

UNIVERSIDAD NACIONAL DE INGENIERÍA

FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA



TESIS

**MODELAMIENTO DEL PRONÓSTICO DE LA DEMANDA
ELÉCTRICA DIARIA DEL SISTEMA ELÉCTRICO
INTERCONECTADO NACIONAL UTILIZANDO TÉCNICAS
DE *MACHINE LEARNING***

PARA OBTENER EL TÍTULO PROFESIONAL DE:

INGENIERO ELECTRICISTA

ELABORADO POR:

LEONARDO BRAIN GARCÍA FERNÁNDEZ

ASESOR

M.Sc. ING. DIONICIO ZOCIMO ÑAUPARI HUATUCO

LIMA – PERÚ

2021

**MODELAMIENTO DEL PRONÓSTICO DE LA DEMANDA ELÉCTRICA
DIARIA DEL SISTEMA ELÉCTRICO INTERCONECTADO NACIONAL
UTILIZANDO TÉCNICAS DE MACHINE LEARNING**

DEDICATORIA

Dedico esta tesis a mis padres Ruth Fernández Flores y Leonardo García Olarte por todo el apoyo incondicional y confianza otorgada.

RESUMEN

Esta tesis desarrolla un modelo computacional para pronosticar la demanda eléctrica peruana a corto plazo, basado en la comparación del desempeño entre dos metodologías, las cuales utilizan las redes neuronales de la Teoría de Resonancia Adaptativa (*ARTMAP Fuzzy*) y el modelo *Neuro-Fuzzy* (ANFIS), técnicas pertenecientes al *Machine Learning* (ML) y aplicado al Sistema Eléctrico Interconectado Nacional (SEIN). Además, el contenido de la tesis propone la metodología de pre-procesamiento del conjunto de datos históricos como alternativa para mejorar el desempeño en los resultados presentados. Los diferentes escenarios desarrollados en el pronóstico de demanda incluyen los años 2019 y 2020, donde las metodologías de las redes neuronales buscan la mejor opción en términos del error porcentual medio absoluto (MAPE). Finalmente, los resultados de la comparación propuesta plantean la sugerencia de actualizar el procedimiento técnico 03 (PR03), metodología propuesta por el Comité de Operación Económica del Sistema Interconectado Nacional (COES).

ABSTRACT

This thesis develops a computational model to forecast the Peruvian electricity demand in the short term, based on the performance comparison between two methodologies that use the neural networks of the Adaptive Resonance Theory (ARTMAP Fuzzy) and the *Neuro-Fuzzy* model (ANFIS), techniques belonging to Machine Learning (ML) and applied to the National Interconnected Electric System (SEIN). In addition, the thesis' content proposes the pre-processing methodology of historical data set as an alternative to improve performance in the results presented. The different scenarios developed in the demand forecast include the years 2019 and 2020, where neural network methodologies seek the best option in terms of absolute mean percentage error (MAPE). Finally, the results of the proposed comparison raises the suggestion to update procedure 03 (PR03), methodology proposed by the Coordinator of the Operation of the Interconnected Electric System (COES).

ÍNDICE DE CONTENIDOS

PRÓLOGO	1
1 INTRODUCCIÓN	2
1.1 Planteamiento del problema.....	2
1.2 Objetivos.....	5
1.2.1 Objetivo general.....	5
1.2.2 Objetivo específico.....	5
1.3 Hipótesis.....	5
1.3.1 Hipótesis general.....	5
1.3.2 Hipótesis específico.....	5
1.4 Antecedentes referenciales.....	6
2 PRONÓSTICO DE LA DEMANDA ELÉCTRICA	12
2.1 Importancia del pronóstico de la demanda.....	12
2.2 Clasificación del pronóstico de demanda.....	12
2.2.1 Corto plazo.....	12
2.2.2 Mediano plazo.....	13
2.2.3 Largo Plazo.....	13
2.3 Factores que afectan la demanda eléctrica.....	13
2.3.1 Factores meteorológicos.....	13
2.3.2 Factores económicos.....	13
2.3.3 Factores de tiempo.....	13
2.3.4 Factores esporádicos.....	14
2.4 Los datos en el pronóstico de demanda.....	14
2.4.1 Medidores convencionales.....	14
2.4.2 Medidores inteligentes.....	15
2.5 Las Métricas para evaluación del pronóstico.....	16

2.5.1	Errores dependientes de la escala	16
2.5.2	Errores porcentuales	16
2.5.3	Errores relativos.....	17
2.5.4	Errores de escala libre.....	18
2.6	Métodos para el pronóstico de demanda en corto plazo.....	18
3	APLICACIÓN DE LAS TÉCNICAS DE MACHINE LEARNING AL PRONÓSTICO DE LA DEMANDA ELÉCTRICA	21
3.1	¿En qué consiste Machine Learning?	21
3.2	Tipos de algoritmos de aprendizaje	22
3.2.1	Aprendizaje supervisado.....	22
3.2.2	Aprendizaje no supervisado.....	23
3.2.3	Aprendizaje por refuerzo	24
3.3	Sistemas Inteligentes.....	24
3.3.1	Redes neuronales artificiales	25
3.3.2	La lógica Fuzzy (Nebulosa).....	31
3.4	Teoría de la resonancia adaptativa (ART)	37
3.4.1	Red neuronal ARTMAP	37
3.4.2	Red neuronal ARTMAP Fuzzy	38
3.4.3	Algoritmo de entrenamiento para ARTMAP Fuzzy.....	41
3.5	Sistema adaptativo Neuro-Fuzzy (ANFIS).....	44
3.5.1	Arquitectura ANFIS	44
3.5.2	Aprendizaje ANFIS	46
4	METODOLOGÍA PARA EL PRONÓSTICO DIARIO DE DEMANDA ELÉCTRICA	50
4.1	Metodología utilizada por COES – procedimiento técnico 03	50
4.1.1	Pronóstico para un día ordinario.....	50
4.1.2	Pronóstico para un día Feriado	52
4.1.3	Resultados de la metodología COES.....	53
4.2	Metodología usando herramientas de Machine Learning.....	53
4.2.1	Pre-procesamiento de datos	55
4.2.2	Primera metodología	61

4.2.3	Segunda metodología	63
5	ANÁLISIS Y DISCUSIÓN DE RESULTADOS	65
5.1	Resultados de la primera metodología	65
5.2	Resultados de la segunda metodología	79
5.3	Comentarios	94
6	CONCLUSIONES	104
7	RECOMENDACIONES	106
8	REFERENCIAS BIBLIOGRÁFICAS	107
9	ANEXO A.....	112

PRÓLOGO

El presente trabajo, tesis de grado titulado modelamiento del pronóstico de la demanda eléctrica diaria del sistema eléctrico interconectado nacional utilizando técnicas de *Machine Learning*, estudió, analizó y propuso una metodología para resolver el problema de pronóstico de la demanda eléctrica en el sistema nacional peruano entre los años 2019 y 2020. El ensayo está motivado en la presentación de una propuesta para la actualización del procedimiento técnico 03, utilizado por COES en la programación diaria del despacho hidrotérmico, que permita obtener los mejores resultados en términos de error porcentual absoluto medio para de esta forma administrar de manera eficiente los recursos energéticos.

El desarrollo de la tesis, motivada en una gran cantidad de trabajos enfocados en el pronóstico de la demanda eléctrica, está basado en la comparación de dos metodologías y una propuesta de mejora de resultados. La primera metodología utiliza el modelo de la teoría de la resonancia adaptativa valiéndose de las redes neuronales ARTMAP *Fuzzy*, y la segunda usa el modelo *Neuro-Fuzzy* empleando las redes neuronales ANFIS. Por último se utiliza el pre-procesamiento de datos, en el desarrollo del entrenamiento, con la finalidad de garantizar un desempeño eficiente de los resultados para las metodologías anteriormente mencionadas. Todos estos análisis se realizaron utilizando el programa Matlab R2016a.

Los capítulos abordados en la presente tesis están divididos en cinco partes, la primera introduce la importancia del pronóstico de la demanda eléctrica a partir de la problemática identificada en el análisis de los datos históricos de los últimos años del sistema eléctrico nacional. El segundo y tercer capítulo constan de un abordaje al marco teórico y conceptual sobre el pronóstico de la demanda eléctrica y su aplicación a los conceptos *Machine Learning*, esto para la comprensión de términos generales de la propuesta del trabajo. El cuarto capítulo presenta el desarrollo del trabajo de investigación, se centra en las metodologías usadas y una propuesta de mejora de resultados. El quinto capítulo es referido al análisis procedente de las metodologías y discusión sobre la mejor propuesta frente al problema. Esta tesis finaliza con las conclusiones y recomendaciones resolviendo los planteamientos desarrollados en el primer capítulo.

CAPÍTULO I

INTRODUCCIÓN

1.1 Planteamiento del problema

El pronóstico de la demanda eléctrica desempeña un rol protagónico de suma relevancia en la toma de decisiones del sector eléctrico; esto significa que la implementación de una metodología ineficiente puede provocar una amenaza a la operación normal de este sector. El regulador y operador mediante una metodología eficiente de pronóstico garantizan una operación eléctrica confiable, segura, continúa y de calidad, aprovechando de manera óptima los recursos energéticos.

