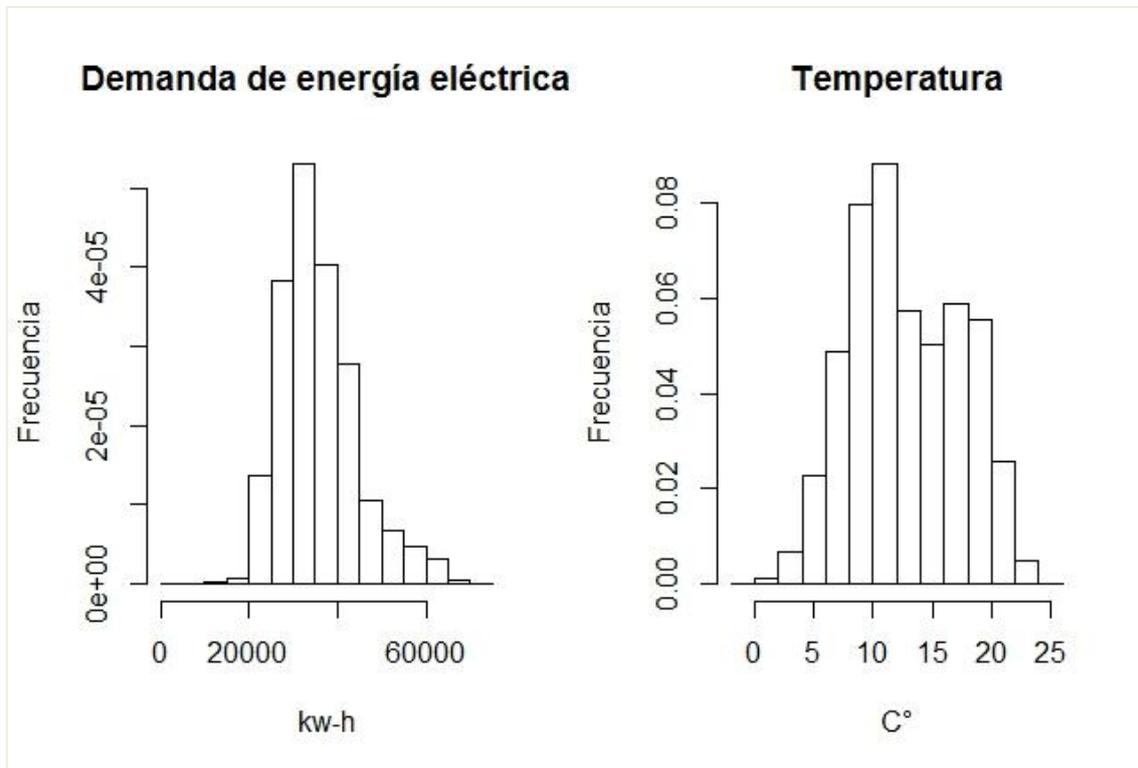


Figura 5-3: Distribución de las Series de Tiempo Demanda Eléctrica y Temperatura
Fuente: Realizado por: Iván Sinaluisa

3.2.2 Selección de variables

Esta etapa comprende el análisis de las características, dinámica y funcionamiento actuales de la demanda (clientes y energía) con el objeto de identificar las variables o factores que afectan su comportamiento. Esto es con la intención de actuar sobre el funcionamiento de las variables para controlar su trayectoria, poder proyectarla y realizar predicción idónea.

Basado en lo mencionado por (Delmar, García, Alexander, & Milanés, 2003), en base a otras investigaciones los factores pueden afectar sensiblemente a la demanda de energía eléctrica se muestran en la tabla No. 2-3.

Tabla 2-3: Factores que afectan a la demanda de energía eléctrica.

Factores	Variables	Unidades	Nomenclatura
Calendario	Año	a	X1
	Mes	m	X2
	Día	d	X3
	Hora	h	X4
	Días laborables	dl	X5
	Feridos	f	X6
Eléctricos	Demanda eléctrica	Kw-h	X7
Climáticos	Temperatura	°C	X8
	Humedad	g/m ³	X9
	Precipitaciones	mm	X10
	Nubosidad		X11
	Radiación solar	Gy	X12
	Velocidad del viento	Km/h	X13
Económicos	PIB	p	*

Fuente: (Delmar et al., 2003),

*Dato por hora no disponible

No se obtuvo datos económicos por hora, sin embargo, con los datos de las variables disponibles se procedió mediante el método de correlación de Pearson a realizar la selección de variables mismas que influyen directa o inversamente en la demanda de energía eléctrica, para lo cual se dividieron las variables en dos grupos, G1: Variable demanda eléctrica vs calendario y G2: Variable demanda eléctrica vs variables meteorológicas, cuyos resultados se muestran las figuras 6-3 y 7-3 respectivamente:

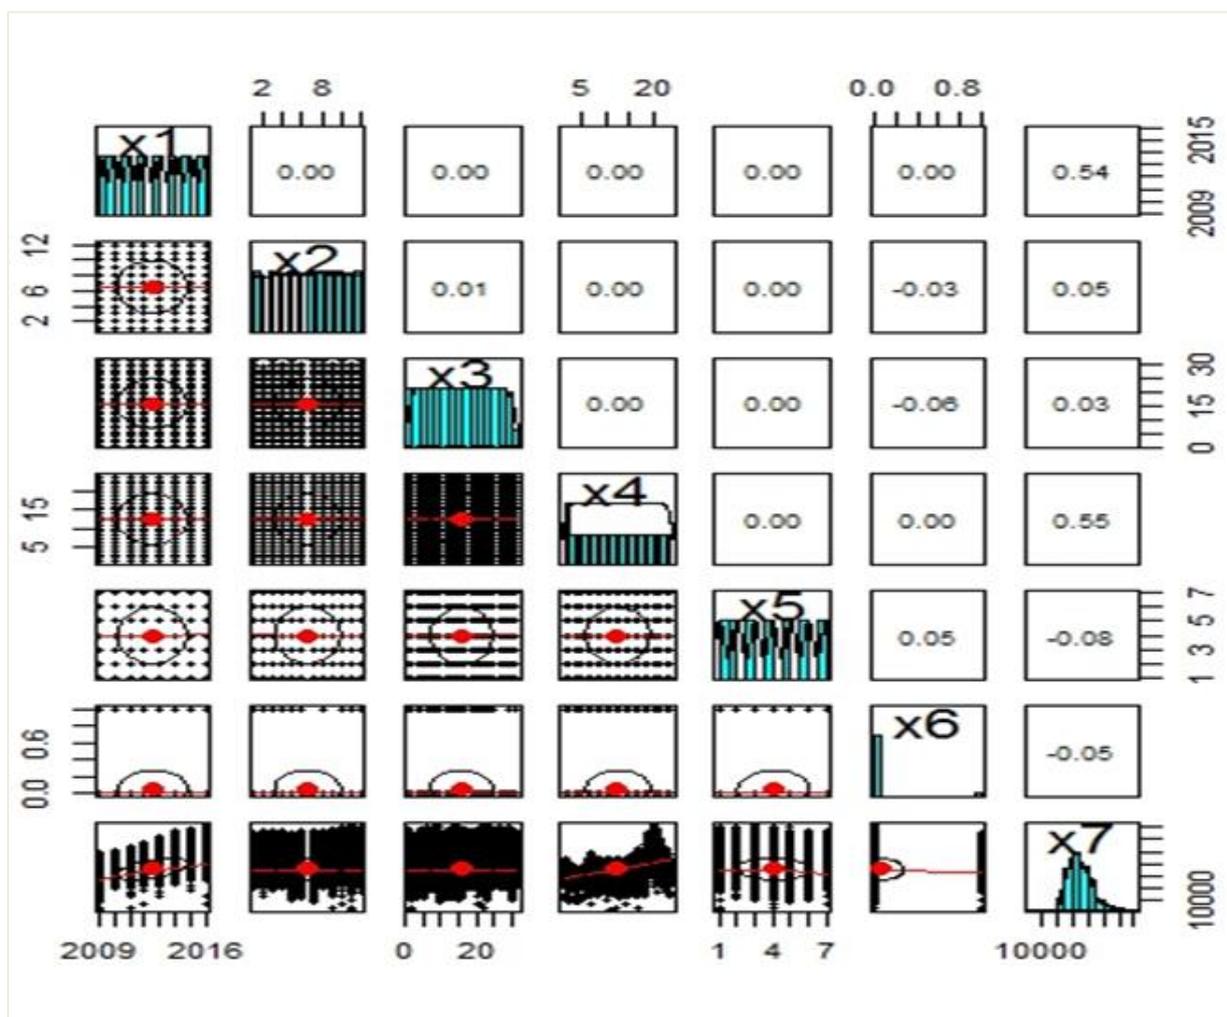


Figura 6-3: Correlación demanda de energía eléctrica vs variables calendario
Fuente: Realizado por: Iván Sinaluisa

En la figura 6-3 se determina que existe una aceptable correlación de la demanda de energía eléctrica con la variable año = x1 y hora = x4, sin embargo, como el año depende de los meses y los meses de los días se consideró el conjunto de variables fecha en el siguiente formato aa-mm-dd-00:00:00.

Mientras tanto que en la figura. 7-3 se muestra que existe un buena correlación entre la demanda de energía eléctrica = x7 y las variables temperatura = x8, Humedad = x9, radiación solar =x12 y velocidad del viento =13, sin embargo, se consideró solo la temperatura y humedad debido a que como se puede observar la variable temperatura tiene una correlación muy alta con las demás variables meteorológicas.

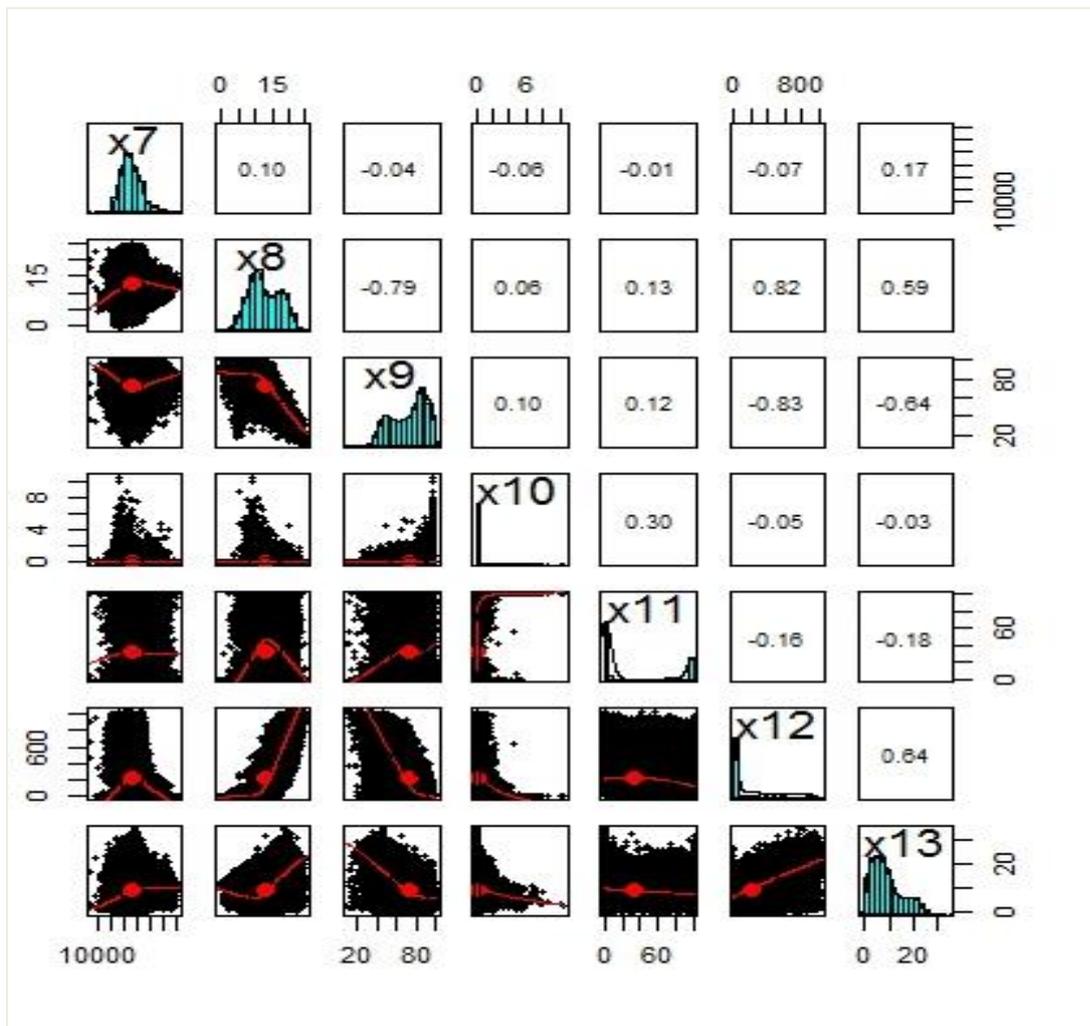


Figura 7-3: Correlación demanda de energía eléctrica vs variables meteorológicas

Fuente: Realizado por: Iván Sinaluisa

3.2.3 Detección y tratamiento de datos perdidos

Los valores perdidos al principio o fin de una serie de tiempo no suponen un problema especial; sencillamente acortan la longitud de la serie, en tanto que las discontinuidades que aparecen en la mitad de una serie (datos incrustados perdido) pueden ser problemas mucho más graves. El alcance del problema depende del procesamiento analítico que se utilice.

En la presente investigación en el análisis de los datos se realizó con el apoyo de los softwares SPSS y con R donde se cuantificó los valores perdidos en la base de datos, cuyos resultados se presentan en la tabla No. 3-3.

Tabla 3-1: Valores perdidos de las variables consideradas

Variable	Demanda	Temperatura
Numero de datos perdidos	406	192
Porcentaje datos perdidos	0,58	0,273

Fuente: Realizado por: Iván Sinaluisa

Según (Segura Chavez & Torres, 2014) hay 3 técnicas para el tratamiento de valores perdidos:

El primero es la eliminación seguramente la opción más sencilla que consiste en eliminar las observaciones que contengan datos perdidos, esto se lo recomienda solo si el porcentaje de observaciones a eliminar es menos a 1%. La segunda técnica consiste en reemplazar o imputar valores perdidos con valores conocidos, para esto existe muchos métodos desde los más sencillos (reemplazo por media o mediana) hasta métodos más complejo, pero a su vez más robustos como modelo de regresión. La otra opción es no realizar imputaciones esto debido a que en algunos casos es factible analizar la información por separado.

Para el caso de esta investigación se procedió a eliminar las observaciones con valores perdidos debido a que el porcentaje de valores perdidos fue de 0,58%, por lo tanto, la base de datos quedó con 60962 observaciones.

3.2.4 *Análisis y tratamiento de datos atípicos*

Con el objetivo de ratificar técnicamente la existencia de valores atípicos en la serie de tiempo tanto de demanda de energía eléctrica, como la serie temperatura que son visualizados la figura 3-2, se procedió se emplear tres técnicas para corroborar la existencia de valores atípicos: Diagrama de cajas, Método de los cuartiles, y prueba de Grubbs.

Diagrama de cajas

El diagrama de cajas conocido también como de bigotes, permite apreciar de manera visual como se distribuyen los valores de una variable, si están más o menos concentrados o dispersos respecto a los cuartiles centrales, y si existen valores anómalos (outliers) (Ojeda, 2014).

En el caso de la serie de tiempo de demanda de energía eléctrica, en la figura 8-3 se puede evidenciar a simple vista que existe valores atípicos moderado y extremos. En la serie de tiempo de temperatura no se evidencia valores atípicos. Además, se puede apreciar que en la serie de tiempo de demanda eléctrica existe mayor concentración, mientras que la serie de temperatura tiene mayor dispersión.