Por medio del procedimiento técnico 03 (PR-03) [1], aprobado por la Resolución OSINERGMIN N° 005-2011-OS/CD, publicada el 15 de enero de 2011, el Comité de Operación Económica del Sistema Interconectado Nacional (COES) se encarga de realizar el pronóstico de la demanda eléctrica Nacional, actividad necesaria para la programación del despacho hidrotérmico. Este PR-03 respaldado en una metodología de cálculo, demostró buenos indicadores en los últimos años, 2017, 2018, 2019 y 2020 medidos en términos de Error Porcentual Absoluto Medio (MAPE) anual de 1.89, 1.70, 1.64 y 1.95, respetivamente; sin embargo, en el análisis realizado a la distribución de frecuencias para los años en mención *Fig. 1.1*, se muestra resultados del MAPE diario en un rango de 0.45 a 7.98. Si bien se resalta que la metodología puede inducir al mínimo valor eficiente de 0.45 en el MAPE diario, también se observa que existen numerosos puntos en la dispersión mayores a la media diaria, esto quiere decir que los errores ineficientes en el MAPE sobrepasan con facilidad 1.64.

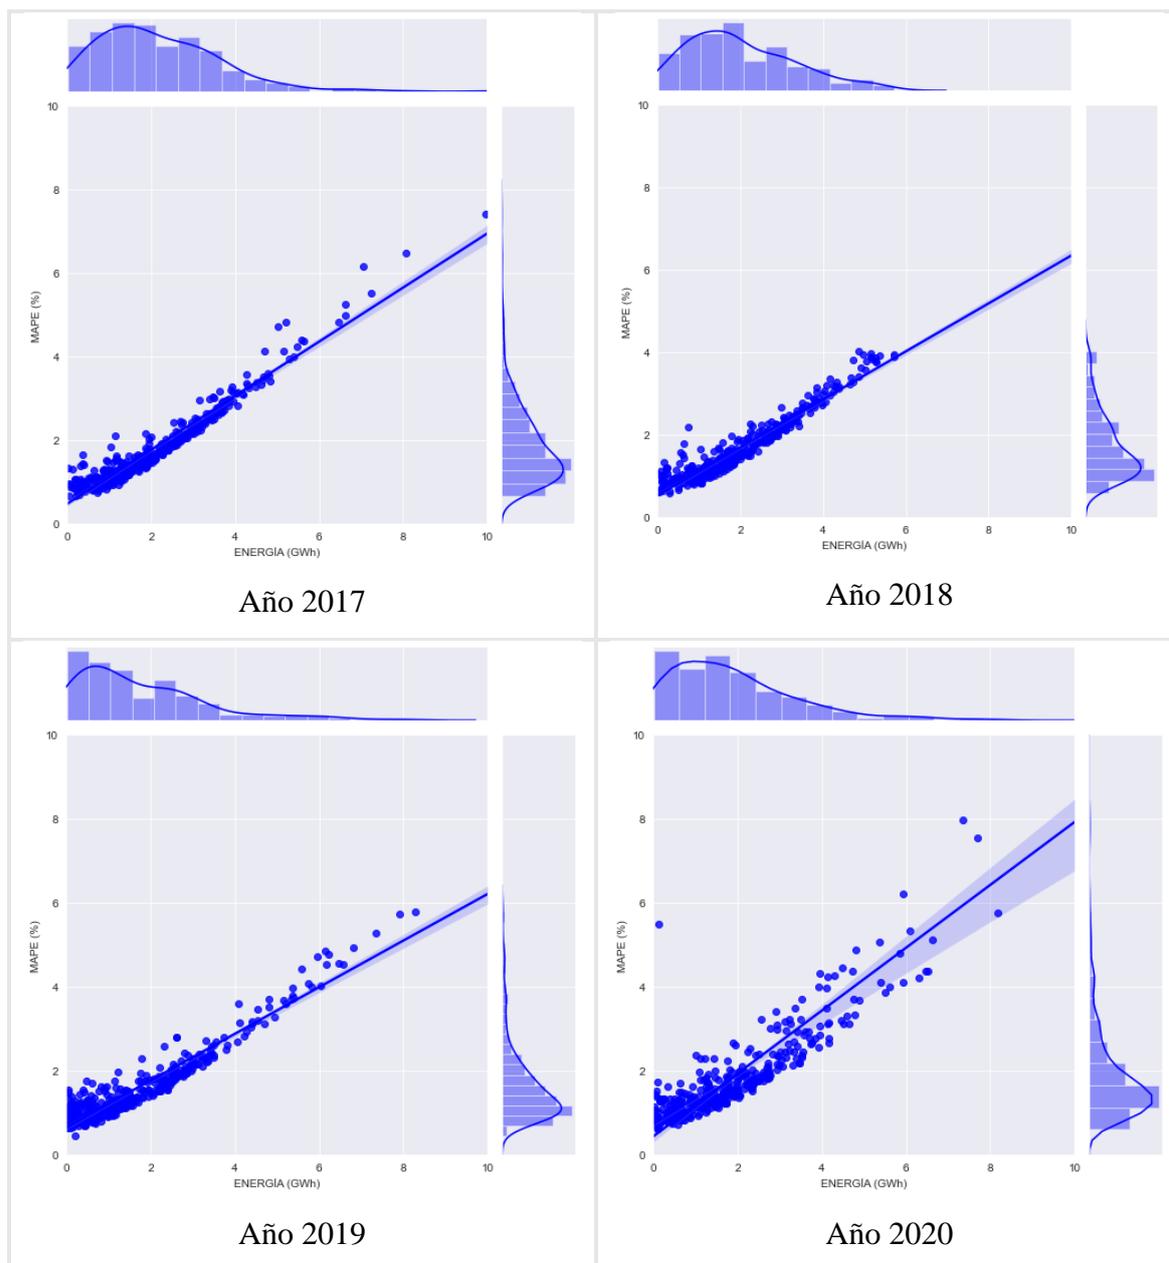


Fig. 1.1 Correlación utilizando distribuciones marginales entre el MAPE y la variación de Energía Absoluta Diaria – 2017, 2018, 2019 y 2020.

(Fuente: Elaboración propia)

El 16 de marzo del 2020, inmediatamente después de las medidas de confinamiento adoptadas por el estado peruano frente a la propagación del COVID-19, la demanda energética nacional empezó a comportarse de manera un tanto diferente a los patrones convencionales Fig. 1.2, consecuencia de la paralización del sector productivo y la baja empleabilidad. Es a partir de esta observación que se efectuó el análisis al pronóstico realizado por COES, programación de la operación del SEIN, basados en datos de los

Informes de Evaluación de la Operación Diaria (IEOD) de los últimos 4 años Fig. 1.1, y como resultado se observó grandes desviaciones en términos de MAPE respecto a la demanda del despacho ejecutado. Frente a este problema nacieron las siguientes interrogantes ¿Será que el procedimiento técnico 03 de COES precisa de mejoras? ¿Será que existe la necesidad de una nueva metodología para simular un pronóstico de la demanda del día siguiente tomando una muestra aleatoria de un día cualquiera y logrando un MAPE eficiente, comparativamente al PR-03?

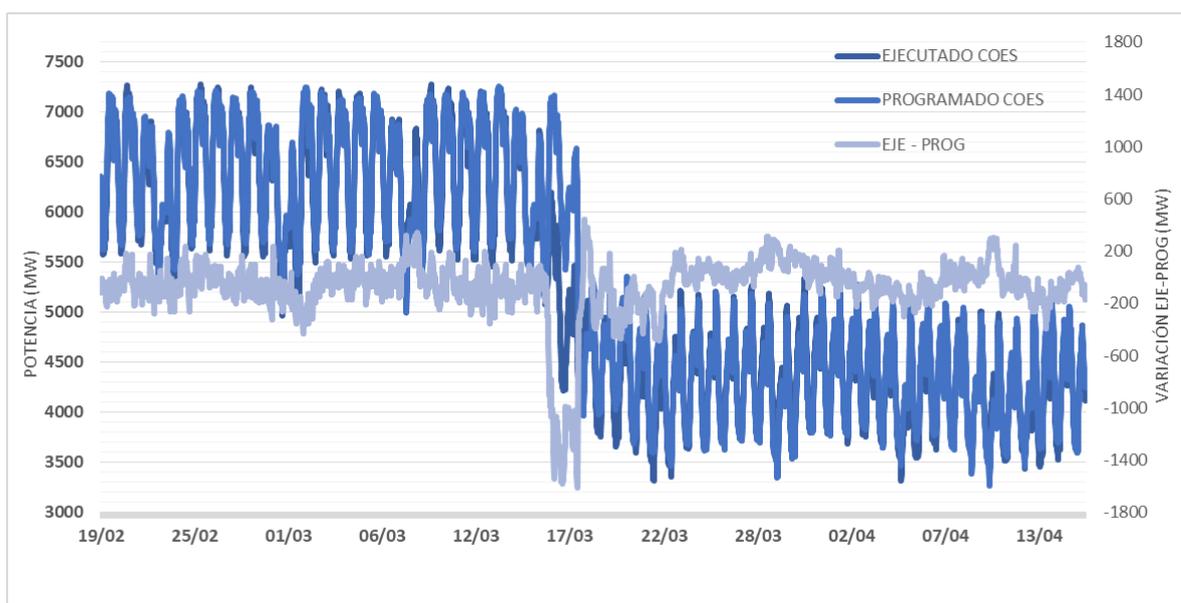


Fig. 1.2 Demanda SEIN 2020 consecuencia del confinamiento COVID-19.

(Fuente: Elaboración propia)

Las características de las cargas eléctricas son influenciadas por incertezas, estas pueden ser por factores de tiempo, climáticos, económicos y esporádicos. El problema a resolver en el pronóstico de la demanda eléctrica, en primera instancia, es identificar un patrón común entre los datos, los cuales conservan características de procesos estocásticos, es así que el pronóstico se convierte en un desafío para modelos convencionales como los de ingeniería. Por esa razón se necesita de modelos avanzado de reconocimientos de patrones que garanticen resultados eficientes a partir de las características mencionadas, esto sin contar con los grandes cambios venideros en referencia a la generación distribuida, la alta participación de fuentes renovables, los sistemas de almacenamiento de energía industriales-residenciales, los cuales adicionarán mayores fluctuaciones a la demanda eléctrica de sistema, y como consecuencia se podría incurrir en grandes imprecisiones en los pronóstico si se continua usando la metodología del PR-03.

Las impresiones en términos de error expuestas sobre el pronóstico de demanda, los comportamientos estocásticos y la evolución tecnológica en los sistemas eléctricos de potencia proponen la necesidad de plantear una nueva metodología que se ajuste a las características de SEIN. De esta manera garantizaría un despacho eléctrico eficiente, al mínimo costo, preservando la seguridad del sistema con un mejor aprovechamiento de los recursos energéticos.

1.2 Objetivos

1.2.1 Objetivo general

- ✓ Proponer una metodología basada en técnicas de *Machine Learning* para el pronóstico de la demanda eléctrica diaria aplicado al Sistema Eléctrico Interconectado Nacional que permita resultados eficientes respecto a una métrica de comparación.

1.2.2 Objetivo específico

- ✓ Proponer un algoritmo de *Machine Learning* para el procedimiento técnico 3 del Comité de Operación Económica del Sistema Interconectado Nacional que permita resultados eficientes respecto a una métrica de comparación.
- ✓ Determinar una correcta asociación de información utilizando una amplia base de datos del Sistema Eléctrico Interconectado Nacional que permita resultados eficientes respecto a una métrica de comparación.
- ✓ Proponer una metodología de pre-procesamiento aplicado a la base de datos que permita resultados eficientes respecto a una métrica de comparación.

1.3 Hipótesis

1.3.1 Hipótesis general

- ✓ La propuesta de la metodología basada en técnicas de *Machine Learning* para el pronóstico de la demanda eléctrica diaria aplicado al Sistema Eléctrico Interconectado Nacional garantiza resultados eficientes respecto a una métrica de comparación.

1.3.2 Hipótesis específico

- ✓ El algoritmo de *Machine Learning* para el procedimiento técnico 3 del Comité de Operación Económica del Sistema Interconectado Nacional garantiza resultados eficientes respecto a una métrica de comparación.

- ✓ La correcta asociación de información utilizando una amplia base de datos del Sistema Eléctrico Interconectado Nacional garantiza resultados eficientes respecto a una métrica de comparación.
- ✓ La metodología de pre-procesamiento aplicado a la base de datos garantiza resultados eficientes respecto a una métrica de comparación.

1.4 Antecedentes referenciales

Diversas investigaciones respecto al desarrollo de *Machine Learning* (ML) y la aplicación a los sistemas de energía están presentando, en estas dos últimas décadas, una tendencia dramática al crecimiento como consecuencia de los avances tecnológicos *e.g.*, sistemas de almacenamientos de energía, sistemas *Smart Grid*, pronósticos de demanda eléctrica e Internet de las Cosas (IoT). En [2] hace referencia a los diez modelos más utilizados de ML como las redes neuronales, los árboles de decisión, el aprendizaje profundo, conjunto de modelos híbrido avanzados entre otros aplicados a los sistemas de energía. Dentro de estos modelos, existen múltiples dedicados al pronóstico de la demanda eléctrica a corto plazo, todos compartiendo objetivos comunes como un bajo costo computacional, estabilidad y precisión en el pronóstico, por esta razón, como forma de contextualizar la presente tesis, se realiza una investigación a las propuestas de pronósticos aplicados a los diferentes mercados eléctricos.

En [3] se aplicó la teoría de redes neuronales artificiales de múltiples capas vía *backpropagation* al pronóstico de la demanda del mercado de corto plazo de Ontario-Canadá. La técnica utilizada demostró, aparte de valores de históricos de carga en Ontario, la importancia de utilizar valores exógenos como datos de entrada *e.g.*, precios de energía en el mercado spot de vecinos. Resultado de este análisis, el trabajo demostró un impacto positivo significativo en el desempeño de la red solo con la inclusión de los precios de mercados eléctricos vecinos.

En la revista [4] propusieron un esquema híbrido neuro-wavelet para el pronóstico de la demanda en corto plazo de Queensland-Australia. La idea nace con el objetivo de mejorar los perfiles de cargas de los participantes en el mercado, minimizando las pérdidas, y particularmente se centra en las limitaciones de los métodos de regresión lineal utilizados, pues cada vez presentan ineficiencias en la captura de no linealidades presentes en condiciones del mercado. El resultado de la técnica propuesta demostró su efectividad en el mercado Australiano con resultados prometedores.

El investigador en [5] sostiene la importancia del pronóstico de la demanda en el corto plazo consecuencia de la desregulación de los sistemas eléctricos. En primera instancia se implementó la adaptación de dos parámetros de inclinación y traslación a la función sigmoidea para las redes neuronales artificiales de múltiples capas vía entrenamiento de *backpropagation*. Los resultados obtenidos fueron buenos; sin embargo la estructura como si, presentaba problemas de convergencia. Por esta razón se propuso utilizar la redes neuronales de la teoría de la resonancia adaptativa (ART y ARTMAP *Fuzzy*) debido a sus características más importantes como la estabilidad y plasticidad. Se evaluaron estas teorías con datos de una compañía de sector eléctrico Brasileño, como resultado la red ARTMAP *Fuzzy* demostró menor tiempo computacional, plasticidad y estabilidad, aplicación a sistemas eléctricos de potencia, implementación a sistemas continuos y calidad de resultados.

Escobar y Pérez [6] compararon las técnicas de máquinas de vectores de soporte (SVM), lógica *fuzzy* y redes neuronales para el pronóstico de la demanda eléctrica a corto plazo. Además de la comparación, en el artículo se discutió la implicancia de los factores externos en los resultados y la necesidad de datos históricos exorbitantes para la obtención de buenos resultados. Finalmente, los autores concluyen que la técnica de SVM realizó una predicción exitosa comparada con las otras, esta descartó un valor de penalización dentro de la optimización cuadrática el cual permitió reducir errores en relación a las otras técnicas mencionadas.

En [7] se aplicaron los modelos de lógica nebulosa y redes neuronales ANFIS para el pronóstico de demanda eléctrica de la siguiente hora en el mercado eléctrico de Turquía. Los datos del 2009 y 2011 fueron utilizados para diseñar el modelo, y finalmente los datos del 2012 para la validación. Los resultados demostraron una mejor precisión de las redes ANFIS comparados con el modelo de lógica nebulosa. Adicionalmente el autor concluye que los factores externos como el cubrimiento de nubes y las variables de velocidad de viento podrían ser utilizados para generar mejores resultados.

El trabajo de maestría en [8] propuso el pronóstico de una demanda global a corto plazo para las próximas 24 horas utilizando la red neuronal ARTMAP Euclidiana, manteniendo las características basadas en la resonancia adaptativa. Los datos utilizados fueron del mercado de energía en España de los años 1990. En la evaluación esta propuesta obtuvo resultados satisfactorios comparados a la red ARTMAP *Fuzzy*.

Li *et al.* [9] propusieron un modelo híbrido para el pronóstico de la demanda eléctrica a corto plazo con una semana de anticipación para el mercado eléctrico de Nueva Gales del Sur y Victoria (Australia). Este modelo titulado EEMD-SCGRNN-PSVR está formado por una combinación de técnicas, descomposición en modo empírico por conjuntos (EEMD), el ajuste estacional (S), la validación cruzada (C), la red neuronal de regresión general (GRNN) y la máquina de regresión vectorial de soporte optimizada por el algoritmo de optimización del enjambre de partículas (PSVR). Es por esa combinación que tiene la capacidad de pronosticar la componente de la forma de la onda y la tendencia de la demanda, demostrando experimentalmente precisión y estabilidad. Sin embargo, el modelo demanda un alto costo computacional y tiempo de procesamiento.