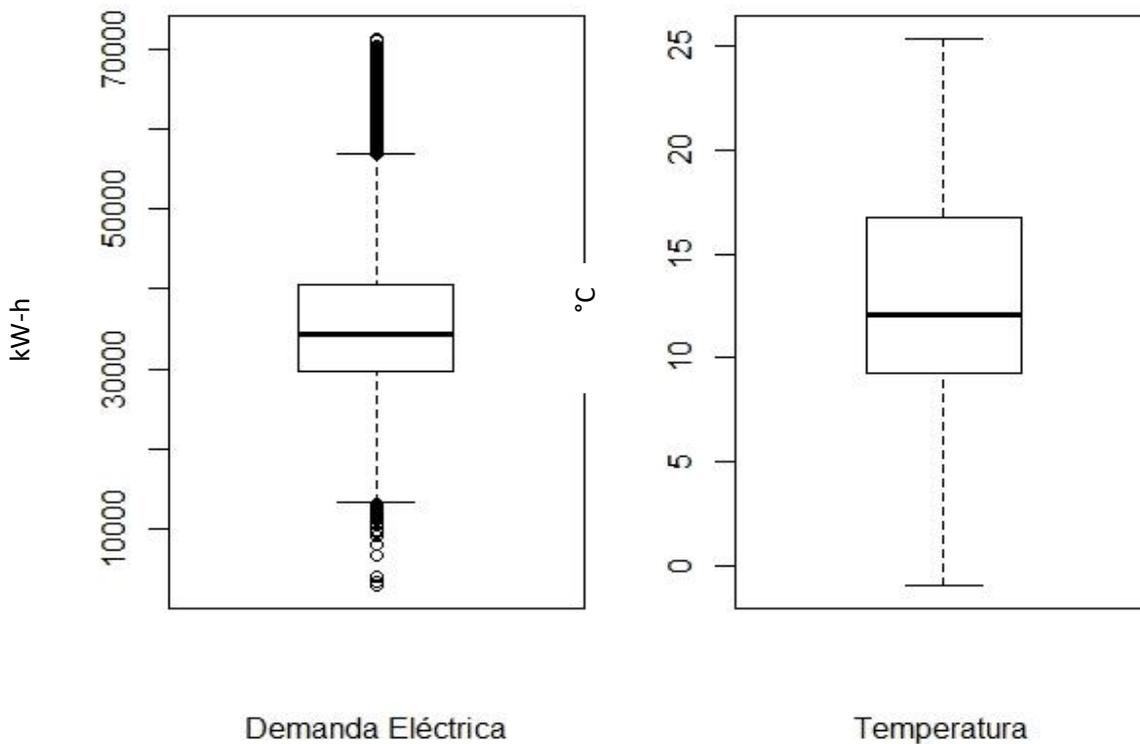


Figura 8-3: Detección de valores atípicos con diagrama de cajas
Fuente: Realizado por: Iván Sinaluisa

Como la media se sitúa en el centro de la caja la distribución se puede considerar que es simétrica la serie de demanda de energía eléctrica, caso contrario es la serie de temperatura que se aproxima a los límites de la caja (Q1 ó Q3) por lo tanto tenemos un diagnóstico de asimetría negativa.

Método de los cuartiles

Los cuartiles “Q” son tres valores de la variable de estudio que divide a un conjunto de datos ordenados de menor a mayor en cuatro partes iguales, se los representa mediante Q1, Q2 y Q3 correspondientes a los valores 25%, 50% y 75% de los datos respectivamente. Además, el cuartil Q2 representa a la media del conjunto de datos.

La posición de los cuartiles se los calcula con la ecuación no. 1-3

$$P_Q: \frac{Qxn}{4} \tag{ 1-3 }$$

Donde:

P_Q: Posición del cuartil

Q: Numero de cuartil

n: Numero de datos

Serie de tiempo demanda eléctrica,

Cuartil	Q1	Q2	Q3
Porcentaje	25%	50%	75%
Valor	29719.34	34405.66	40563.21
Posición	17382	34765	52147

El rango Inter cuartil (IQR) es la diferencia entre Q3 y Q1 =10843.87

Serie de tiempo Temperatura

Cuartil	Q1	Q2	Q3
Porcentaje	25%	50%	75%
Valor	9.24	12.07	16.74
Posición	17382	34765	52147

El rango Inter cuartil es $IQR = 7.5$

Existe dos tipos de valores atípico denominados moderados y extremos. Se considera a un valor atípico moderados cuando excede 1,5 unidades de la longitud de la caja es decir la distancia de los cuartiles $25(Q1)$ y $75(Q3)$.

Para definir los limites inferior y superior de los valores atípicos moderados de las series de tiempo se aplicó la ecuación 3-2 y 3-3 respectivamente:

$$L_{inf} = Q1 - 1.5(Q3 - Q1) \quad (2-3)$$

$$L_{sup} = Q3 + 1.5(Q3 - Q1) \quad (3-1)$$

Se considera a un valor atípico moderados cuando excede 3 unidades de la longitud de la caja es decir la distancia de los cuartiles $25(Q1)$ y $75(Q3)$.

Para definir los limites inferior y superior de los valores atípicos extremos de las series de tiempo se aplicó la ecuación 4-3 y 5-3 respectivamente:

$$L_{inf} = Q1 - 3(Q3 - Q1) \quad (4-3)$$

$$L_{sup} = Q3 + 3(Q3 - Q1) \quad (5-3)$$

Los resultados se detallan en la tabla 4-3.

Tabla 4-3: Detección de valores atípicos método de los Cuartiles

Serie	Cuartil		Rango atípico moderado		Rango atípico extremo	
	Demanda Eléctrica (Kw-H)	Q1=	29059.63	L _{inf}	13.680,54	L _{inf}
Q3=		39312.89	L _{sup}	54.693,02	L _{sup}	70.073,82
Temperatura (°C)	Q1=	9.24	L _{inf}	13.453,54	L _{inf}	-13,26
	Q3=	16.74	L _{sup}	56.829,02	L _{sup}	38,24

Fuente: Realizado por: Iván Sinaluisa

Al ser una serie temporal con tendencia positiva se consideró como límite inferior 13680,50 y como límite superior 70073,82, por lo que aplicando la ecuación 2-3 y 5-3.

En la figura 9-3 de dispersión de la serie de tiempo se observa que la mayoría de datos atípicos corresponden al año 2009.

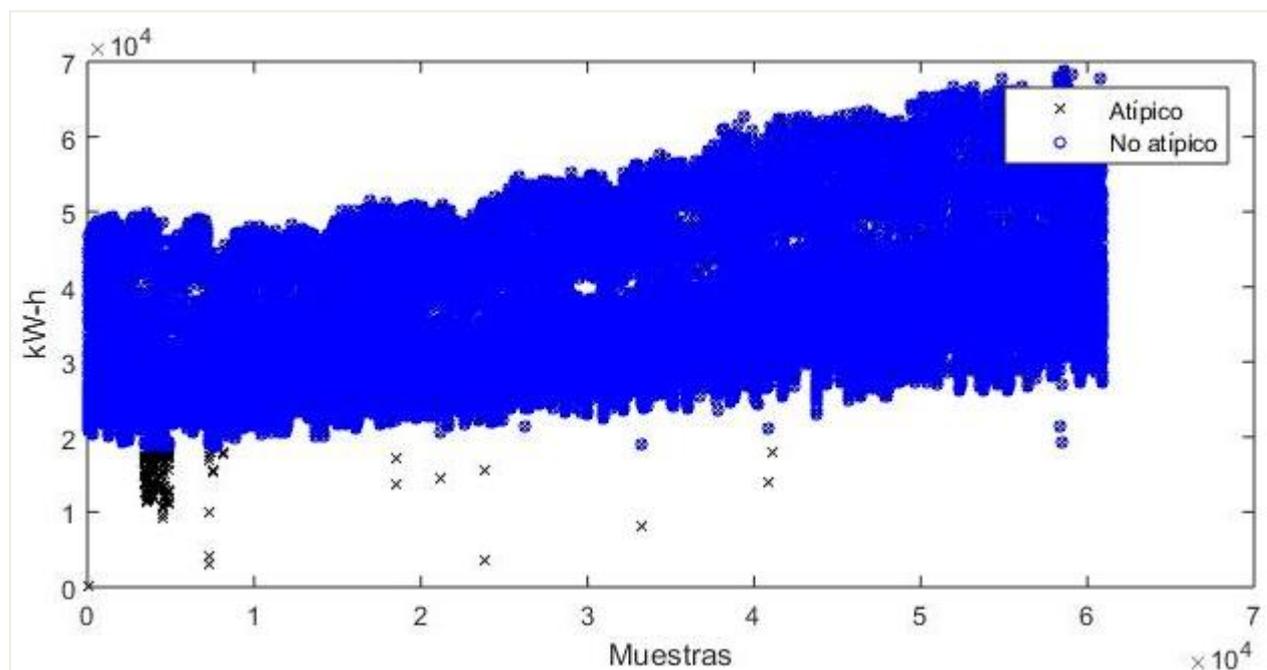


Figura 9-3: Datos atípicos de la serie de tiempo demanda eléctrica

Fuente: Realizado por: Iván Sinaluisa

En las series de tiempo tanto de temperatura (ver figura 10-3) como de humedad no se encontró cuantifico datos atípicos por lo que no fue necesario ningún tratamiento.

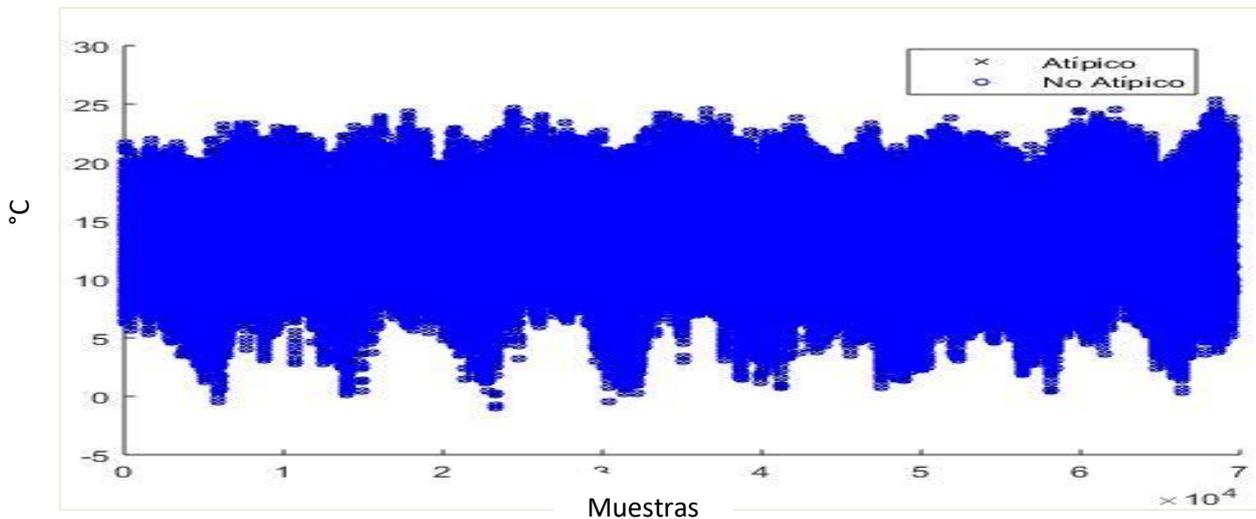


Figura 10-32: Datos atípicos de la serie de tiempo Temperatura
Fuente: Realizado por: Iván Sinaluisa

Prueba de Grubbs

La prueba de Grubbs también se la conoce como la prueba residual normalizada máxima o Desviación T de Studen (DTS), La estadística de prueba de Grubbs se define la versión de dos caras como:

$$G = \frac{|X_i - \bar{X}|}{s} \quad (6-3)$$

Donde:

G:

X_i : Dato a valorar

\bar{X} : media de la serie de datos

s: Desviación estándar

La prueba de Grubbs identifica que tan separado está el valor atípico del resto de los valores, obteniéndose el valor de G que representa el valor absoluto de la diferencia de la media y el atípico, dividido por la desviación estándar, es decir es la mayor desviación absoluta de la media muestral en unidades de la desviación estándar de la muestra. (Ortiz, 2014).

Para el caso de estudio se tomó una muestra de 60 datos con posibles valores atípicos (ver figura 10-3), correspondientes al mes de noviembre del 2009, donde se puede evidenciar en la figura 3-11 existe 2 valores atípicos mismos que superan el valor crítico de Grubbs para esta muestra que es de 3,03.

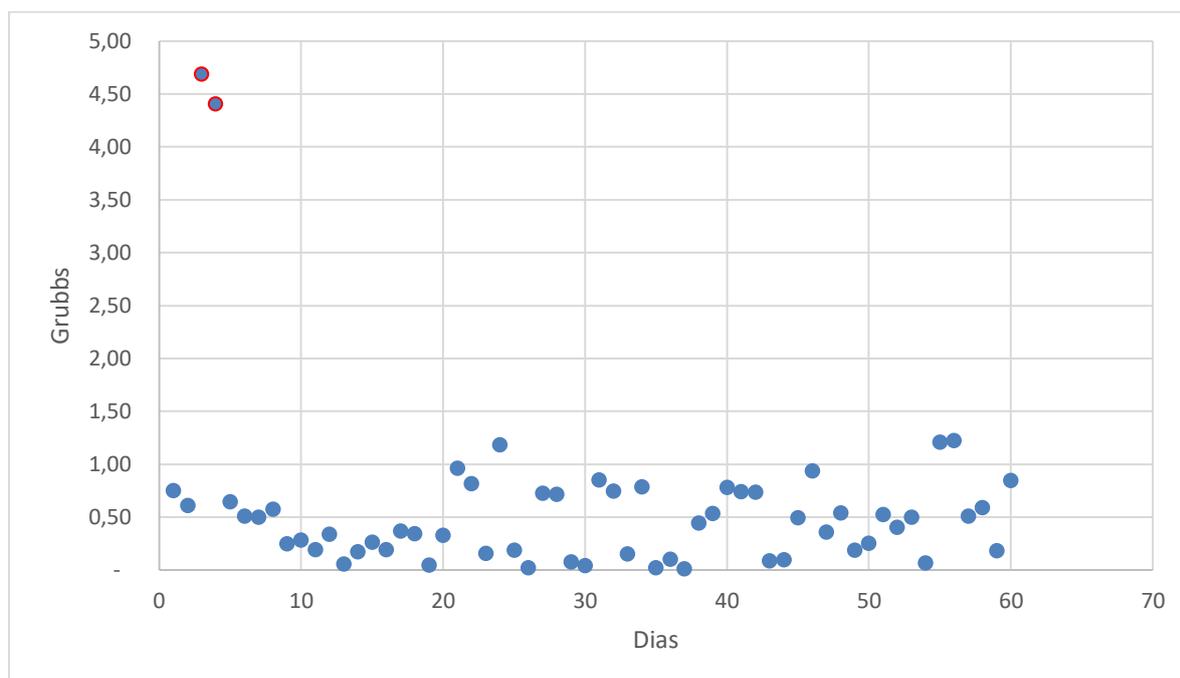


Figura 11-3: Valores atípicos demanda Eléctrica (11h00 y 12h00) noviembre de 2009

Fuente: Realizado por: Iván Sinaluisa

Luego de aplicar las técnicas de detección de valores atípicos, y en especial el método de los cuartiles se detectó que existen 320 valores atípicos en la serie temporal de demanda de energía eléctrica.

Tratamiento de los Atípicos

Una vez determinado los valores atípicos, existen técnicas para tratarlos, la más conocida y la más fácil es eliminarlos de la muestra, situación que puede afectar en la estimación si la serie es muy pequeña;

la segunda es sustituirlos por valores estadísticamente probables, en base a la función de distribución de probabilidad (FDP) de mejor ajuste.

Sin embargo, para solucionar el problema se utilizó la técnica de eliminación de muestra con valores atípicos y perdidos, luego de lo cual la serie para entrenamiento de la red neuronal quedó con 60618 observaciones.