Sevlian y Rajagopal [10] proponen una ley empírica para el pronóstico de la carga en diferentes niveles de agregación, demostrando de manera experimental que mediante diferentes métodos la agregación solo tiene rendimiento hasta un punto específico de carga. De los resultados se afirma que cuanto más agregada esté una carga, más suave serán los patrones de consumo, por consiguiente se obtendrá un pronóstico más preciso. De otro modo, en una agregación individual los pronósticos de carga incurrirán en errores mucho más altos. Finalmente este estudio deja como carta abierta investigar ideas novedosas para el pronóstico de cargas agregadas basado en modelo inducidos por la agregación de consumos individuales.

En [11] proponen el algoritmo de entrenamiento basado en un comportamiento sobre el movimiento de las ovejas de un rebaño (FTL) aplicado al aprendizaje de las redes neuronales artificiales para el pronóstico de la demanda a corto plazo. Este algoritmo actualiza de forma adecuada los parámetros de las redes neuronales *perceptron* multicapas (MLP) manteniendo una alta propiedad de extracción de características y ayuda a generar un mapeo no lineal de datos complejos. Los cálculos de la eficiencia se realizaron bajo datos obtenidos de los años 2004 a 2007 de los mercados eléctricos australiano y norteamericano.

Alves [12] propuso un modelo híbrido entre ARTMAP *Fuzzy* y mínimos cuadrados (MMQ) para el pronóstico de la demanda eléctrica no residencial a corto plazo de una Universidad Brasileña. Los datos disponibles contenían muchos ruidos y valores atípicos, también una poca variabilidad en las entradas. Los primeros resultados con la red ARTMAP *Fuzzy* no fueron satisfactorios debido a la poca variedad en las entradas, por lo que se introdujo el concepto de valores de carga máxima, media y mínima para las entradas y a su vez se realizó

evaluaciones con distintos parámetros en la red. El modelo híbrido ARTMAP *Fuzzy*-MMQ demostró superioridad en referencia a resultados en comparación al ARTMAP *Fuzzy*.

Peng *et al.* [13] en este trabajo se sostiene que gran mayoría de las investigaciones en el pronóstico de corto plazo de la últimas décadas se han centrado en cargas con un alto nivel de agregación *e.g.*, un país, una región, por esta razón se planteó la necesidad de abordar el estudio al pronóstico en diferentes niveles de agregación. Sin embargo, de los análisis realizados por los autores se rescata que el aumento de los niveles de agregación aumenta la previsibilidad y el rendimiento de todos los algoritmos. Además, la selección de las técnicas de pronóstico de carga depende en gran medida de los datos en sí, y no existe una técnica única que supere a otras técnicas en todos los escenarios. Finalmente recomiendan realizar un análisis de predictibilidad de los datos antes de aplicar directamente cualquier técnica de pronóstico.

En [14] propusieron un modelo híbrido para el pronóstico de la demanda eléctrica a corto plazo de Langfang-China. Esta herramienta EMD-mRMR-FOA-GRNN está constituido por la combinación de las técnicas descomposición en modo empírico (EMD), la relevancia máxima de redundancia mínima (mRMR), la red neuronal GRNN y el algoritmo de optimización de la mosca de la fruta (FOA). Los datos históricos de carga pasaron por diversos procesos como descomposiciones, análisis de correlación, factor de suavizado con el fin obtener un valor de métrica eficiente. Es por medio de estos procesos que se garantizó la efectividad, eficiencia y aplicabilidad al mercado de corto plazo.

Kim *et al.* [15] plantearon un modelo híbrido de red neuronal convolucional de inicio recurrente (RICNN), que combina las redes neuronales recurrentes (RNN) y las redes neuronales convolucionales (CNN) unidimensional (CNN 1-D), para el pronóstico de la demanda en corto plazo de tres grandes complejos de energía en Corea de Sur. Los modelos de RNN han demostrado un rendimiento favorable para el pronóstico de demanda; sin embargo, al pronosticar la carga eléctrica en un momento específico, los modelos de pronóstico existentes basados en RNN no utilizan un vector de estado oculto futuro predicho ni la información pasada totalmente disponible. Por lo tanto, un vector de estado oculto en el momento específico de pronóstico, no se podrá corregir para mejorar la predicción de los siguientes tiempos del pronóstico. Para solucionar este problema se plantó la red RICNN demostrando un alto desempeño debido a su robustez comparado a los modelos RNN, CNN y MLP.

En [16] proponen el método híbrido ENN-PSO, basado en la red neuronal de Elman (ENN) y la optimización de enjambre de partículas (PSO), esto aplicado al pronóstico de la demanda eléctrica a corto plazo de Eslovaquia. A través del algoritmo PSO se buscó una tasa de aprendizaje adecuada para ENN, como consecuencia el modelo híbrido demostró superioridad en eficiencia a GRNN, ENN original y MLP; sin embargo, la única desventaja de este método fue un elevado costo computacional.

En Bento *et al.* [17] se propuso el método híbrido inspirado en el gradiente conjugado de *Bat* y *Scalet* con el fin de mejorar la capacidad de aprendizaje de la red neuronal. Este método utiliza una técnica de selección de datos mejorados y extracción de características, una condición del pre-procesamiento para el aporte de un comportamiento regular en las series de tiempo. Para la evaluación de este método se utilizó datos del mercado eléctrico Portugués, Nueva York y Nueva Inglaterra aplicados a un pronóstico de las próximas 24 horas. Los resultados obtenidos demuestran errores de métricas muy eficientes comparados los métodos ENN, redes neuronales con función de base radial (RBF) y SVM, además enfatiza la importancia de la selección adecuada de patrones de entrada para la red.

El problema que abordó Müller *et al.* [18] se enfatizó en la dificultad del pronóstico de demanda eléctrica a corto plazo en niveles desagregados consecuencia de las características aleatorias de las series de tiempo, lo que genera ruidos y como resultado afecta la calidad de las predicciones. Para resolver el problema del ruido utilizó el Espectro Singular de Análisis (ESA) en conjunto con la Red Neuronal ARTMAP *Fuzzy*; el uso de ESA con otros métodos presentó respuestas ambiguas. Como resultado de ESA y ARTMAP *Fuzzy* se logró una reducción de casi el 50% en la métrica MAPE comparada con el modelo de media móvil integrado autorregresivo estacional (SARIMA).

En [19] propusieron un modelo *Neuro-Fuzzy* local de autopartición (LLFN) que es capaz de realizar un pronóstico de demanda eléctrica a corto plazo de manera rápida y precisa. Este modelo se aplicó a los mercados de energía AEMO localizado en Nueva Gales del Sur-Australia y a NYISO en New York-Estado Unidos. El modelo aparte de mantener linealidad y propiedad de aprendizaje por medio de un sistema de inferencia difuso, también administra el ingreso de los datos dividiéndolos en vectores lineales y no lineales para la asignación separada de modelos locales. El algoritmo utilizado para entrenar esta propuesta se realiza mediante el aprendizaje de árbol binario jerárquico y las premisas de las reglas se calculan mediante funciones de partición sigmoidea. Los pronósticos realizados para 12 y 24 horas

en adelante, alcanzaron resultados superiores comparados a algunos métodos comunes utilizados en la literatura.

El-Hendawi y Wang [20] propusieron una red neuronal *wavelet* completo para el pronóstico de demanda a corto plazo. Este modelo combina la transformada de *Wavelet* y redes neuronales multicapas. Por medio de la transformada de *Wavelet* se descompone el perfil de carga original en diferentes frecuencias para aprovechar los patrones de consumo eléctrico. Utiliza la MLP para predecir la carga de cada componente descompuesto mediante el algoritmo *Levenberg-Marquardt*. El desempeño de este modelo fue aplicado al mercado de energía en Ontario-Canadá, destacándose por reducir considerablemente el error porcentual en comparación a métodos de redes neuronales tradicionales.

CAPÍTULO II

PRONÓSTICO DE LA DEMANDA ELÉCTRICA

2.1 Importancia del pronóstico de la demanda

El sector de energía eléctrica, al igual que otros, se desarrolla en torno a la toma de decisiones tanto económicas como técnicas. Estas decisiones repercuten significativamente en el comportamiento de la operación de los sistemas eléctricos y viceversa, ambas coexisten cooperando entre sí para garantizar intereses individuales con el fin de satisfacer objetivos comunes *e.g.*, confiabilidad, seguridad, continuidad y un despacho económico. Por esta razón, es imprescindible realizar un pronóstico de demanda que garanta una operación eficiente de los objetivos comunes mencionados, cada uno adecuándose a los horizontes de tiempo pertinentes. Por tanto, cada protagonista participa y realiza análisis en diferentes horizontes de tiempo dependiendo de sus objetivos propios a alcázar. El regulador y operador por medio de criterios precisos en los pronósticos, garantizan una operación eléctrica confiable, segura, continúa y de calidad de manera que aproveche de forma eficiente los recursos energéticos. Los agentes del sector eléctrico se encargan de generar estrategias comerciales y toma de decisiones en cuanto a inversión. Los usuarios pueden ocuparse de una gestión eficiente de las cargas conectadas en su punto de suministro [21][22][23].

2.2 Clasificación del pronóstico de demanda

El pronóstico de demanda eléctrica representa un indicador para la toma de decisiones futuras, relacionados al corto, mediano y largo plazo. Por esta razón, una clasificación teniendo en cuenta los diferentes horizontes de tiempo es considerado una propuesta necesaria para la correcta operación de los sistemas eléctricos, así como también en el planeamiento de expansión para garantizar la rentabilidad de grandes proyectos eléctricos.

2.2.1 Corto plazo

El pronóstico a corto plazo cubre un horizonte que abarca usualmente el intervalo de tiempo de una hora hasta una semana. Este tipo de clasificación [21], puede ayudar al operador de

sistemas eléctricos a estimar los flujos de cargas para tomar decisiones que puedan evitar sobrecargas y desconexiones. Estas decisiones son de alta relevancia porque garantiza la seguridad, continuidad y mejora la confiabilidad del sistema eléctrico.

2.2.2 Mediano plazo

El pronóstico a mediano plazo cubre un horizonte que abarca usualmente el intervalo de una semana hasta un año. Este permite a los participantes del mercado eléctrico estimar la demanda eléctrica para un intervalo de tiempo mayor con la finalidad de ser un soporte frente a negociaciones de contratos [22].

2.2.3 Largo Plazo

El pronóstico a largo plazo contempla un horizonte mayor a un año. El límite del análisis en el estudio podría tener un alcance hasta 20 años, aunque también puede encontrarse plazos de entrega de 25 a 30 años. Los análisis del pronóstico a largo plazo contribuyen principalmente al análisis de planeamiento expansión de los sistemas eléctricos, y al mismo tiempo decisiones sobre inversiones futuras [21][22].

2.3 Factores que afectan la demanda eléctrica

2.3.1 Factores meteorológicos

Son factores provenientes de la naturaleza y ocurren en corto plazo *e.g.*, la humedad relativa, las lluvias, neblinas, temperaturas. De los ejemplos mencionados, la temperatura es uno de los factores que más influyen en el consumo de energía, debido al incremento de la energía por la utilización de aires acondicionados, refrigeradoras, calefactores[21] [24].

2.3.2 Factores económicos

Estos son factores que se suscitan a largo plazo. La densidad demográfica, el crecimiento poblacional, el poder de adquisición económica son informaciones importantes que determinan la evolución de la demanda eléctrica [24].

2.3.3 Factores de tiempo

El factor tiempo incluye la época del año, el día de la semana y la hora del día. Desempeña un papel relevante en el pronóstico de demanda. Esta se divide en base al comportamiento de la carga que puede ser estacional y cíclica. Estacional se refiere a días atípicos, días donde existes feriados que generan comportamientos no comunes en las cargas. Cíclica se refiere a los comportamientos de las cargas que suceden con cierta periodicidad *e.g.*, los sábados y domingos[21][24].

2.3.4 Factores esporádicos

Son escenarios que ocurren de forma ocasional como eventos deportivos, elecciones [24]. Los factores esporádicos no tienen mucha relevancia cuando se refiere a la conexión y desconexión de cargas residenciales; sin embargo, el escenario cambia en las desconexiones y variaciones de cargas en grandes clientes libres.

2.4 Los datos en el pronóstico de demanda

El análisis de datos es un proceso que se encarga de examinar conjuntos de informaciones con el propósito de inferir conclusiones sobre comportamientos de patrones, sirviendo como soporte en la toma de decisiones o en la ampliación de conocimientos en ciertas disciplinas. Estas informaciones no están exentas a la demanda eléctrica, en virtud, los medidores son importantes herramientas que recaban información del consumo energético que ayuda en las valorizaciones de potencia y energía, además de garantizar datos históricos que permitan entender y administrar eficientemente el mercado eléctrico. La información proporcionada por los medidores en el abordaje del pronóstico de demanda es muy relevante, por ese motivo, se procede a describir los usados en el sector.

2.4.1 Medidores convencionales

Automatic Meter Reading (AMR): Conocido como el sistema automático de medición, es una técnica utilizada en los sistemas de mediciones tradicionales. Desempeña la función de recopilar datos que serán utilizados en el proceso de facturación. La tecnología en esta técnica consiste en descifrar el movimiento mecánico en el dial del medidor para ser traducidos en señales digitales, los mismos que serán transmitidos a empresas de servicios por medio de cables, líneas telefónicas, líneas eléctricas entre otras [25].

Advanced Metering Infrastructure (AMI): Conocida como la infraestructura de medición avanzada, presenta una arquitectura para los “medidores inteligentes”, comunicación de redes y el manejo de datos. Está habilitado para una transmisión bidireccional entre consumidores y los proveedores de servicio respaldados en la dirección IP. El tipo de transmisión de datos es realizado en tiempo real usando comunicaciones de líneas de potencia, radio frecuencia entre otras. Estos datos son recibidos en un sistema de gestión de datos del medidor para luego ser almacenados y analizados por empresas que administran el servicio [25].

Por lo referido anteriormente, respecto a la característica y funcionalidades de estos medidores convencionales, se espera, para categorizar este avance hacia medidores realmente inteligentes, la captura de datos de energía en tiempo real y posiblemente en generación distribuida, la capacidad de lectura remota y local, capacidad de control remoto del suministro y posibilidad de vinculación a otros tipos de suministro como gas o agua.

2.4.2 Medidores inteligentes

El medidor inteligente es un dispositivo electrónico de alta complejidad capaz de medir y capturar grandes bloques de información, en la gran mayoría de casos está conectado a un dispositivo de comunicación llamado puerta de enlace inteligente que permite establecer una red segura en el procesamiento de datos. A pesar de una amplia variedad de tecnologías involucradas en su diseño y fabricación, además de las variaciones en despliegues tecnológicos entre los diferentes países, existe un proceso común en los medidores inteligentes para la recolección, comunicación y análisis de datos que conducen a la toma certera de decisiones.

Los procesos según [26] están divididos en dos partes como son la recopilación y transferencia, y procesamiento de datos. La primera se encarga de recopilar y transferir por medio de una red de área local (LAN) direccionados a un punto de recolección de datos. Los datos refieren al consumo real de energía eléctrica medidas en kilovatios hora (kWh), esto se lee y transmite en intervalos de tiempo de 15 minutos y puede variar hasta 1 hora. En lo que respecta a la segunda parte, el procesamiento de datos puede realizarse en el punto de la recolección de datos, pero en la mayoría de casos se transfiere a un centro de control o central de recolección de las empresas involucradas en la medición a través de una red de área amplia (WAN).

Las partes interesadas en el proceso de medición a partir de los medidores inteligentes, siguiendo una clasificación simple, son consumidores, empresas eléctricas y el medio ambiente. Para los consumidores porque podrían gestionar el uso de los artefactos eléctricos por medio de concepto de la función de control de carga, referido a la gestión de lado de la demanda. En el caso de las empresas eléctricas para perfilar y comprender las necesidades para una mejor prestación de servicios con el objetivo de fidelizar clientes. Para el medio ambiente la reducción de los gases de efecto invernadero consecuencia de una buena gestión de la programación de la operación para restringir el despacho de las centrales termoeléctricas.

Finalmente, la recopilación de los datos realizada por diferentes empresas se utilizan con el objetivo de la elaboración de estrategias comerciales, facturación, monitoreo de redes y servicios, elaboración de perfiles, pronósticos y planificación.

2.5 Las Métricas para evaluación del pronóstico

Con la finalidad cuantificar y promediar los errores de los pronósticos de demanda, varias métricas para el proceso de evaluación de precisión fueron propuestas. Estas se clasifican en cuatro [27].

2.5.1 Errores dependientes de la escala

El error absoluto del pronóstico es simplemente:

$$e_t = |Y_t - F_t| \quad (2.1)$$

Y_t : Valor verdadero

F_t : Valor de pronóstico

Este error está en la misma escala que los datos, es aplicado a un número de ilimitado de cosas desde barcos hasta tornillos. Las mediciones de precisión se basan en la misma escala.

$$\text{Error absoluto medio (MAE)} = \text{Media}(|e_t|) \quad (2.2)$$

$$\text{Error absoluto de la media geométrica (GMAE)} = \text{Media geométrica}(|e_t|) \quad (2.3)$$

$$\text{Error cuadrático medio (MSE)} = \text{Media}(e_t^2) \quad (2.4)$$

La observación relevante a estas opciones de métricas es que todas deben estar en la misma escala que los datos, no se puede comparar la precisión entre múltiples series porque las escalas de datos y errores son dependientes. Además, ninguno de estos son significativos; sin embargo, la literatura recomienda MAE por la facilidad de entender y calcular.