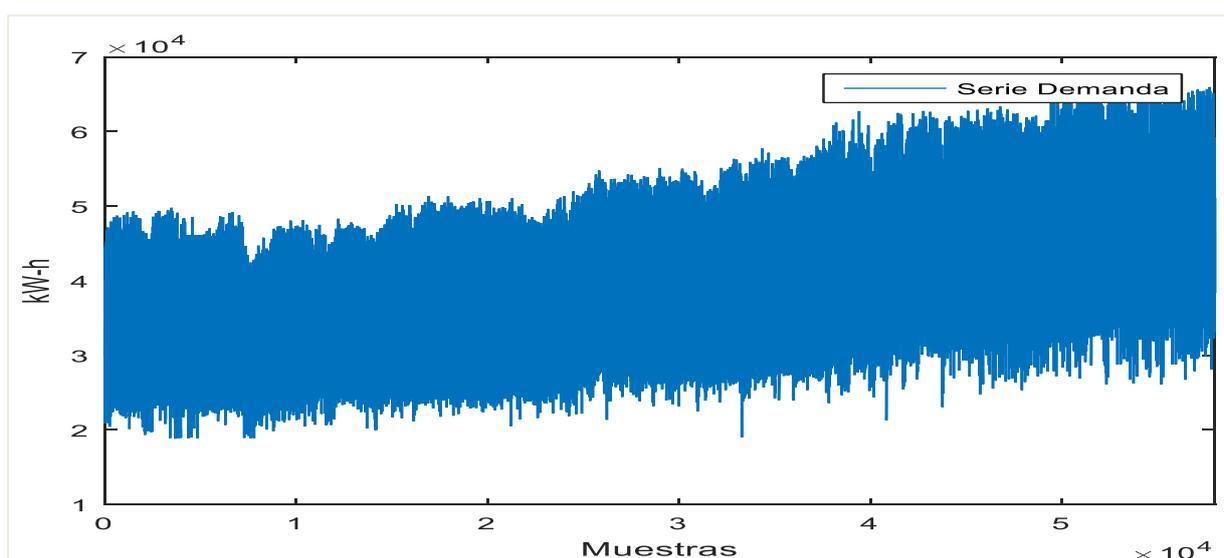


Figura 12-3: Serie de tiempo demanda eléctrica sin valores atípicos.

Fuente: Realizado por: Iván Sinaluisa

Para la serie de tiempo correspondiente a la temperatura no fue necesario realizar el tratamiento, toda vez que no existieron valores vacíos ni atípicos.

3.2.5 Suavizado de la serie temporal.

Con el objetivo de eliminar los valores picos en la serie de datos se utilizó el método de media móviles de tercer orden, que consiste en sustituir cada valor de la serie por la media obtenida con esa observación y algunos de los valores inmediatamente anteriores y posteriores, en este caso se utilizó la media móvil de tercer orden es decir de tres elementos.

$$M_i^3 = \frac{(y_{i-1} + y_i + y_{i+1})}{3} \quad (7-3)$$

Donde:

M_i^3 = Media móvil

y_{i-1} = Valor adyacente anterior

M_i^3 = Valor central

M_i^3 = Valor adyacente posterior

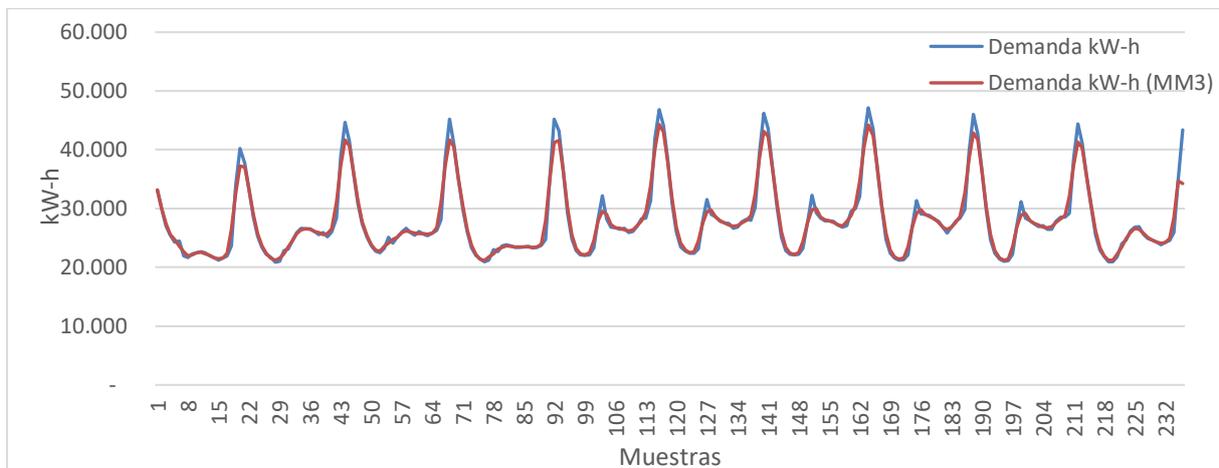


Figura 13-3: Suavizado de la serie de tiempo mediante media móvil

Fuente: Realizado por: Iván Sinaluisa

Como se puede observar en la figura 13-3 efectivamente se corrigen las observaciones con valores muy pronunciados considerándolos como ruido de la serie.

3.3.1 Normalización y acondicionamiento de datos

Una vez realizado el tratamiento de los datos perdidos y atípico tanto de la serie de tiempo de demanda eléctrica como de la temperatura, se procedió a acondicionar los valores mediante la normalización que consiste en representar estos valores en otra escala, que está comprendida en el intervalo 0 y 1, este procedimiento es muy necesario para mejorar el proceso de entrenamiento de la red neuronal. Existe

muchas formas de escalar una serie de tiempo, sin embargo, para la investigación se utilizó la siguiente formula:

$$r_i = \frac{y_i - \min}{\max - \min} \quad (8-3)$$

Donde:

ri= Dato con nueva escala
yi= Dato con escala original
min=Menor dato de la serie
max=mayor dato de la serie

Por la tanto la serie de tiempo de la demanda de energía eléctrica y temperatura normalizada se muestra en la figura 14-3:

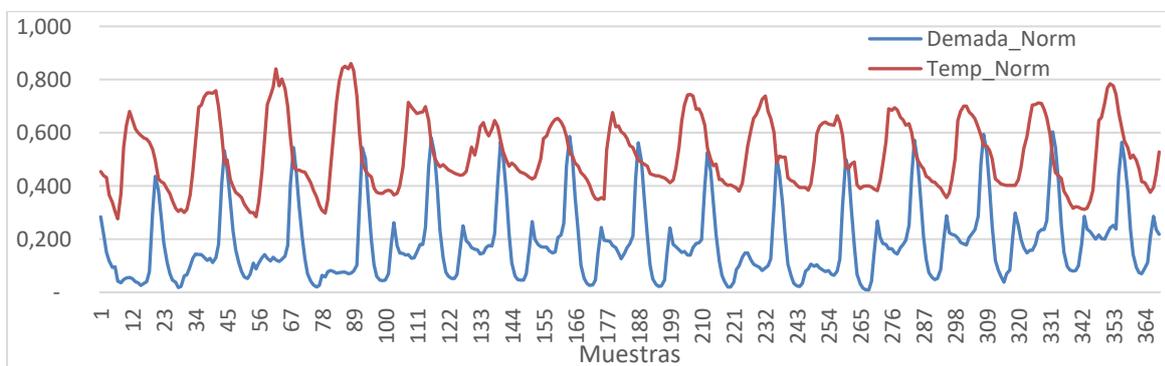


Figura 14-3: Series de tiempo normalizadas
Fuente: Realizado por: Iván Sinaluisa

3.3 Diseño del modelo de predicción

Esta sección se presenta el diseño de la arquitectura, entrenamiento, validación y pruebas aplicando métrica de calidad a la red Neuronal FeedForward backpropagation.

A continuación, se muestra la metodología utilizada para encontrar la arquitectura del modelo.

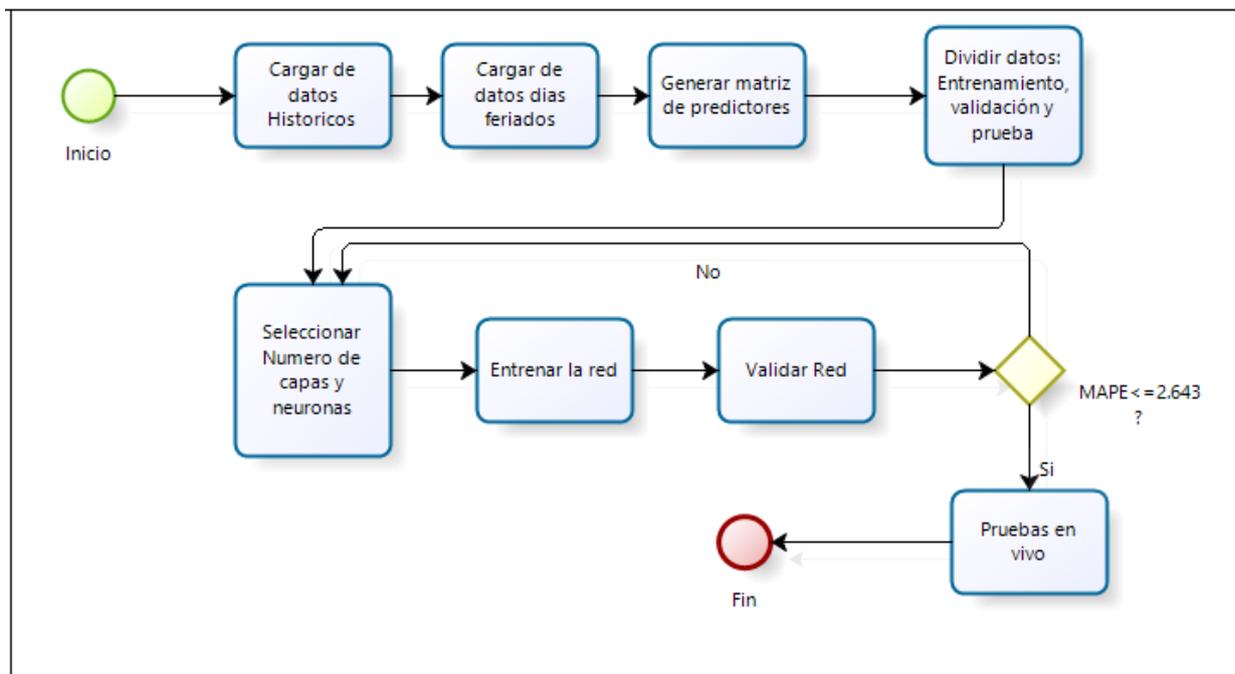


Figura 15-3: Metodología para el diseño de del Modelo mediante Redes Neuronales

Fuente: Realizado por Iván Sinaluisa

3.3.1 Arquitectura de la Red Neuronal

Para dimensionar el número idóneo de capas ocultas y numero de neuronas depende de la complejidad del problema a abordar y criterio del diseñador, sin embargo, para garantizar un buen rendimiento en el pronóstico y minimizar el error (MAPE), se utilizó método de generación dinámica de la topología (ver figura 16-3) con algunas configuraciones especialmente en la selección de la función de entrenamiento.

Existe varias propuestas para dimensionar el número de neuronas de la capa oculta tales como el definido por (Masters, 1993) que manifiesta que la cantidad mínima de neuronas en la capa oculta puede obtenerse de los valores conseguidos a partir de la ecuación correspondientes a la regla de la pirámide geométrica.

$$k = \text{Redondeo} (\sqrt{n * m}) \quad (9-3)$$

Donde:

k: es el número de neuronas de la capa oculta

n: es el número de la neurona de entrada

m es el número de neuronas de la capa de salida,

Sin embargo, existen otros método más sofisticados tales como propuestos por (Branch & Valencia, 2006) que propone complementar la técnica propuestas por Ash y Hirose que consiste en la búsqueda dinámica y forzada de los mejores mínimos locales, es decir si el valor está por debajo del valor esperado una nueva neurona es incorporada, pero si el error es cero o muy cercano a cero una neurona será retirada con el fin que no memorice.

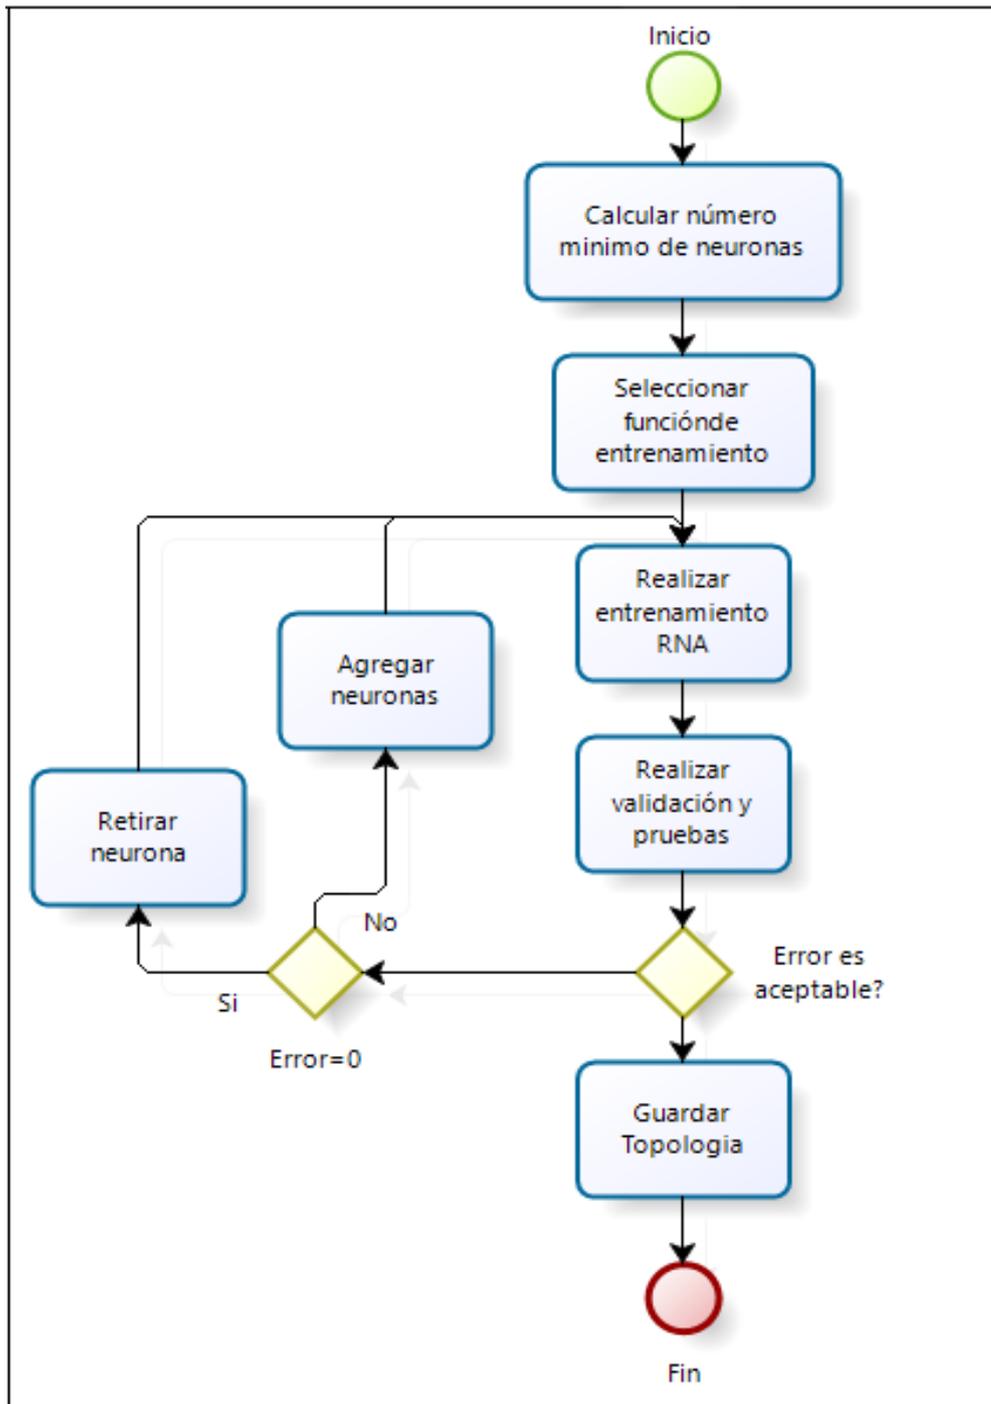


Figura 16-3: Proceso de generación dinámica de topologías RNA
 Realizado por: Iván Sinaluisa

Aplicando la ecuación 9-3 el mínimo de neurona que la capa oculta puede tener es de 3, y aplicando el método de generación dinámica de la topología la arquitectura de la red neuronal consta de los siguientes elementos, conforme se observa en la figura 17-3:

- 8 entradas que corresponde a las variables predictoras
- 1 capa oculta con 27 neurona
- 1 capa de salida que corresponde a la demanda de energía eléctrica pronosticada.