2.5.2 Errores porcentuales

Este enfoque referente a los errores porcentuales presenta la ventaja de ser independiente en la escala, por lo que se utiliza con frecuencia para comparar el rendimiento de pronósticos entre diferentes series.

$$\text{Porcentaje de error } (p_t) = 100e_t/Y_t \quad (2.5)$$

Este tipo de medición basado en errores porcentuales presenta desventaja, podría ser infinito o indeterminado si existe dentro de la base de datos valores ceros. Además, los errores pueden generar una distribución cuando los valores reales son cercanos a cero. Por lo tanto, es imposible usar MAPE consecuencia de la ocurrencia de períodos cero en la demanda.

$$\text{Error porcentual absoluto medio (MAPE)} = \text{Media}(|p_t|) \quad (2.6)$$

En el *sMAPE*, si el valor Y_t es cercano a cero, el pronóstico F_t probablemente podría ser un valor cercano a cero, por lo tanto, la medida todavía implicaría la división por un número cercano a cero. Además *sMAPE* podría ser negativo lo que generaría una interpretación ambigua.

$$\begin{aligned} \text{Error simétrico porcentual absoluto medio (sMAPE)} = \\ \text{Media}\left(\frac{200|Y_t - F_t|}{(Y_t + F_t)}\right) \end{aligned} \quad (2.7)$$

2.5.3 Errores relativos

La división entre un valor de error del método de referencia en los errores relativos, representa alternativa a los porcentajes para el cálculo de medidas de escala independiente. Generalmente este método puede llegar a ser el método *naïve* donde F_t es igual a la última observación.

$$\text{Error relativo (} r_t) = e_t / e_t^* \quad (2.8)$$

e_t^* : Es el error de pronóstico obtenido del método de referencia.

Esta métrica es usada para la precisión del pronóstico de diferentes series. Sin embargo, cuando los errores son pequeños, utilizar el método de *naïve* puede generar error de división entre cero.

$$\text{Error absoluto de media relativa (MdRAE)} = \text{Media}(|r_t|) \quad (2.9)$$

$$\begin{aligned} \text{Error absoluto de la media geométrica relativa (GMRAE)} = \\ \text{Media geométrica}(|r_t|) \end{aligned} \quad (2.10)$$

2.5.4 Errores de escala libre

El error de escala absoluto medio puede ser utilizado para pronosticar una sola serie, y para comparar antes de emitir la precisión en todas las series. También, esta medición puede luego compararse con los valores MASE de otros grupos de series para identificar qué series son las más difíciles de pronosticar.

$$\text{Error de escala } (q_t) = e_t / \left(\frac{1}{n-1} \sum_{i=2}^n |Y_t - Y_{i-1}| \right) \quad (2.11)$$

$$\text{Error de escala absoluto medio (MASE)} = \text{Media}(|q_t|) \quad (2.12)$$

La única circunstancia donde MASE sea infinita o indeterminada es cuando los datos históricos son todo igual. Este se consagra como la única métrica que puede ser usado para todos los pronósticos y todos los tipos de series.

2.6 Métodos para el pronóstico de demanda en corto plazo

El crecimiento de métodos y una larga variedad de técnicas como estadísticas y de inteligencia artificial son aplicados a los pronósticos de la demanda de corto plazo [21].

Enfoque del día general: En este método, para realizar el pronóstico se requiere primeramente relacionar los datos con el clima, el día de la semana y la fecha. El proceso es recopilar una grande base de datos, puede abarcar uno, dos o tres años, para después buscar entre estas, las características similares al día de pronóstico. Cabe resaltar que no solamente ese pronóstico puede ser un día similar al de la base de datos, sino que puede abarcar una combinación lineal o un proceso de regresión de varios datos pasados de nuestra base.

Métodos de Regresión: Este método consiste en relacionar datos para el pronóstico de demanda eléctrica. Los datos de consumo de energía presentan una relación con los factores meteorológicos, de tiempo y hasta tipo de clientes, es por todo esto que el consumo puede ser pronosticado.

Series de Tiempo: Este método, muy utilizado durante décadas en economía, procesamiento de señales, y hasta pronóstico de demanda, se basa en un supuesto en relación a los datos pasados. Estos datos históricos conservan una estructura interna, como la autocorrelación, tendencia y variación estacional. Los métodos de pronóstico en series de tiempo buscan y detectan estas estructuras. Las series de tiempo clásicas más usada son media móvil

autorregresiva (ARMA), media móvil integrada autorregresiva (ARIMA), media móvil autorregresiva con variables exógenas (ARMAX) y media móvil autorregresiva integrada (ARIMAX).

Redes Neuronales Artificiales (ANN): Las ANN tienen una gran variedad de aplicaciones consecuencia de su capacidad de aprendizaje. Además, en la literatura existen una gran variedad de arquitecturas de redes neuronales aplicadas al pronóstico de la demanda e.g., MLP, red auto organizada, Máquina de Boltzmann entre otras, la selección de cada una de estas será en base a la necesidad de los datos, y también a la capacidad computacional en el procesamiento. Una de la ventaja frente a los métodos clásico es que la gran mayoría de métodos en relación a la ANN no requieren modelos matemáticos de las cargas. En contra parte, un entrenamiento en la red puede predisponer de mucho tiempo. Para la comprensión estructural se dispone que las ANN son esencialmente circuitos no lineales que tiene la capacidad de realizar ajustes de curvas no lineales. Las salidas de una ANN son alguna función matemática lineal o no lineal de sus entradas. Las entradas pueden ser salidas de otros elementos de la red, así como las entradas de red reales. En la práctica las entradas de la ANN están compuestas de un número relativamente pequeño de capas conectadas de elementos de entradas y las salidas de la red. Algunas veces se utilizan rutas de retroalimentación.

Sistemas Expertos: Un pronóstico de cargas desarrolladas a base de reglas, a menudo mantiene una naturaleza heurística, esto con el objetivo de desarrollar precisión. Los sistemas expertos incorporan reglas y procedimientos utilizados por humanos expertos en el campo de interés de un software, y puede efectuar un pronóstico automático sin asistencia humana. El sistema de los expertos consiste en impartir información del humano experto hacia un sistema o software durante un período considerable de tiempo. El conocimiento debe ser apropiado para la codificación en las reglas del software. Un sistema experto codifica hasta cientos y miles de reglas de producción.

Lógica *fuzzy*: Esta es una generalización de la lógica Booleana habitual utilizada para el diseño de circuitos digitales. Dentro de las entradas de la Lógica fuzzy se asocia rangos cualitativos e.g., la carga de un transformador puede ser baja, media y alta. Debido a que la lógica nebulosa permite deducir las salidas de las entradas difusas, y se convierte en una técnica esencial para mapear. Entre las ventajas de este modelo se encuentra la ausencia de

necesidad de un modelo matemático que mapee a las entradas y a las salidas, también la ausencia de la necesidad de entradas precisas.

Máquinas de vectores de soporte (SVM): Su desarrollo se sienta a partir de la teoría del aprendizaje estadístico. SVM es un poderoso método que ayuda resolver problemas de clasificación y regresión. A diferencia de la ANN, que intentan definir funciones complejas del espacio de características de entrada, el SVM realiza un mapeo no lineal de un estado de espacio en alta dimensión. Después, las máquinas de soporte utilizan funciones lineales simples para crear límites de decisión en el nuevo espacio.

CAPÍTULO III

APLICACIÓN DE LAS TÉCNICAS DE MACHINE LEARNING AL PRONÓSTICO DE LA DEMANDA ELÉCTRICA

3.1 ¿En qué consiste *Machine Learning*?

Para introducir al concepto fundamental de *Machine Learning*, es primordial destacar el crecimiento y los avances acelerados en la rama de la tecnología de la información que actualmente la sociedad está atravesando, particularmente al ingreso de la humanidad a la era de la *Big Data* y *Data Science*. Este crecimiento se pone en evidencia por la siguiente pregunta ¿Cuánta información se sube, consume y procesa diariamente a la internet *e.g.*, Redes Sociales, Bancos, Bolsa de Valores e instituciones gubernamentales? Sin mencionar otros tipos de instituciones que gestan grandes bloques de información. Por lo tanto, partiendo de lo realmente tangible, en la sociedad es imprescindible la gestión de toda esa vasta información buscando herramientas de aprendizaje que permitan asociar datos, que a final de cuentas, se tornarán relevantes para una buena interacción sociedad-tecnología [28].

Machine Learning es una rama de la Inteligencia Artificial enfocada en el desarrollo de técnicas que permiten el aprendizaje de las máquinas. En particular, se define como un proceso computacional automático que permite inferir o generalizar un aprendizaje a partir de una base de datos. Dicho de otra forma, es un conjunto de métodos que tienen la capacidad de detectar patrones en los datos de forma automática, para luego usar estos patrones descubiertos que permita clasificar, predecir o realizar algún tipo de acción para la toma de decisiones en condiciones de incertidumbre. Teóricamente *Machine Learning* está compuesto por un conjunto de datos observados, un conjunto de parámetros característicos del sistema y un algoritmo de aprendizaje. Todas estas mencionadas constituyen de *Machine Learning*, una herramienta innovadora que permite minimizar errores de aprendizaje entre diversos modelos, para finalmente sin perder la generalización, obtener resultados eficientes procedentes del proceso de adaptación [28][29].