Por tanto, la arquitectura de la red neuronal FeedForward Backpropagation más óptima para este trabajo de investigación es la siguiente:

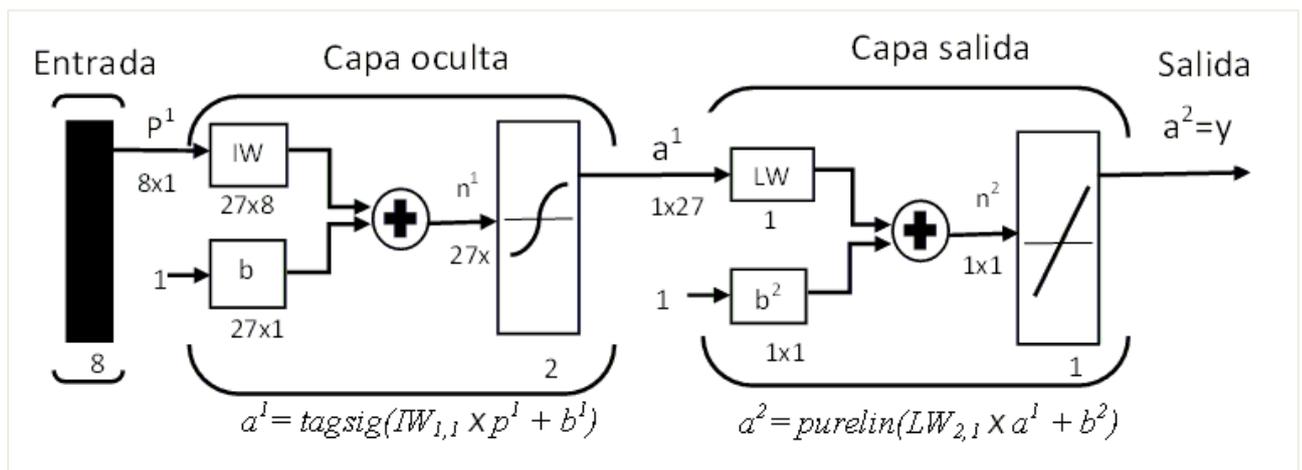


Figura 17-3: Arquitectura de la Red Neuronal FeedForward Backpropagación

Fuente: Realizado por: Iván Sinaluisa a partir de (Demuth, 2002).

Además, tiene las siguientes características:

- Función de activación capa oculta: Sigmoide (tagsig)
- Función de activación capa salida: lineal (purelin)
- Función de error: MAPE.
- Función de aprendizaje: Descenso de gradiente con impulsos (learngdm)

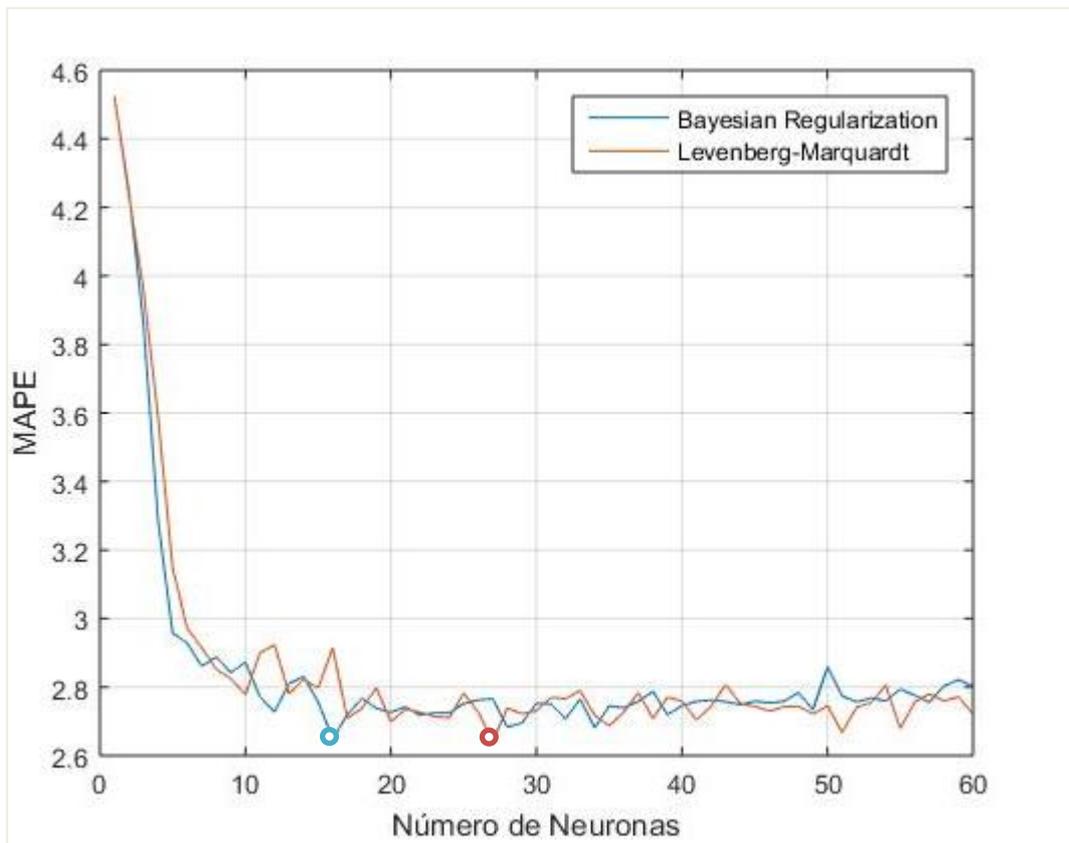


Figura 18-33: Comparación del error Regulación Bayesiana y Levenber-Marquardt
Fuente: Realizado por: Iván Sinaluisa

En la figura 18-3 se registra que el modelo de red FeedForward Backpropagation entrenada con función TRAINLM basados en el principio de optimización de Levenberg-Marquardt generó menor Error (MAPE) de 2,643 %, sin embargo, fue necesario utilizar 27 neuronas en la capa oculta para conseguir ese resultado.

Por otro lado, la red FeedForward Backpropagation entrenada con función TRAINBR según la optimización de regulación bayesiana (Bayesian Regularization), tiene un mínimo error MAPE de 2,650 % utilizando 16 neuronas en la capa oculta.

Se puede evidenciar que las dos funciones de entrenamiento tienen similar respuesta MAPE, sin embargo, la función de optimización Levenberg-Marquardt es más robusto y utiliza menor tiempo en su entrenamiento, pese a que utiliza más memoria.

3.3.2 *Aprendizaje de la Red Neuronal*

Para el proceso de aprendizaje y validación de la Red Neuronal diseñada, se consideró 60618 (83%) observaciones de 7 años correspondientes al periodo 2009 – 2015. Es necesario mencionar que solo los conjuntos de datos para entrenamiento fueron sometidos a preprocesamiento.

Adicionalmente se cargó una lista de días de vacaciones en la Provincia de Chimborazo y Ecuador que abarcan el rango de fechas histórico del 2009 al 2015 importadas desde una hoja de cálculo de Excel.

Se generó una matriz de variables predictoras que fueron utilizadas como entradas de la red neuronal.

- Fecha
- Temperatura
- Humedad
- Hora del día
- Día de la semana
- Un indicador que indica si es un día festivo / fin de semana
- Carga media del día anterior
- Carga de la misma hora del día anterior
- Carga de la misma hora y el mismo día de la semana anterior

El entrenamiento de la red neuronal se lo realizó utilizando la herramienta tecnológica Tool Box de Matlab, y a su vez se elaboró un script utilizando comandos para probar paralelamente el modelo con técnicas de optimización de Levenberg-Marquardt.

Para el entrenamiento de la red se utilizó la técnica de gradiente descendente propio del algoritmo de retro propagación, cuyo objetivo es minimizar la función de error encontrando los pesos y bias adecuados. Se adjunta la matriz de pesos vías.

En la gráfica No. 19-3 se puede evidenciar la evolución del aprendizaje de la Red neuronal donde se denota el mejor rendimiento en el entrenamiento, es decir converge en 153 interacciones de 159

realizadas, por lo tanto, el entrenamiento es el óptimo para este caso, toda vez que el error de validación se aproxima a cero y converge con el menor número de interacciones.

Además, el coeficiente de correlación es del entrenamiento es de 0,98473, por lo tanto, existe una buena correlación entre las observaciones reales y los valores pronosticados toda vez que se aproxima a 1.

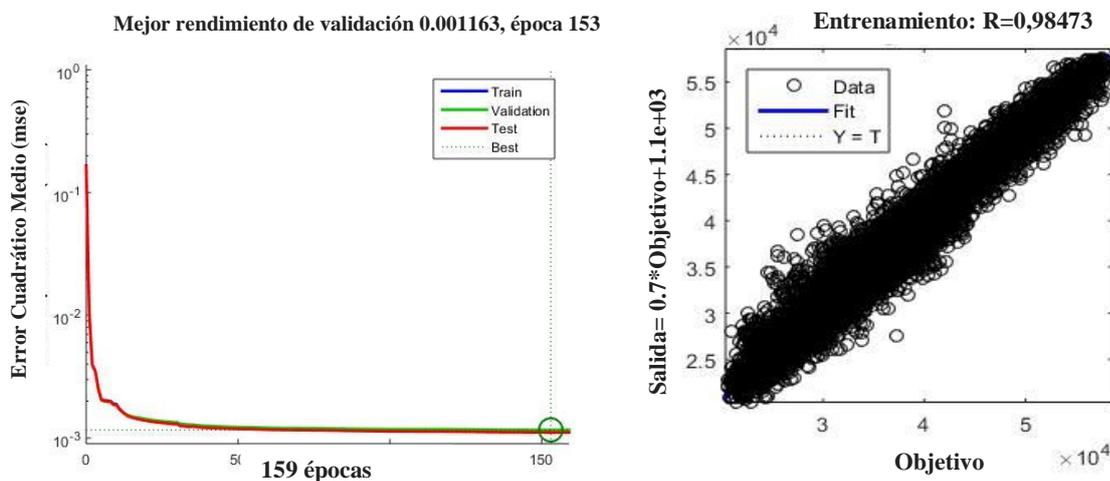


Figura 19-34: Rendimiento y correlación de entrenamiento de la Red Neuronal Artificial.
Fuente: Realizado por: Iván Sinaluisa

3.4 Validación y prueba del modelo

3.4.1 Exactitud del modelo de predicción

Por último, para determinar la exactitud del modelo en los períodos de muestras (año 2016) con los resultados de simulación de la red neuronales se procedió a comparar con los resultados de la metodología utilizada por la ERRSA (Regresión Lineal Múltiple), esto se lo realizó mediante los indicadores de desempeño denominado Porcentaje de Error Medio Absoluto (MAPE) y coeficiente de correlación de Pearson, calculados mediante las ecuaciones:

$$r = \frac{n \sum_{i=1}^n (y' y) - [\sum_{i=1}^n y'] [\sum_{i=1}^n y]}{\sqrt{[n \sum_{i=1}^n y^2 - [\sum_{i=1}^n y^2]] [n \sum_{i=1}^n y'^2 - [\sum_{i=1}^n y'^2]]}} \quad (10-3)$$

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y'_t - y_t}{y_t} \right| \quad (11-3)$$

Donde

n es el número de observaciones consideradas

y_t es la demanda real

y'_t es la demanda estimada por el modelo.

3.4.2 Modelo basado en red neuronal Feed Forward Backpropagation

El MAPE generado por el modelo basado en redes neuronales es del 2,63%, se puede observar que el modelo tiene buena capacidad de generalización, sin embargo, a inicio del mes de enero y finales de diciembre el error es muy pronunciado, lo que perjudica al promedio del año. Ver figura 20-3.

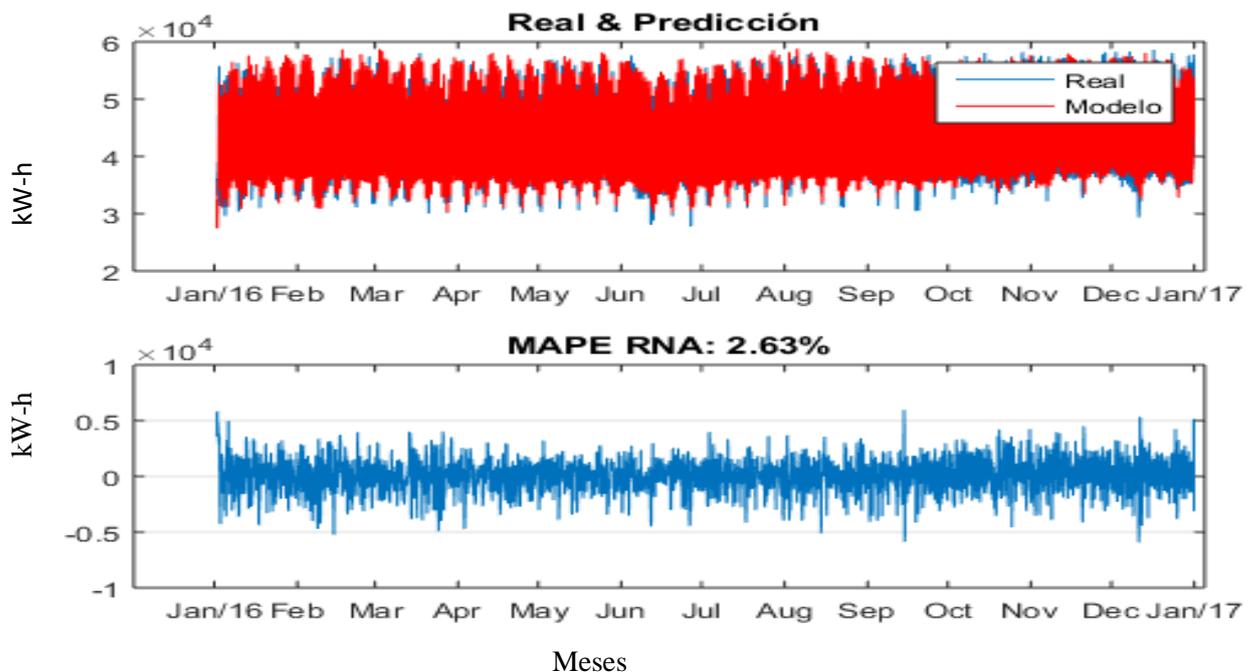


Figura 20-3: MAPE modelo basado en redes neuronales sobre el año 2016
Fuente: Realizado por: Iván Sinaluisa

En la figura 21-3 se puede apreciar el coeficiente de correlación de validación 0,98466 y de prueba 0,98466, cuyo promedio es cercano al 1.00 (uno), por lo tanto, se puede concluir que existe una buena correlación entre las observaciones reales y los valores de validación y de prueba.

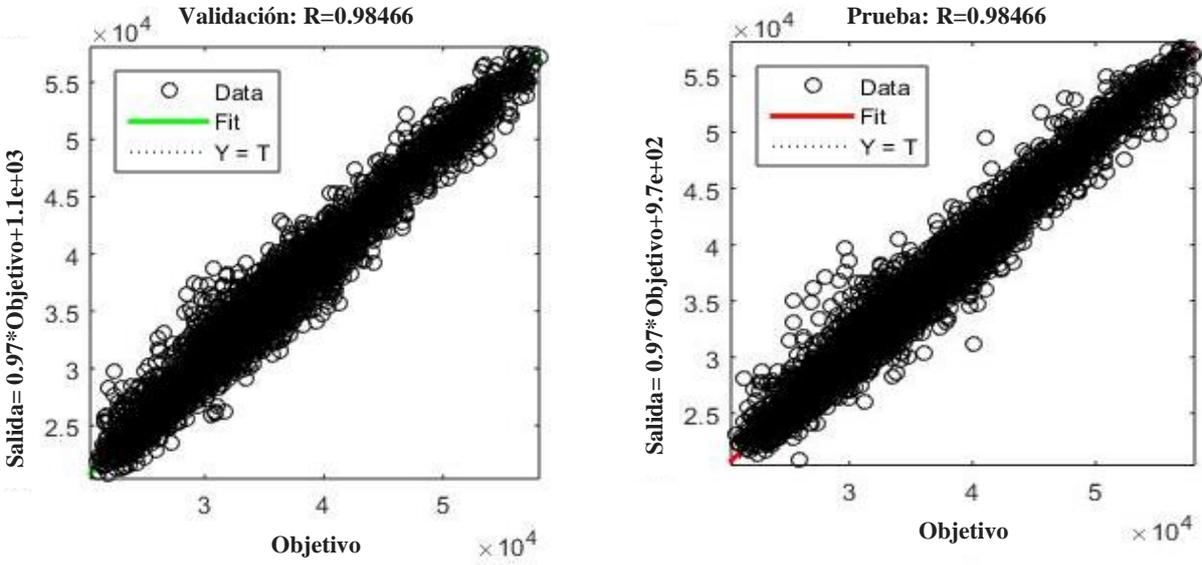


Figura 21-35: Coeficiente correlación Modelo Red Neuronal
 Fuente: Realizado por: Iván Sinaluisa

3.4.3 Modelo basado en Regresión Lineal Múltiple

Por otro lado, el error MAPE generado sobre los mismos datos de prueba (año 2016) el modelo basado en regresión lineal múltiple fue de 4,57%, conforme se puede observar en la figura 22-3.