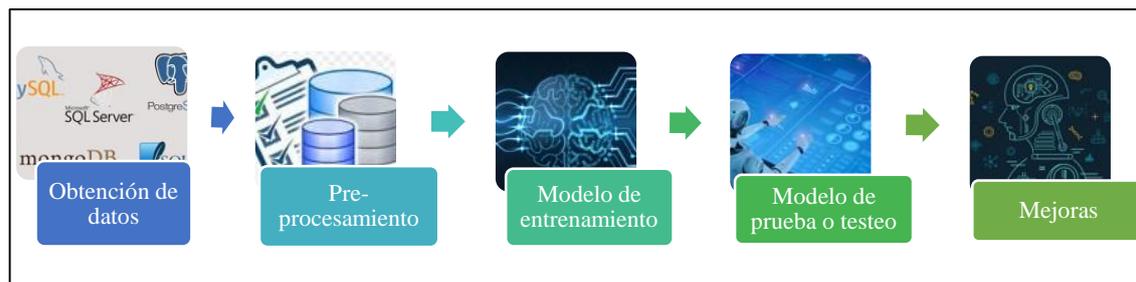


Fig. 3.1 *Machine learning*: Proceso de aprendizaje de las máquinas

(Fuente: Elaboración propia.)

3.2 Tipos de algoritmos de aprendizaje

3.2.1 Aprendizaje supervisado

El aprendizaje supervisado es conocido también en la literatura como el aprendizaje profesor. Consiste en la búsqueda de correspondencia entre las entradas y las salidas deseadas en un sistema. Este tipo de aprendizaje, asociado a un algoritmo, se alimenta con datos históricos de una muestra. Este algoritmo entrena y obtiene un modelo a partir de las muestras proporcionadas, luego del aprendizaje y por cuenta del entrenamiento, el modelo tiene la capacidad asociar datos en base a los históricos generando puntos nunca antes utilizados. Es a partir de lo mencionado, que se obtiene un alto rendimiento en cuanto a la clasificación o pronóstico [29].

Una visión más clara del concepto de aprendizaje supervisado se identifica notablemente en el proceso de la ANN explicadas en [30]. La definición aprendizaje supervisado o profesor está vinculado a un ente conocedor del entorno Fig. 3.2. Este conocimiento está representado por un conjunto de datos de muestra de entradas y salidas, es a partir de esta información que se desarrolla la definición sobre el profesor capaz de proporcionar respuestas deseadas a la ANN por medio de un vector de entrenamiento. El profesor y la ANN en primera instancia están desvinculados, la red es incapaz de asociar patrones de entradas y salidas; sin embargo, cuando el profesor interactúa con la red por medio del vector de entrenamiento, este proporciona la de información de la influencia combinada entre ese vector y la señal de error, lo que permitirá que los parámetros de la red sean ajustados de forma iterativa con la finalidad de que la red se emule al profesor hasta el punto de presidir su servicio, lo mismo que completar el aprendizaje.

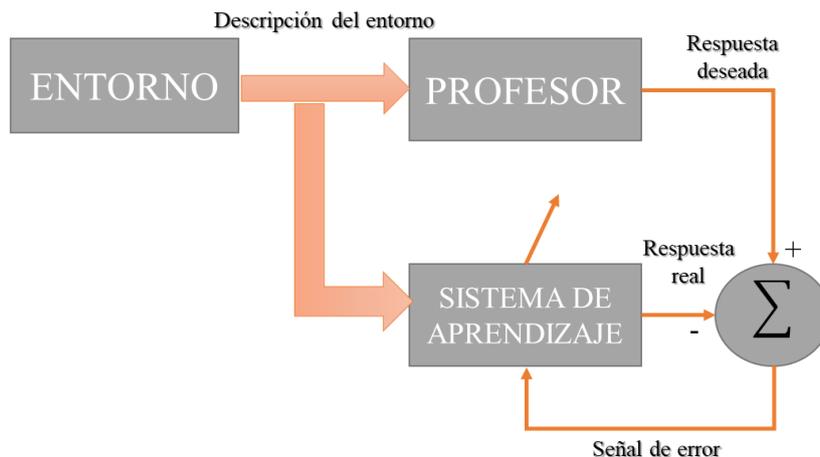


Fig. 3.2 Diagrama de bloque del aprendizaje supervisado.

(Fuente: Adaptación de *Neural networks and learning machines*)

3.2.2 Aprendizaje no supervisado

El aprendizaje no supervisado es conocido también como el aprendizaje auto-organizado, desafortunadamente, comparado con el supervisado, carece de un profesor externo que imposibilita la supervisión del proceso de aprendizaje Fig. 3.3. Sin embargo, se genera las condiciones de calidad en la medición a la que la red debe aprender, es de esta forma que sus parámetros son optimizados. Una vez realizado el ajuste, se desarrolla la habilidad de generar representaciones internas para codificar la características de la entradas, consecuentemente, crear nuevas clases.

Una de las reglas del aprendizaje no supervisado es el aprendizaje competitivo *winners-take-all*. En un contexto de ANN, por ejemplo, se propone una red con dos capas, una de entrada y la otra de competencia. La capa de entrada recibe los datos disponibles, mientras que la competitiva desarrolla una contienda entre las neuronas para satisfacer las características contenidas en la entrada. Finalmente, las neuronas con mayor entrada total ganan la competencia y son activados, mientras las perdedoras son desactivadas [30].

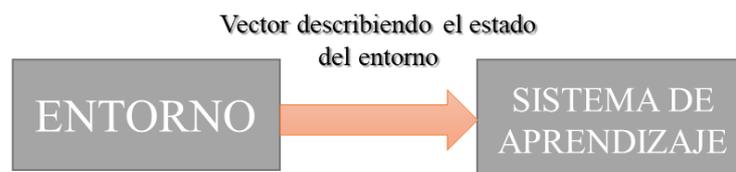


Fig. 3.3 Diagrama de bloque del aprendizaje no supervisado.

(Fuente: Adaptación de *Neural networks and learning machines*)

3.2.3 Aprendizaje por refuerzo

Este tercer aprendizaje conocido como aprendizaje por refuerzo es el que se usa con menor frecuencia. Es útil para aprender a comportarse cuando el entorno proporciona señales ocasionales de recompensa o castigo, el mapeo de la entrada y salida es realizada a través de la interacción continua con el entorno, intentando minimizar un índice escalar de desempeño [30].

En la Fig. 3.4 el sistema de aprendizaje por refuerzo es realizado alrededor del crítico, el cual tiene la función de convertir la señal de refuerzo primario en una de mejor calidad, refuerzo heurístico. Este sistema puede también ser diseñado para aprender el refuerzo atrasado, lo que traduce en la observancia de la secuencia temporal de estímulos decepcionados del ambiente, resultando en una señal de refuerzo heurístico. El objetivo de este aprendizaje es minimizar una función de costo el cual se acumula a lo largo de una secuencia de pasos.

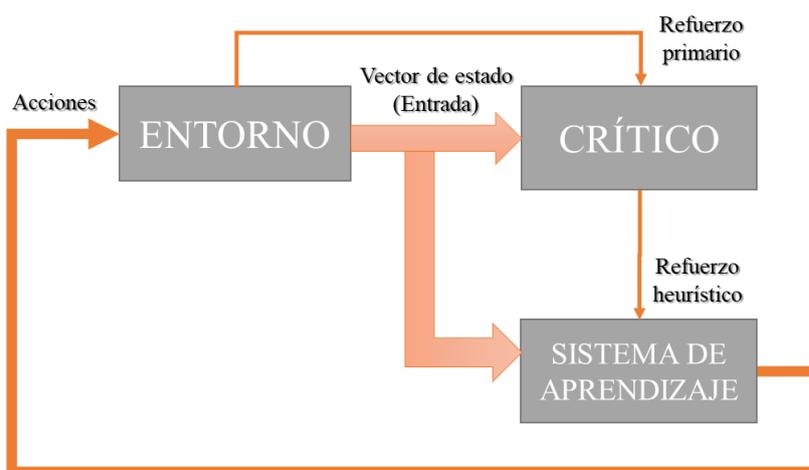


Fig. 3.4 Diagrama de bloque del aprendizaje por Refuerzo.

(Fuente: Adaptación de *Neural networks and learning machines*)

3.3 Sistemas Inteligentes

Los sistemas inteligentes son programas computacionales que agrupan características inteligibles comparadas al de la inteligencia humana. El sistema completo permite almacenar la información del entorno a partir de dispositivos electrónicos *e.g.*, medidores, sensores para de esa forma, aprender de su propia experiencia. Por un tema particular del desarrollo de la tesis, se expondrá los sistemas de las redes neuronales artificiales y la lógica nebulosa.