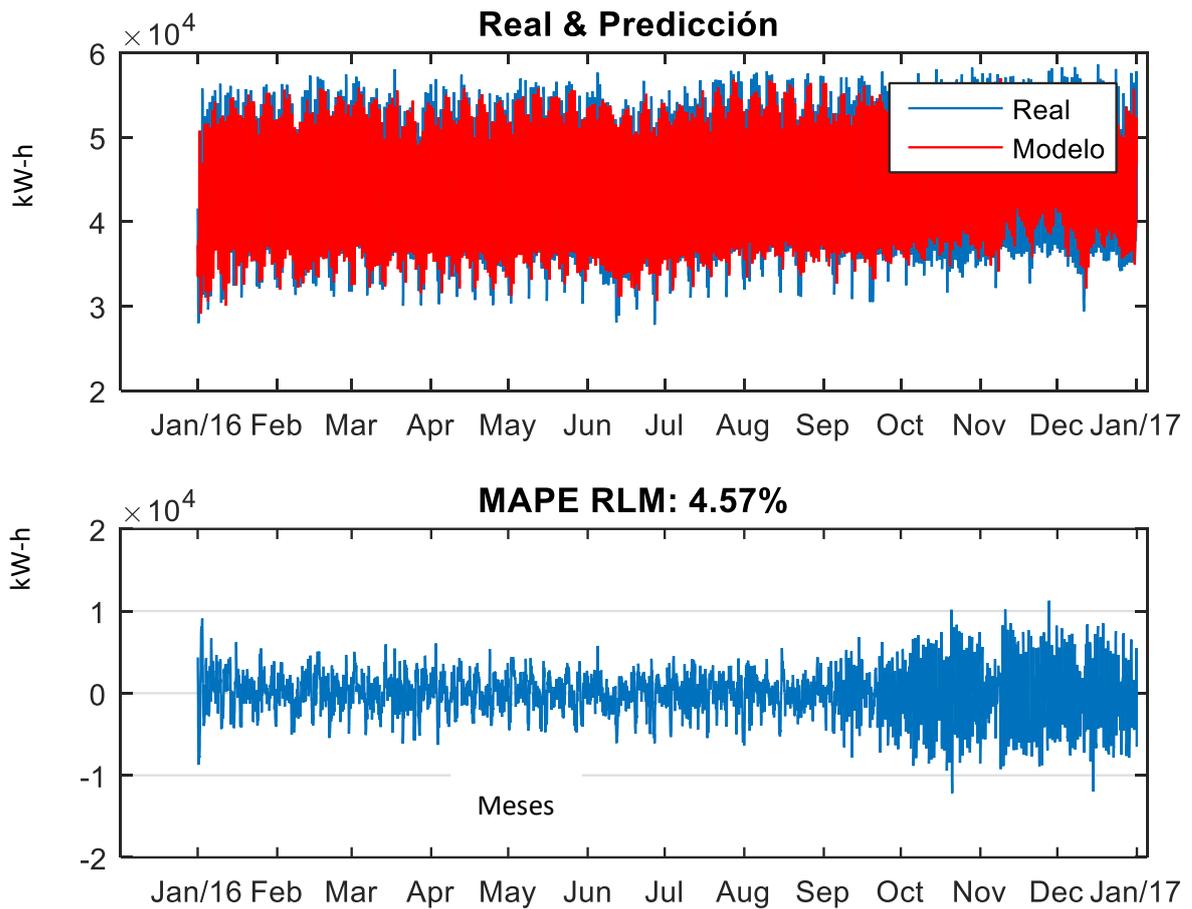


Figura 22-3: MAPE modelo basado en regresión lineal múltiple sobre el año 2016
Fuente: Realizado por: Iván Sinaluisa

Se puede observar en la figura 22-3 que los residuos correspondientes a los primeros nueve meses mantienen su generalidad, sin embargo, a partir del mes de octubre el error crece aproximadamente un 50%, por lo tanto, se puede evidenciar que esta técnica no proporciona un error MAPE aceptable en el tiempo.

Además, en la figura 23-3 se observa que el coeficiente de correlación del 0,9129, esto significa que hay poca coincidencia entre valores reales y pronosticados.

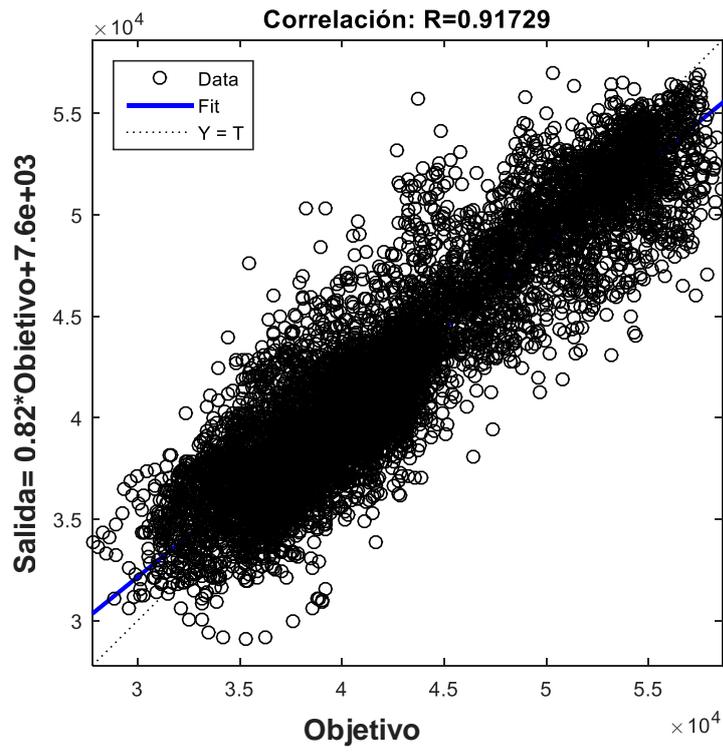


Figura 23-3: Coeficiente de correlación modelo Regresión lineal Múltiple
Fuente: Realizado por: Iván Sinaluisa

CAPÍTULO IV

4 RESULTADOS Y DISCUSIÓN

En este capítulo se analizará los resultados obtenidos en las pruebas aplicadas al Modelo de predicción de demanda eléctrica, a corto plazo con redes neuronales en los siguientes casos:

- Modelo de pronóstico con datos sin pre-procesar y pre-procesados.
- Modelos de predicción con Redes Neuronales vs. Regresión lineal múltiple.
- Factores que determinan la idoneidad de una técnica de pronóstico.

4.1. Modelo RNA con datos sin pre-procesar y pre-procesados.

En primera instancia se compara el modelo con datos de entrada pre-procesados, y con datos entrada sin pre-procesar es decir con valores atípicos, perdidos y suavizados, en la tabla 1-4 se muestra los resultados de tal comparación donde se demuestra que el preprocesamiento y clasificación de los datos mejora la calidad de los datos y por tanto diseñar el modelo de mejor rendimiento.

Tabla 1-4: Comparación modelo con datos pre-procesados y sin pro-procesar

DATOS	MAE (kw-h)	MAPE (%)	RENDIMIENTO (%)	R
Pre-procesados suavizados MM5	1085,81	2,63	97,37	0,98555
Pre-procesador y suavizados MM3	1308,05	3,17	96,83	0,98221
Pre-procesados sin suavizar	1394,30	3,34	96,66	0,98185
Sin Pre-procesar	2099,57	4,81	95,19	0,93737

Fuente: Realizado por: Iván Sinaluisa

Se observa que existe un mejor rendimiento del modelo trabajado con datos pre-procesados, en este caso mejora el rendimiento en aproximadamente el 2%, además el coeficiente de correlación (R) es más próximo a 1, por lo tanto, es de vital importancia diseñar un modelo de predicción con datos pre-

procesados y de buena calidad, aunque esto signifique utilizar el 60% del tiempo de trabajo en este objetivo.

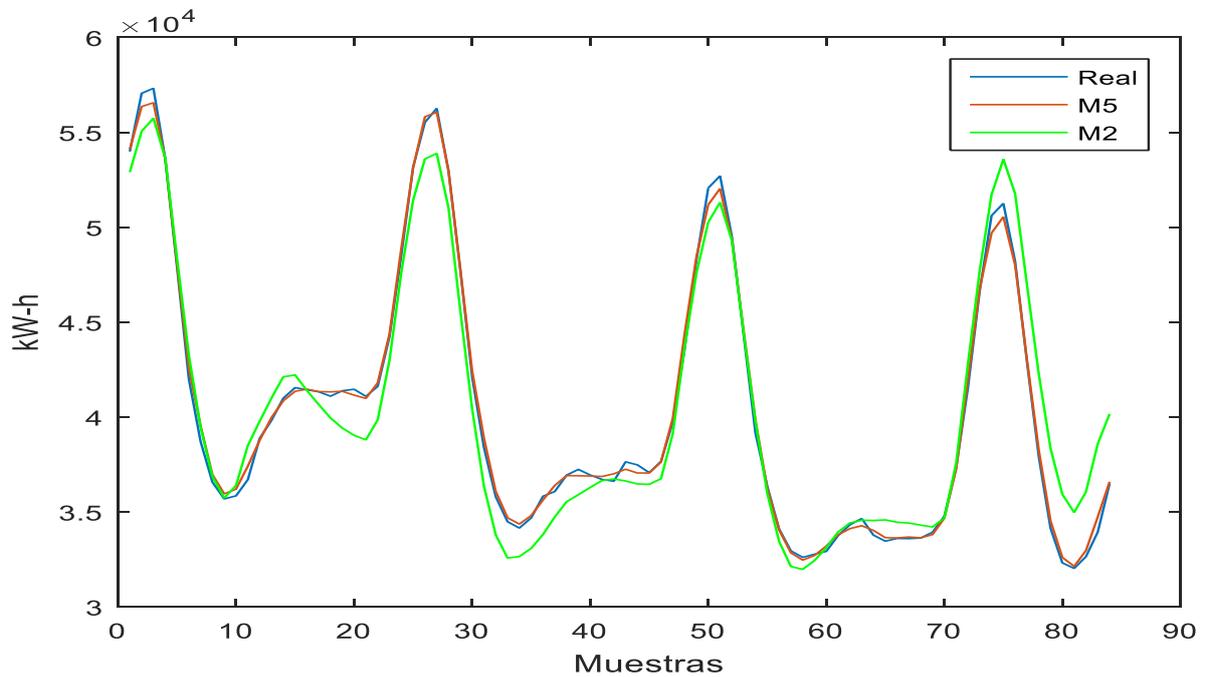


Figura 1-4: Modelo con datos suavizados y no suavizados
Fuente: Realizado por: Iván Sinaluisa

En la figura 1-4 se observa que efectivamente existe una notable diferencia entre trabajar con datos sin pre-procesamiento (M2) y con datos pre-procesados (M5), por lo tanto, de vital importancia realizar el tratamiento de los datos.

4.2. Modelo de predicción Redes Neuronales vs. Regresión lineal múltiple.

Por otro lado, en la tabla 2-4 muestra la comparación entre el modelo de predicción de la demanda de energía eléctrica basado en la Red Neuronal FeedForward BackPropagation diseñado, con respecto a al método de Regresión Lineal Múltiple utilizado por la empresa Eléctrica de Riobamba para su planificación.

Tabla 2-4: Comparación modelos con Redes Neuronales vs Regresión lineal múltiple

METRICAS	MAPE (%)		Max ϵ (%)		Min ϵ (%)		Rendimiento (%)		Correlación de Pearson	
	RNA	RLM	RNA	RLM	RNA	RLM	RNA	RLM	RNA	RLM
MES										
Enero	3,27	5,06	17,47	30,77	0,01	0,00	96,73	94,94	0,97	0,91
Febrero	2,85	3,84	14,32	15,73	0,00	0,02	97,15	96,16	0,97	0,91
Marzo	2,89	4,18	10,83	18,97	0,00	0,01	97,11	95,82	0,97	0,94
Abril	2,34	3,36	14,38	18,68	0,00	0,01	97,66	96,34	0,98	0,95
Mayo	2,42	3,72	11,34	14,23	0,00	0,01	97,58	96,28	0,98	0,95
Junio	2,40	3,66	15,81	21,93	0,00	0,00	97,60	96,34	0,98	0,96
Julio	2,43	3,66	12,83	16,88	0,00	0,01	97,57	96,34	0,98	0,95
Agosto	2,59	3,70	14,55	17,93	0,00	0,00	97,41	96,30	0,98	0,95
Septiembre	2,38	3,72	13,58	20,64	0,00	0,00	97,62	96,28	0,98	0,94
Octubre	2,59	6,68	11,46	34,36	0,01	0,01	97,41	93,32	0,98	0,82
Noviembre	2,50	6,62	12,60	23,39	0,00	0,00	97,50	93,38	0,98	0,80
Diciembre	2,88	6,51	20,22	28,47	0,00	0,02	97,12	93,49	0,97	0,84
PROMEDIO	2,63	4,56	14,12	21,83	0,00	0,01	97,37	95,42	0,98	0,91

Fuente: Realizado por: Iván Sinaluisa

Conforme se muestra en la tabla 2-4 el modelo con mejor rendimiento es el basados en Redes Neuronales FeedForward Backpropagation, donde se observar que el mes con menor error de pronóstico es el mes de abril y con mayor error es enero, tal como se muestra en la figura 2-4 correspondiente a la tercera semana de abril del 2016.

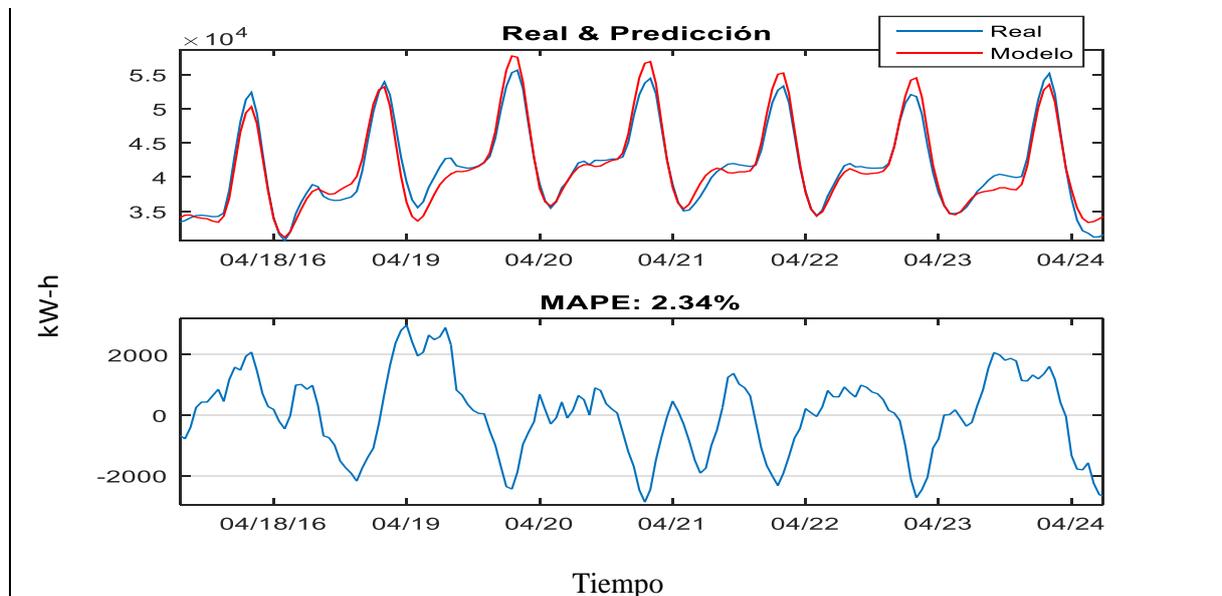


Figura 2-4: Comparación entre el valor real y el pronosticado - mes de abril 2016

Fuente: Realizado por: Iván Sinaluisa

Claramente se puede observar en la figura 3-4, que el modelo basado en Redes Neuronales FeedForward Backpropagación (RNA) tiene mejor rendimiento que el modelo basado en Regresión lineal múltiple (RLM), entrenados, validados y testeados con los mismos datos históricos.

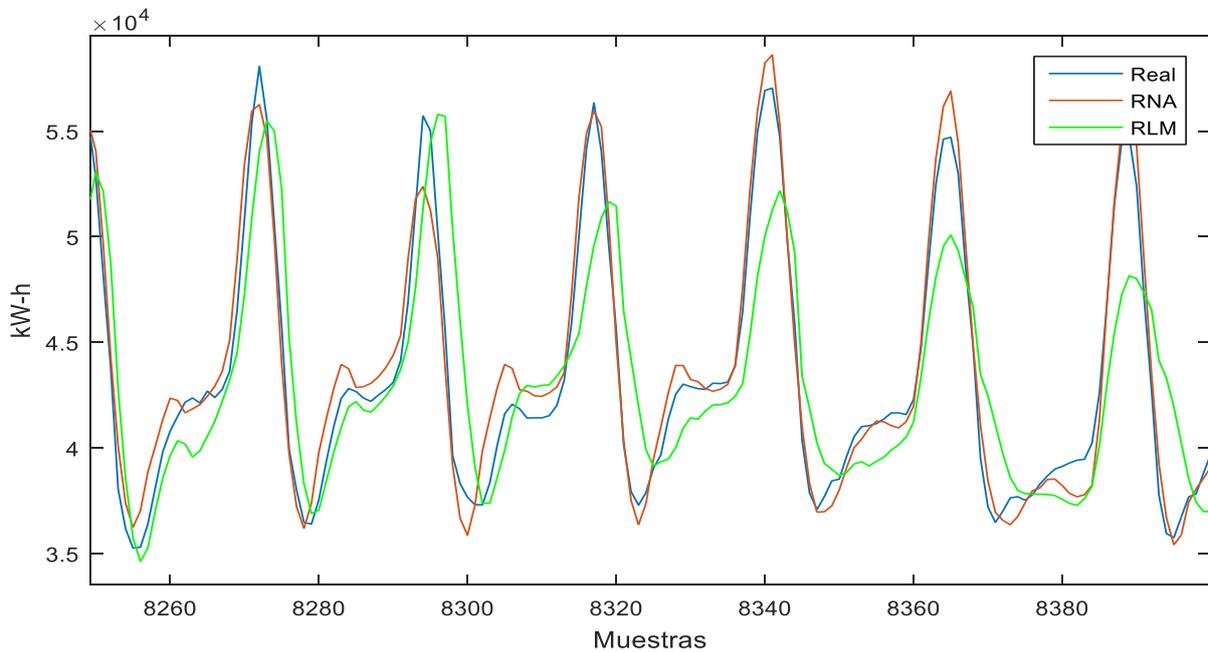


Figura 3-4: Comparación entre resultado del Modelo RNA y RLM
Fuente: Realizado por Iván Sinaluisa

Sin embargo, se evidencia en la figura 4-4 que existe valores MAPE atípicos elevados en los meses de enero y diciembre que afectan promedio del rendimiento del Pronóstico, esto se da debido al consumo temporal e inestable que tiene la provincia por motivo de las fiestas de navidad y año nuevo.

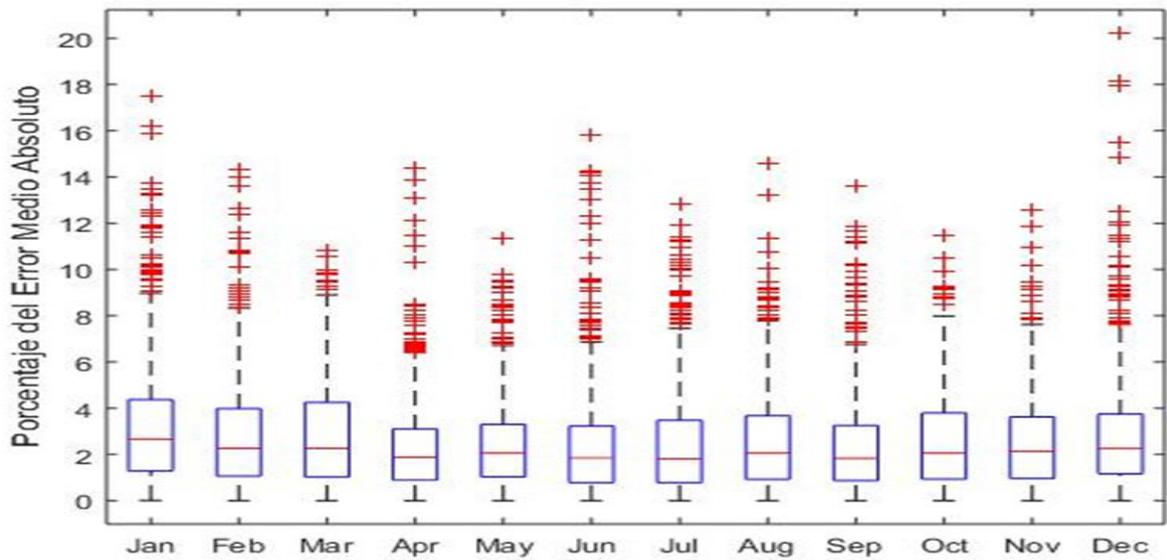


Figura 4-1: Despliegue estadístico de error de pronóstico por Mes.

Fuente: Realizado por: Iván Sinaluisa

En los demás meses el error MAPE es moderado. También se observa en la figura 5-4 los valores MAPE atípicos corresponden a los días sábados y domingos esto se da principalmente al consumo inestable que se tiene en la provincia estos días.

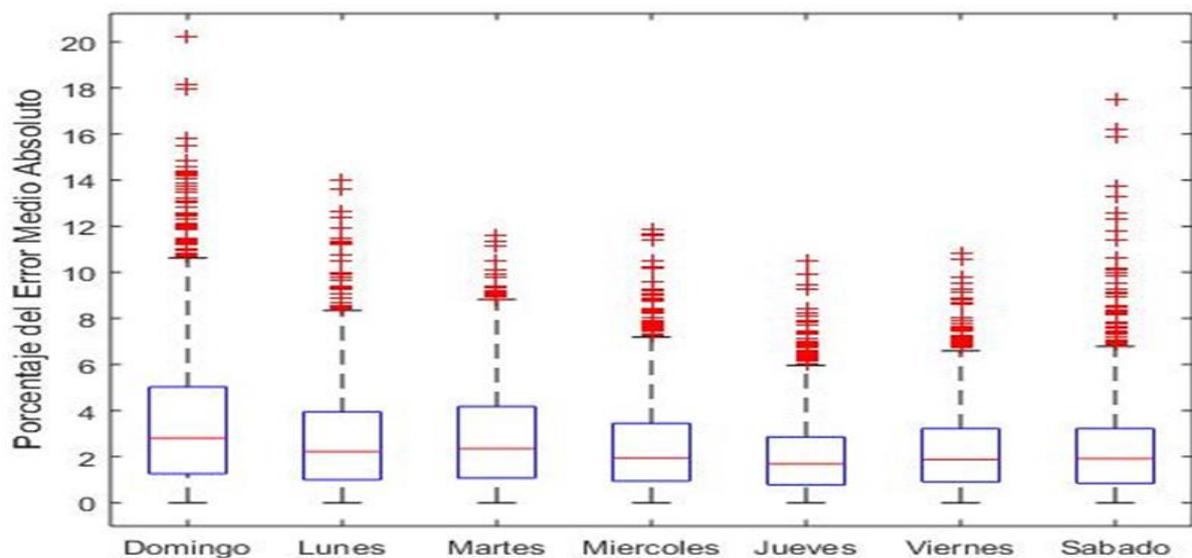


Figura 5-4: Despliegue estadístico de error de pronóstico por día.

Fuente: Realizado por: Iván Sinaluisa

4.3. Determinación de la idoneidad del Modelo de pronóstico

Para determinar la idoneidad de una técnica de pronóstico se tomaron en cuenta los siguientes factores (Hanke & Wichem, 2006).

4.3.1 Coeficientes de autocorrelación residuales

Los coeficientes de autocorrelación residuales (errores) debe indicar la relación que tiene la serie consigo misma y que existe una serie aleatoria para diferentes periodos, es decir que existe correlación entre una variable retrasada uno o más periodos consigo misma.

En figura 6-4 se observa la autocorrelación residual con una confianza de un 95%, cuyos puntos que se encuentran fuera de los límites de la franja roja poseen autocorrelación, por lo tanto, se puede demostrar que existe una buena autocorrelación residual y por lo tanto el modelo cumple con esta característica.

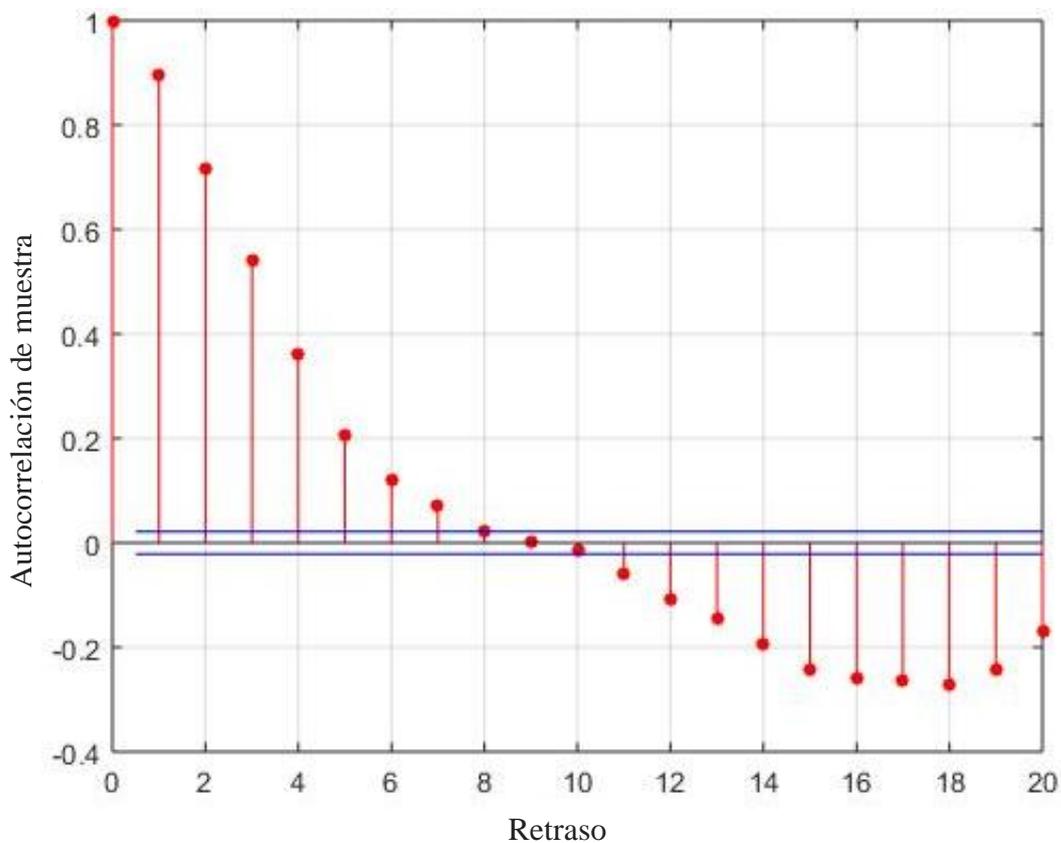


Figura 6-4: Autocorrelación residual del Modelo RNA
Fuente: Realizado por: Iván Sinaluisa

4.3.2 Distribución residual

El pronosticador es idóneo si la distribución del error se distribuye normalmente, para lo cual se analizó el grafico de probabilidad normal.

En la figura 7-4 se muestra la distribución normal del residuo del Modelo basado en Redes Neuronales, donde efectivamente se evidencia que existe una buena distribución normal de los residuos formando una campana de GAUSS casi perfecta.

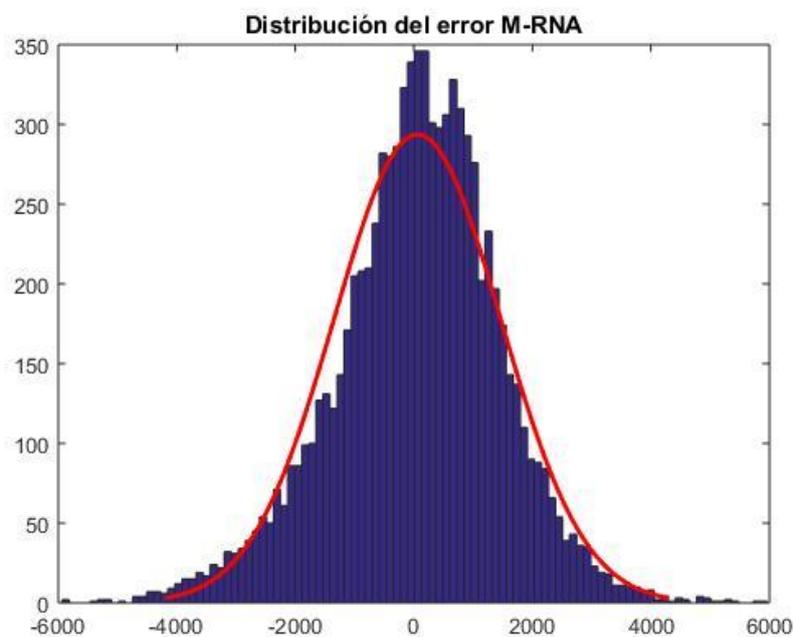


Figura 7-4: Distribución residual del Modelo RNA

Fuente: Realizado por: Iván Sinaluisa

Por lo tanto, el Modelo basado en la Red Neuronal FeedForward Bacpropagation cumple con esta característica entonces se puede decir que es idóneo para el pronóstico de la demanda eléctrica.

Se Adjuntó en anexos varios gráficos de simulación realizado tomando como muestra datos del año 2016.

4.4 Docimasia Hipótesis

4.4.1 Planteamiento

La Hipótesis planteada en la presente investigación fue:

“El modelo de predicción de la demanda de energía eléctrica basado en la red neuronal FeedForward backprogratation minimiza el error de predicción respecto a la metodología empleada por la empresa Eléctrica de Riobamba S.A.”

De la cual se definió la hipótesis alternativa y la nula:

H₁: El error generado por el modelo de predicción de la demanda de energía eléctrica basado en la red neuronal *FeedForward backprogratation* (μ_1) es menor al generado con la metodología empleada por la empresa Eléctrica de Riobamba para su planificación (μ_2).

$$H_i: \mu_1 < \mu_2$$

H₀: El error generado por el modelo de predicción de la demanda de energía eléctrica basado en la red neuronal *FeedForward backprogratation* (μ_1) es igual o mayor al generado con la metodología empleada por la empresa Eléctrica de Riobamba para su planificación (μ_2).

$$H_0: \mu_1 \geq \mu_2$$

4.4.2 Nivel de Significancia

El nivel de significancia tomada para esta investigación es de 5% (o un nivel de confianza del 95%), es decir 0,05 en decimales.

4.4.3 Descripción de Población y la Muestra

Para el contraste de la hipótesis se trabajó con datos correspondientes a los errores de predicción de los doce meses del año 2016 de la tabla 2-4. Por ser la población pequeña, se ha considerado trabajar con toda la población.

4.4.4 Elección de la prueba Estadística

Para demostrar la hipótesis se aplicará la prueba estadística T-student a las muestras independientes. Se utiliza esta prueba estadística ya que se desea evaluar si el grupo difieren entre sí de manera significativa respecto a sus medias.

4.4.5 Prueba T-student con SPSS

Para la prueba T-student se utilizó datos de la tabla 3-4 correspondiente a los resultados del modelo basado en redes neuronales artificial y regresión lineal múltiple.

Tabla 3-4. Estadísticos de muestras relacionadas

Estadísticas de grupo					
	Método	N	Media	Desviación estándar	Media de error estándar
MAPE	RNA	12	2,6283	0,28473	0,08219
	RLM	12	4,5592	1,30259	0,37602

Fuente: Elaborado por Iván Sinaluisa

Tabla 4-4. Prueba T- student

	prueba t para la igualdad de medias						
	t-studens	Grados libertad (gl)	Significancia (sig)	Diferencia de medias	Diferencia de error estándar	95% de intervalo de confianza	
						Inferior	Superior
MAPE Se asumen varianzas iguales	-5,016	22	0,00051	-1,93083	0,38490	-2,72907	-1,13259
No se asumen varianzas iguales	-5,016	12,049	0,000297	-1,93083	0,38490	-2,76909	-1,09258

Fuente: Elaborado por Iván Sinaluisa

Condición:

Sig < 0.05, rechazo H₀, con un 95% de confianza

Sig > 0.05, acepto H₀, con un 95% de confianza

4.4.6 *Conclusión de hipótesis*

- Los resultados de la prueba t-student para muestras independientes rechaza la hipótesis nula H_0 , por tanto, se acepta la hipótesis alternativa o de investigación, es decir el modelo de predicción de la demanda de energía eléctrica basado en la red neuronal FeedForward backproagation minimiza el error de predicción respecto a la metodología empleada por la empresa Eléctrica de Riobamba S.A.