3.3.1 Redes neuronales artificiales

El sistema Nervioso

La habilidad de actuar, comprender y reaccionar frente a un aliciente en el medio ambiente es asignada al funcionamiento integrado de nuestro sistema nervioso. Este es un conjunto de tejidos conformado por células altamente especializadas, responsables por recibir información, procesarlas para finalmente generar una respuesta física a un determinado estímulo. Es por ese motivo que en el trabajo del sistema nervioso, apoyado por el sistema endocrino, además de generar una comprensión de la realidad, hace posible una respuesta de alta precisión por parte del cuerpo sometiéndolo a cambios dinámicos frente al medio [31].

Según [31], el sistema nervioso está dividido en el sistema nervioso central y periférico. El sistema nervioso central se encuentra dentro de la estructura ósea localizado en el cráneo y el canal vertebral, está compuesto por la medula espinal y el encéfalo. El sistema periférico incluye nervios craneales y espinales aportando de esta forma la conducción de los impulsos nerviosos sensitivos hacia el sistema nervioso central. Una explicación más plausible al sistema nervioso se encuentra en las divisiones anatómicas como el cerebro, medula espinal, entre otras para recibir y procesar información recogidas por el sistema periférico, y además de administrar las funciones motoras del cuerpo humano.

Una neurona biológica

La neurona es definida como la unidad básica del sistema nervioso Fig. 3.5, transporta impulsos eléctricos a través del cuerpo por medio de una comunicación celular. Ese proceso está basado en el intercambio de información entre axones y dendritas. El axón es una extensión citoplasmática que transfiere los impulsos nerviosos fuera del cuerpo celular, generalmente conocido como sinapsis, y las dendritas transfieren impulsos hacia el cuerpo celular.

Debido a las variaciones estructurales y funcionales de las neuronas biológicas *e.g.*, tamaño del cuerpo celular, el tamaño del axón, el número de ramas de los terminales de los axones e impulsos generados, es necesario clasificarlas para su mayor comprensión.

Estructuralmente, las neuronas se describen comúnmente como unipolares, bipolares y multipolares. La clasificación está muy relacionada con los procesos que se propagan en el cuerpo celular, es decir que la neurona unipolar tiene un solo proceso, la bipolar dos neuronas y la neurona multipolar varios.

Según la función, hay tres clases de neuronas que son las sensibles o aferentes, motoras o eferentes y la tercera clase consta de neuronas que están limitadas por completo dentro del sistema nervioso central. Las neuronas aferentes transportan impulsos desde la piel u otros órganos sensoriales hacia el sistema nervioso central. Las neuronas eferentes sacan impulsos del sistema nervioso central, las glándulas y los músculos [31].

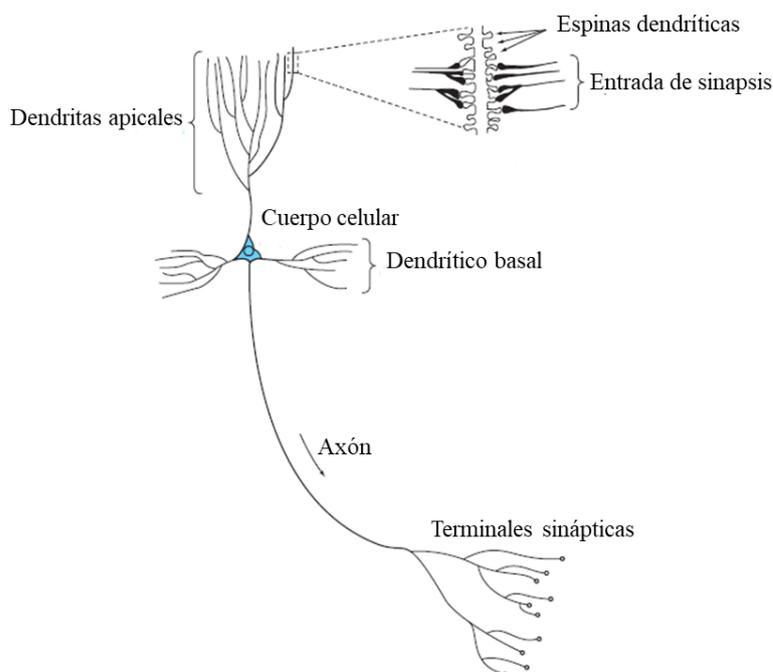


Fig. 3.5 Representación simplificada de una neurona biológica.
(Fuente: Adaptación de *Neural networks and learning machines*)

Una neurona artificial

Algunas definiciones básicas sobre las ANN comenzaron hace un siglo, conocido según [32] como la edad de Camelot. En ese entonces, William James, uno de los más renombrados psicólogos de Norteamérica, realizó una publicación sobre la estructura del cerebro y sus funciones, la cual declaró los principios básicos de la memoria asociativa y el aprendizaje correlacionado. En esta la publicación, *Principios de la Psicología*, James parece tener una percepción de la actividad de una neurona *e.g.*, la noción de esta actividad comienza con la suma de las entradas, adicionalmente con una historia de correlación pasada que contribuye al peso de las interconexiones.

A mediados del siglo XX, McCulloch y Pitts publicaron un artículo trascendental sobre las redes neuronales [33], teoremas que derivan de modelos de sistemas neuronales basados en el conocimiento de estructuras biológicas, declarando cinco supuestos físicos para sustentar

las conclusiones . El quinto supuesto, la estructura de la red no cambia con el tiempo, sigue siendo válido porque durante el entrenamiento con el algoritmo de *backpropagation* y *self-organizing* la estructura no cambia [32].

El modelo McCulloch-Pitts es uno de los modelos más utilizados principalmente en problemas de reconocimiento de patrones. Considerando una neurona como la unidad de procesamiento de información relevante para el funcionamiento de una red neuronal, la Fig. 3.6 describe una neurona cuya suma v_k es la suma de las m entradas $[X = (x_1, x_2, \dots, x_m)]$ ponderadas por sus respectivos pesos $[W = (w_{k1}, w_{k2}, \dots, w_{km})]$. Esta actividad alimenta una función de activación que produce una señal que se enviará a las otras neuronas.

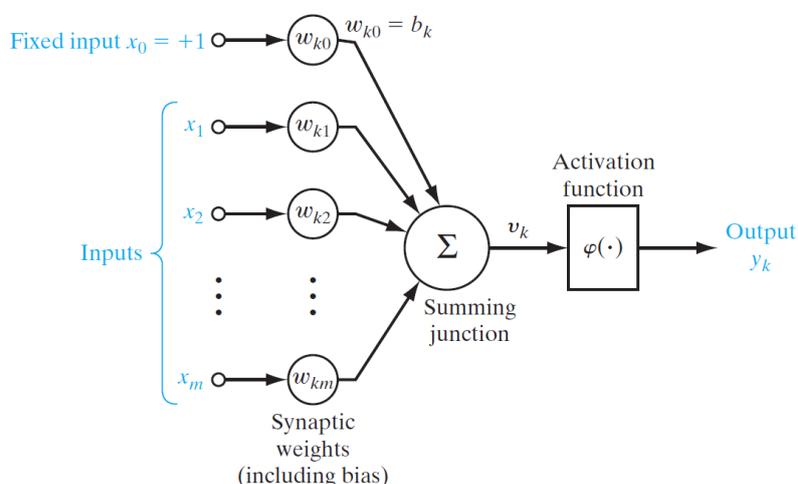


Fig. 3.6 Neurona no lineal.

(Fuente: Adaptación de *Neural networks and learning machines*)

Además, la neurona puede contener un peso de polarización w_{k0} alimentado por una constante $x_0 = +1$ que realiza el control de salida de la neurona. La descripción matemática de una neurona se establece mediante las ecuaciones (3.1) e (3.2).

$$v_k = \sum_{j=0}^m x_j w_{kj} \quad (3.1)$$

$$y_k = \varphi(v_k) \quad (3.2)$$

La función de activación se define como una función lineal o restrictiva, su trabajo es procesar y definir la salida de una neurona. En un esquema de salida, normalmente la neurona normalizada está en un rango cerrado de 0 a 1 o alternativamente de -1 a 1 [30].

Hay que saber que las funciones restrictivas más utilizadas son las funciones: lineal (1), umbral (2), escalón (3), lineal por parte (4), sigmoidea (5) y gaussiana (6).

1. Función lineal

$$\varphi(v) = \alpha v \quad (3.3)$$

2. Función umbral

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3.4)$$

3. Función escalón

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ -1, & \text{se } v \leq 0 \end{cases} \quad (3.5)$$

4. Función lineal por parte

$$\varphi(v) = \begin{cases} 1, & v \geq \frac{1}{2} \\ v, & \frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (3.6)$$

5. Función sigmoidea

La función sigmoidea es una de las funciones de activación que se utilizan a menudo en las redes neuronales artificiales. Una de las características es que es estrictamente creciente, mostrando un comportamiento lineal y no lineal.

a) Sigmoidea 1

$$\