CONCLUSIONES

- El porcentaje del error medio absoluto del modelo de predicción de la demanda de energía eléctrica basado en la red neuronal FeedForward Backpropagation fue del 2,63%, frente al 4,56% al generado por la metodología utilizada por la empresa Eléctrica de Riobamba S.A.
- Se acepta la hipótesis alternativa o de investigación, es decir el modelo de predicción de la demanda de energía eléctrica basado en la red neuronal FeedForward backpropagation minimiza el error de predicción respecto a la metodología empleada por la empresa Eléctrica de Riobamba S.A.
- La revisión de modelos para la predicción de demanda de energía eléctrica que se utiliza en el país, permitió determinar las falencias que existen en los sistemas de predicción de demanda tradicionales, por lo que se seleccionó un modelo de predicción de energía eléctrica basado en redes neuronales más precisos.
- El desarrollo del pre-procesamiento es muy importancia para obtener resultados óptimos del modelo de predicción elegido, sin embargo, esto puede significar un 60% del tiempo del trabajo de investigación.
- Las funciones de entrenamiento (Levenberg-Marquardt- Regulación Bayesiana) tienen similar respuesta, sin embargo, Levenberg-Marquardt utiliza menor tiempo en su entrenamiento, pese a que utiliza más memoria, Bayesian Regulation Backpropagation puede lograr una buena exactitud de la predicción, pero tiene una carga de procesamiento relativamente pesada.
- La selección correcta de las variables predictoras que influyen en el comportamiento de la demanda de energía eléctrica juega un papel muy importante en los resultados de predicción de la red neuronal.
- El software Matlab utilizado para el entrenamiento de la red neuronal presenta restricciones en el manejo del número de capas ocultas, sin embargo, para este caso de estudio fue suficiente trabajar con una capa oculta generada por el software.
- La red FeedForward con el algoritmo Backpropagation ejecuta eficientemente en aplicaciones académicas, sin embargo, para aplicaciones de mayor escala existe restricciones de hardware y software para el entrenamiento de la red.

RECOMENDACIONES

- Si el objetivo es el pronóstico de la carga es a mediano o largo plazo, es necesario utilizar deterministamente las horas de entrada del día, el día de la semana, la época del año y las vacaciones. La información meteorológica y de carga debería especificarse como un promedio o una distribución.
- Realizar el pre-procesamiento de los datos para corregir datos atípicos, perdidos y suavizado de la serie con el fin de obtener resultados satisfactorios.
- Complementar el presente estudio a nivel nacional a mediano y largo plazo, toda vez que las aplicaciones de modelos basados en redes neuronales han demostrado eficiencia en el pronóstico de demanda eléctrica.

BIBLIOGRAFÍA

•
ANDINA, D. et al. (2007). *Neural Networks Historical Review In Computational Intelligence for Engineering and Manufacturing* (pág. 57). New York: Springer.

ARIZA, A. (2013). *Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución*. Pereira, Colombia: Universidad Tecnológica de Pereira.

BRANCH, J., VALENCIA, J. (2006). *Generación dinámica de la topología de una red neuronal artificial del tipo perceptrón multicapa*. Branch, Jhohn, 38(resumen), 146–162.

BRUNER, J. (2001). *El proceso mental en el aprendizaje*. Madrid: Narcea, S. A.

BUNGE, M. (2000). *La investigación científica*. México: Siglo XXI editores.

CERDAS, E. et al (2006). *Crisis de Ecuador en los años 1999 -2000*. Recuperado el 12 de mayo del 2017, de <http://www.memoriacrisisbancaria.com>

CISCO, H. (2010). *Aprendizaje supervisado en redes neuronales*, México: Limusa.

CORTINA, M. (2012). *Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos*. Madrid: McGraw-Hill.

DELMAR, I.,et al. (2003). *Predicción de la demanda eléctrica de corto plazo mediante Redes Neuronales Artificiales*. Departamento de Economía Cuantitativa, Universidad de Oviedo, España.

ECUADOR, Ministerio de Electricidad y Energía Renovable, (1996). Ley de régimen del sector eléctrico. Quito: CELEC.

ECUADOR, Ministerio de Electricidad y Energía Renovable, (2014). *Plan maestro de electrificación 2013 - 2022*, Quito: ARCONEL.

ECUADOR, Ministerio de Electricidad y Energía Renovable, (2015). *Estadística anual y multianual del Sector Eléctrico Ecuatoriano*. Quito: ARCONEL.

EMPRESA ELÉCTRICA RIOBAMBA. (2015). *Rendición de Cuentas 2015*. Recuperado 15 de julio del 2017, de <http://www.eersa.com.ec>

MORENO, A. et al. (1994). *Aprendizaje automático*. Barcelona, España: Ediciones UPC.

HANKE, J. et al. (2006). *Pronóstico en los negocios*. México: Pearson Educación.

HAYKIN, S. (2008). *Neural Networks and Learning Machines*. Pearson Prentice Hall New Jersey USA 936 pLinks (Vol. 3). Recuperado el 02 de Agosto de 2017, de <https://doi.org/978-0131471399>

HILERA, J. et al. (1995). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Madrid: Iberoamericana.

MASTERS, T. (1993). *Practical Neural Networks recipes in C++*. California: Morgan Kaufmann Publishers.

MATICH, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Historia, 55. Recuperado el 30 de mayo del 2017, de <ftp://decsai.ugr.es>

MORENO, A. et al. (1994). *Aprendizaje automático*. Barcelona, España: Ediciones UPC.

OMEGA. H. (1979). *Diccionario Científico y Tecnológico Chambers*. Barcelona: Ediciones Omega.

ORTIZ, D. (2014). *Aplicación de redes neuronales artificiales en el pronóstico de la demanda de energía eléctrica a corto plazo en el SIN*, Universidad Politécnica Salesiana Sede Quito.

PERÉZ, J. (2013). *Perceptrón Multicapa*, 1–49. Recuperado el 16 de junio del 2017, de <http://bibing.us.es>.

PONCE, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería*, México: Alfaomega

PLAZA, E. (1992). *Tendencias en Inteligencia Artificial* (pág. 379). Universidad de Deusto.

QUINTELA, F. et al. (2005). *Redes Eléctricas*. Universidad de Salamanca, España: Limusa.

SAMPIERI, H. (2010). *Metodología de la Investigación*. México: McGraw-Hill.

TRUJILLANO, J. et al. (2004). *Aproximación metodológica al uso de redes neuronales artificiales para la predicción de resultados en medicina*. *Medicina Clínica*. Recuperado el 30 de agosto de 2017, de <https://doi.org/10.1157/13057536>

TWIDELL, J., & Weir, T. (2006). *Renewable Energy Resources*. Canadá: Taylor&Francis.

UNIVERSIDAD TECNOLÓGICA DE PEREIRA. (2013). *Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución*. Pereira: Universidad Tecnológica de Pereira.

ANEXOS

ANEXO A. Carta de certificación de la autorización para el desarrollo del proyecto de investigación



 *Empresa Eléctrica Riobamba S.A.* 

Riobamba, Enero 09 de 2017

CERTIFICADO

A quien corresponda,

Yo Ing. RENZO CÓRDOVA, en calidad de Director de Planificación de la Empresa Eléctrica Riobamba certifico y autorizo la total apertura para el desarrollo del proyecto de titulación de maestría cuyo tema tentativo es: "EVALUACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL PARA EL PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA EN LA EMPRESA ELÉCTRICA RIOBAMBA, 2017", propuesto por el Sr. Ing. IVAN FERNANDO SINALUISA LOZANO con cedula de identidad No. D603111907, siendo este de vital importancia para la planificación institucional del suministro de energía eléctrica a nuestros clientes, vinculando el sector académico con el industrial para tal propósito.

Atentamente

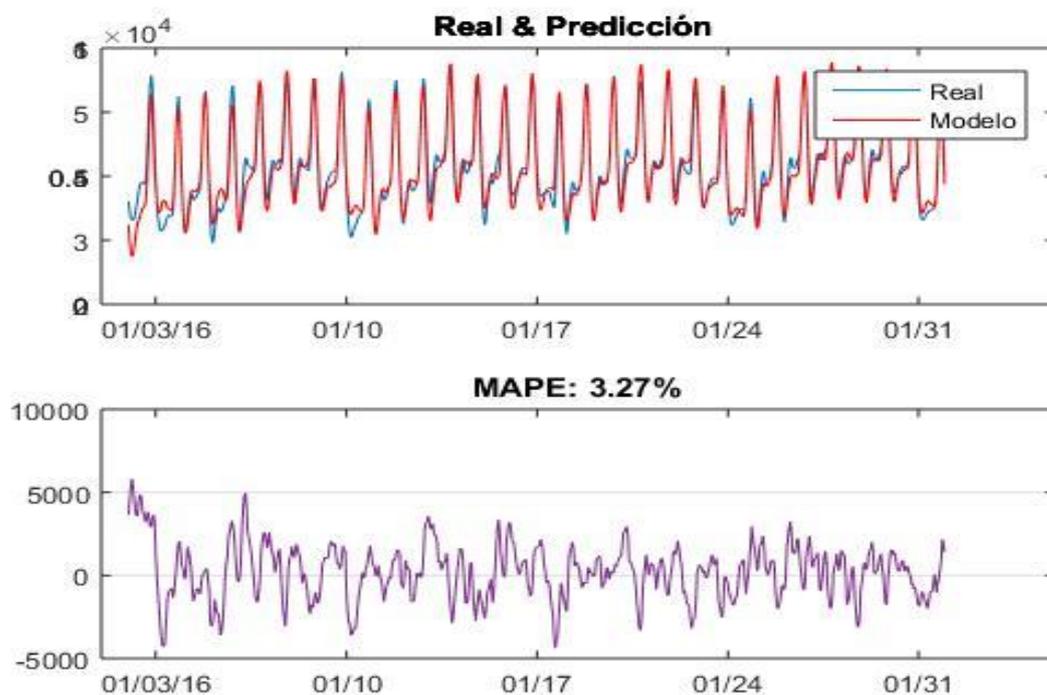

Ing. Renzo Córdova
DIRECTOR DE PLANIFICACION (e)
EMPRESA ELÉCTRICA RIOBAMBA S.A.

Trabajamos para *iluminar* tu vida

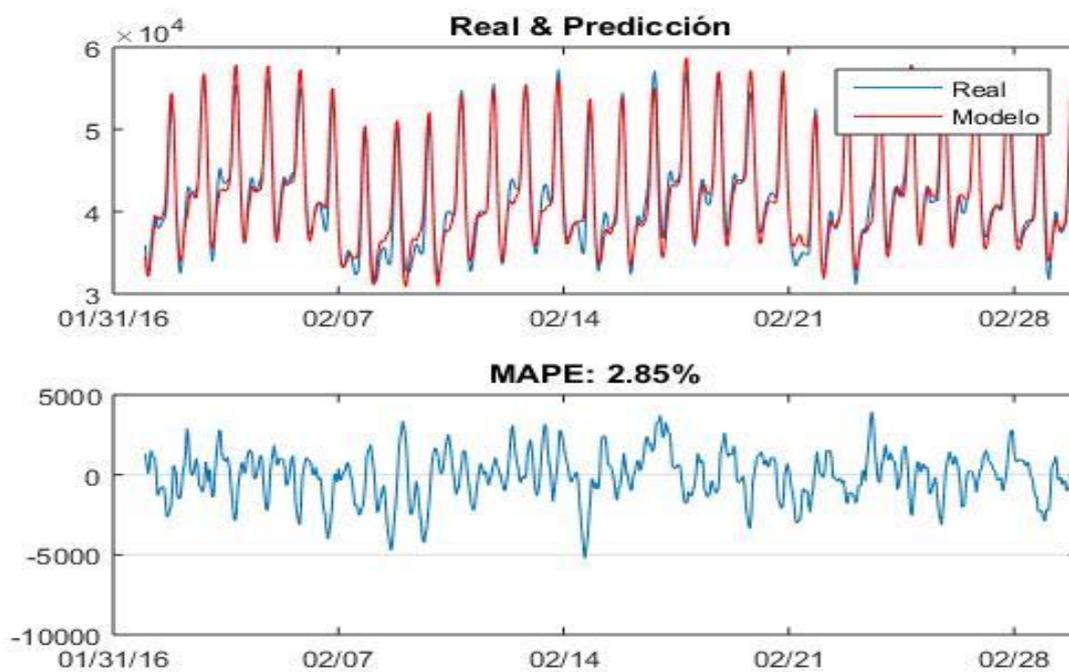
Juan Larrea 2266 y Primera Constituyente.
Casilla 670. Telfs.: 2 962 939 / 2 960 283 / 2 961 966 / 2 964 622 / Fax: 2 968 216
WEB Site: www.eersa.com.ec / e-mail: e-mail@eersa.com.ec

ANEXO B. Resultado de las pruebas del modelo de predicción mediante Redes Neuronales Artificiales AÑO 2016

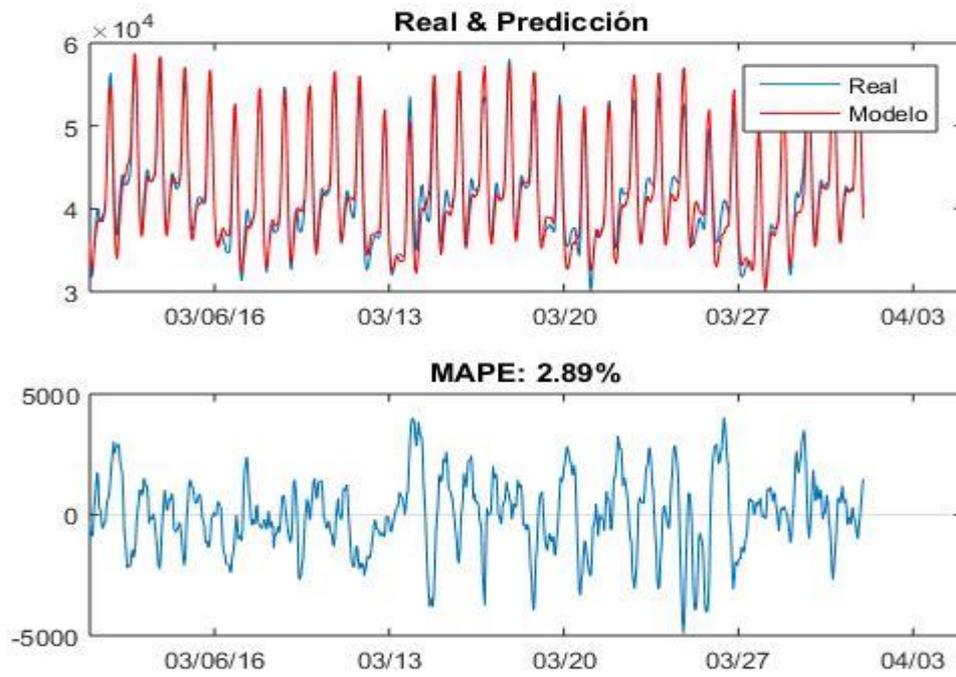
Enero 2016:



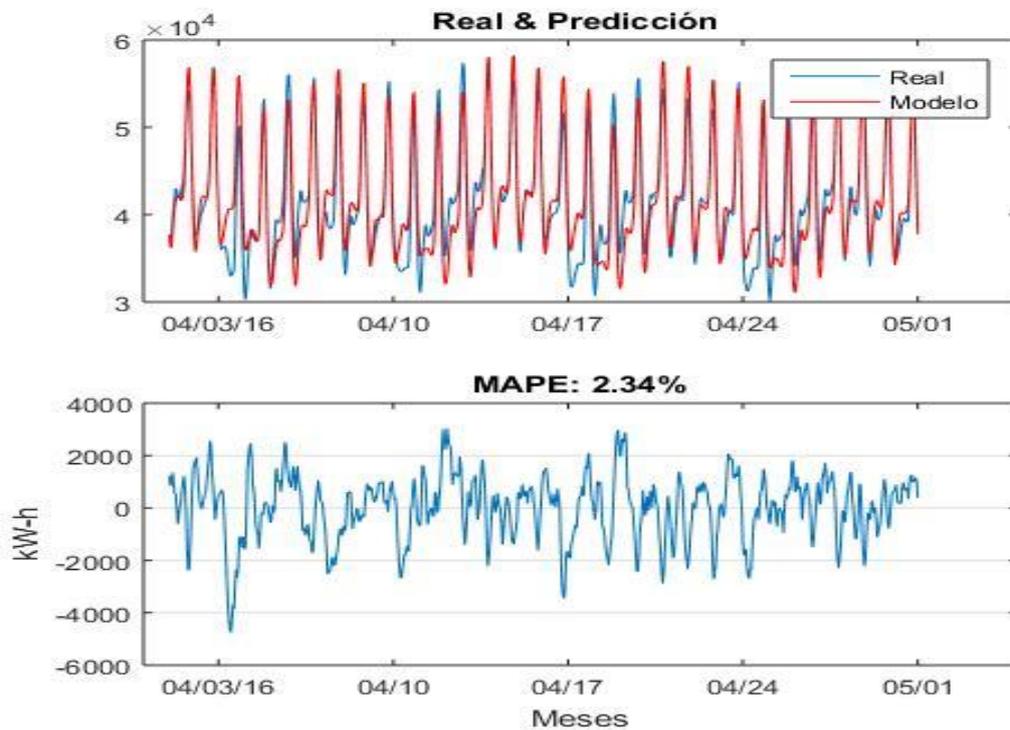
Febrero 2016:



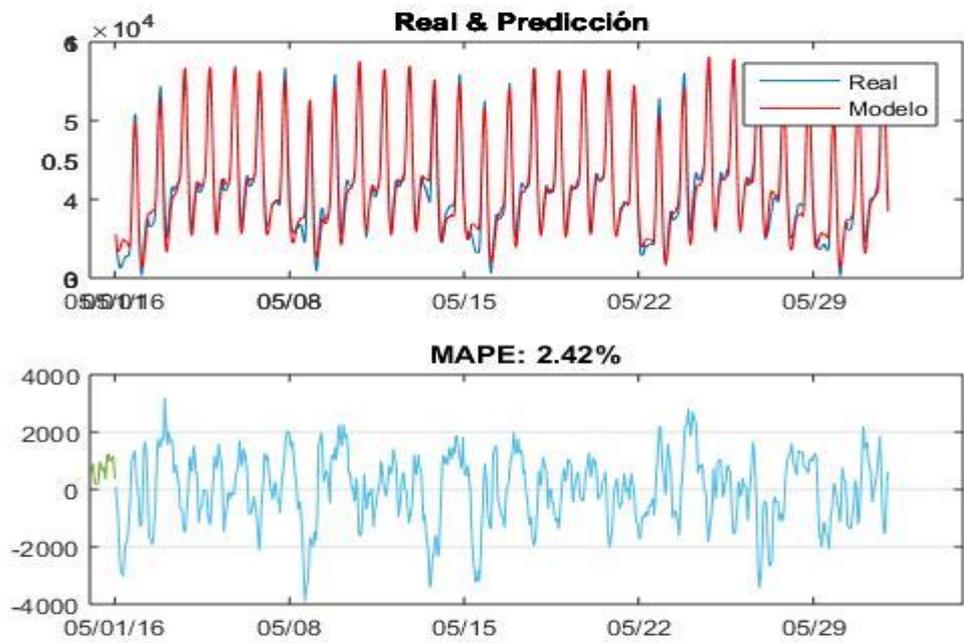
Marzo 2016:



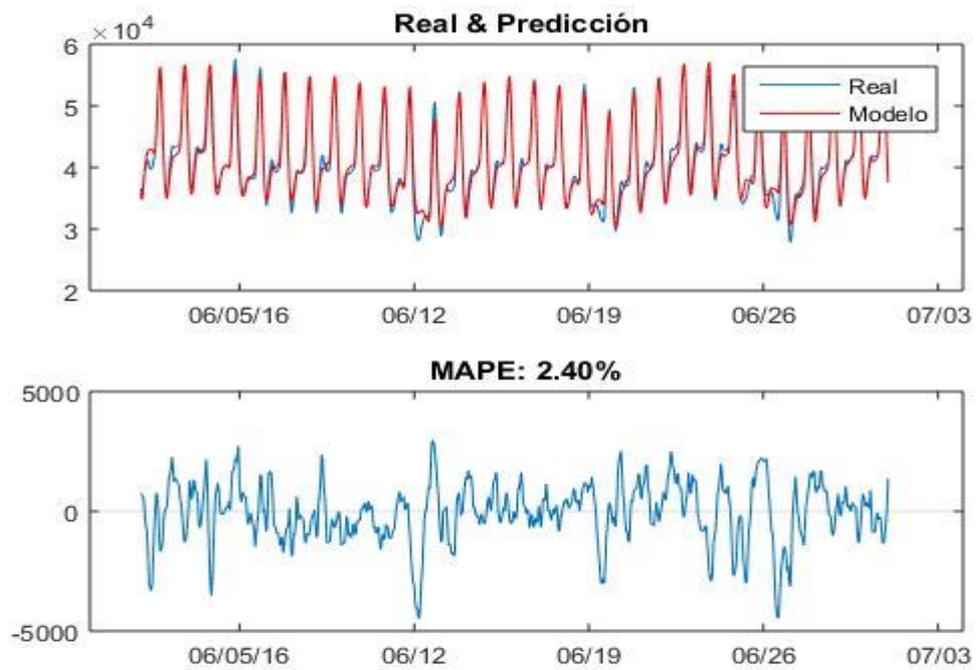
Abril 2016:



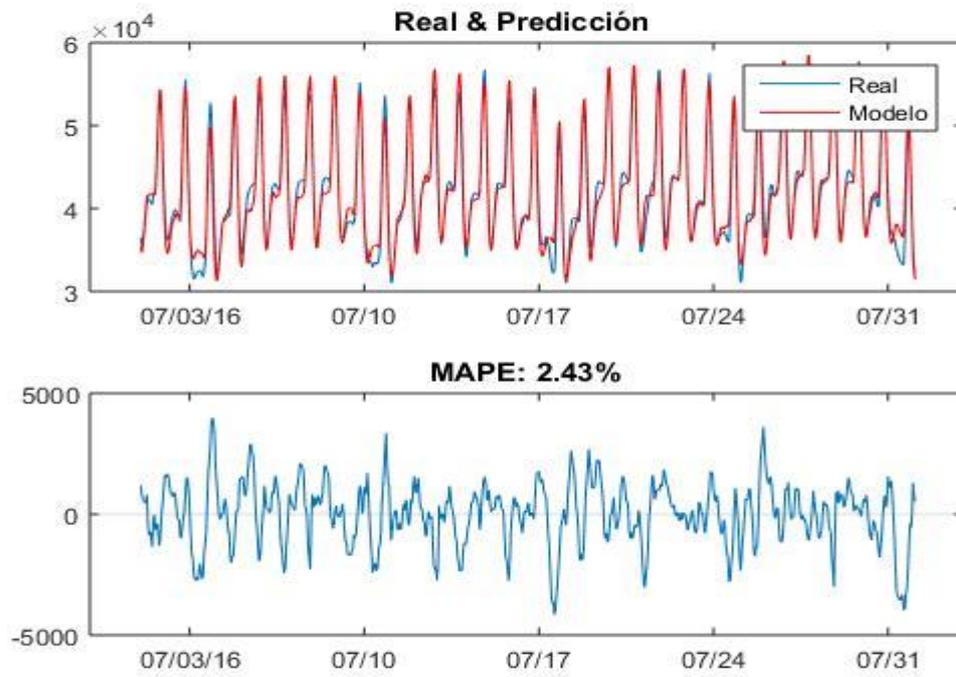
Mayo 2016:



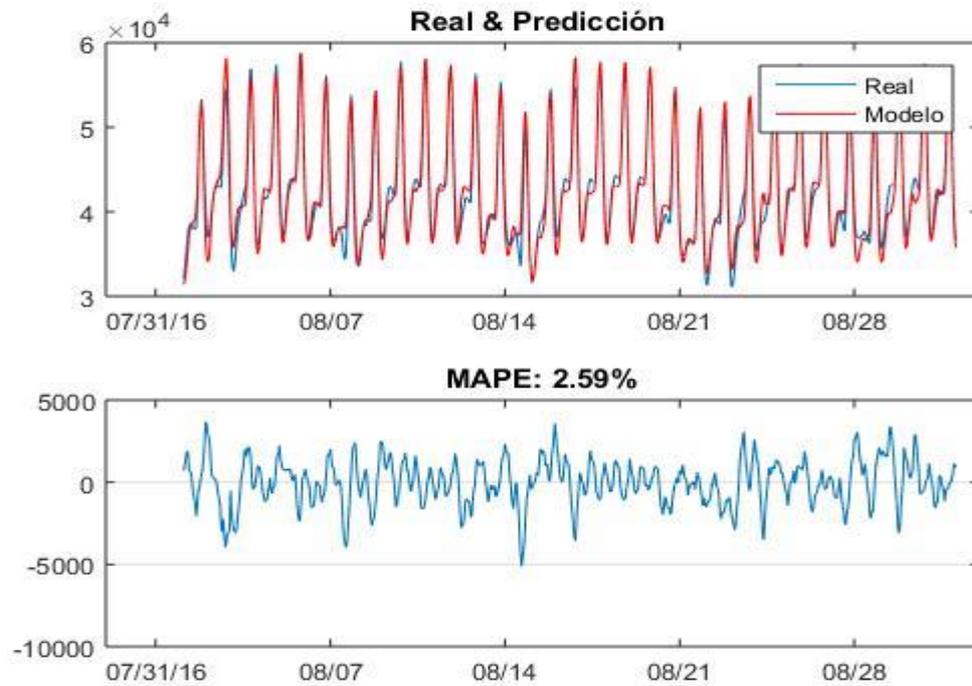
Junio 2016:



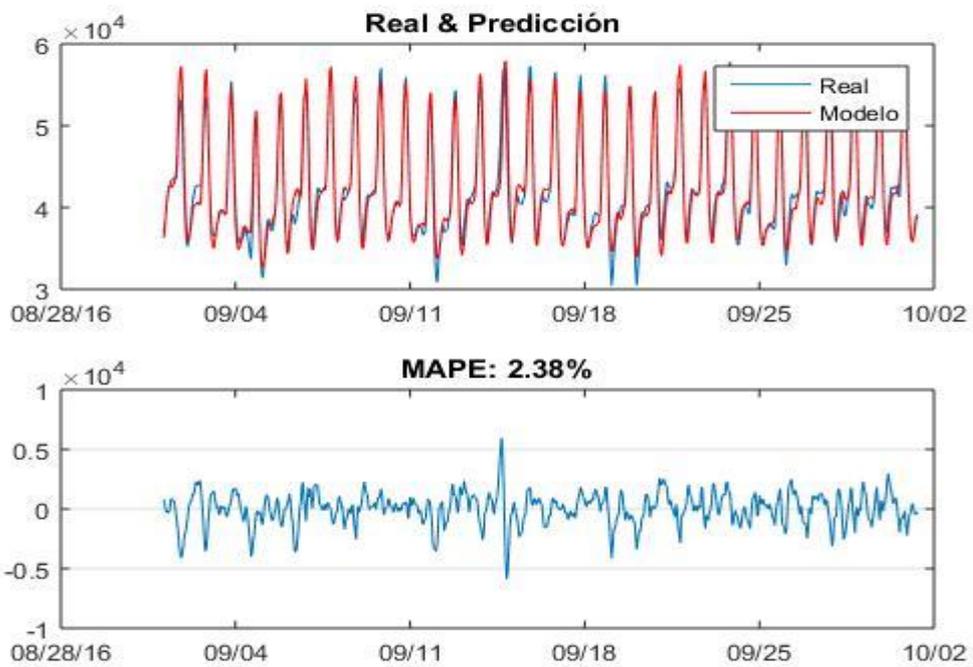
Julio 2016:



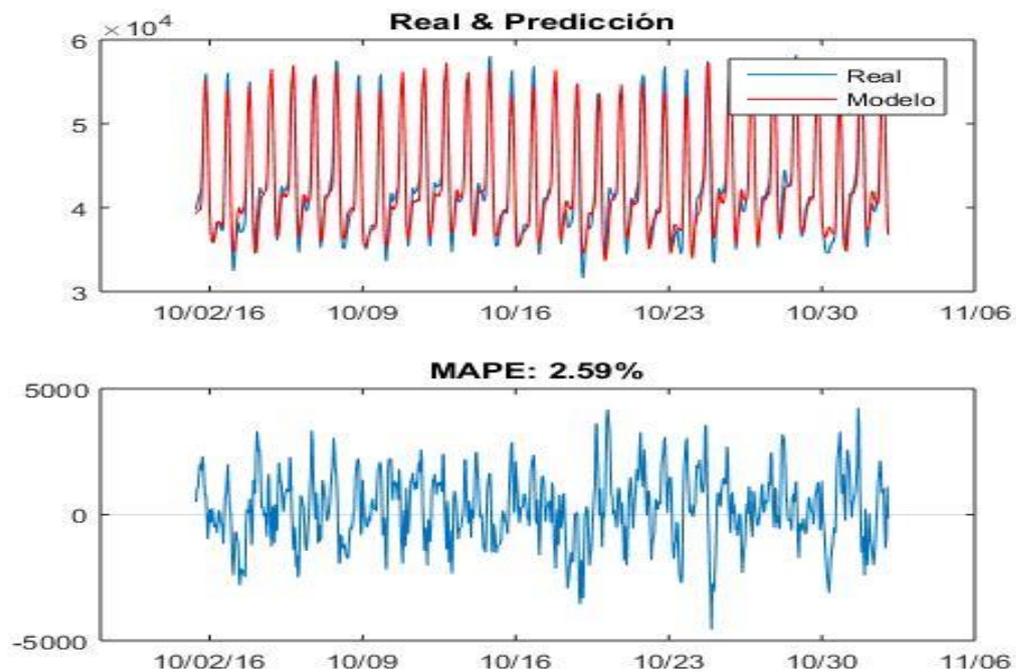
Agosto:



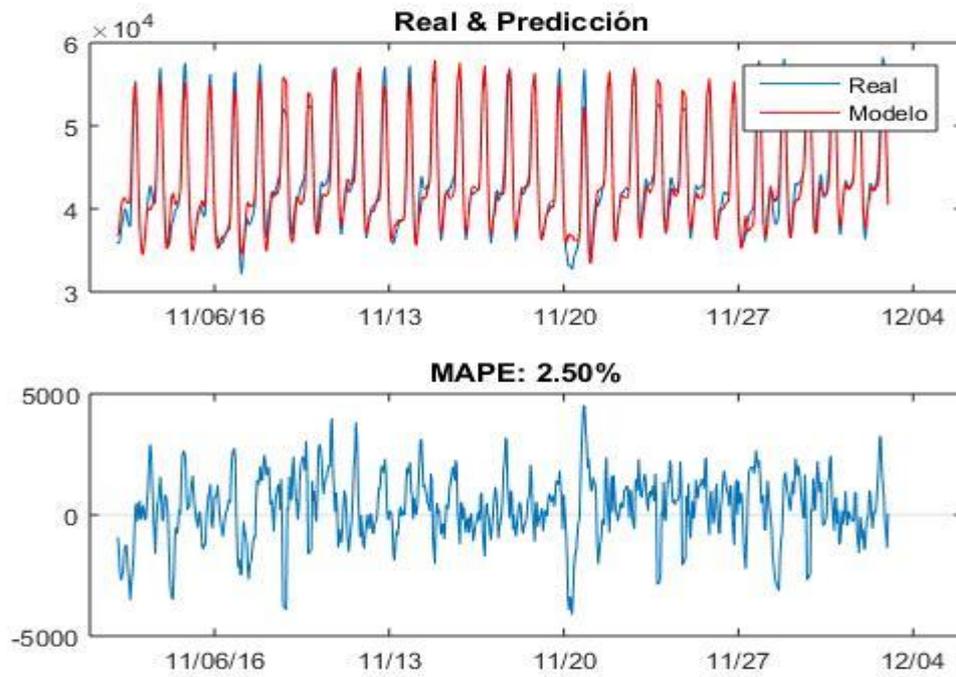
Septiembre 2016:



Octubre 2016:



Noviembre 2016:



Diciembre 2016:

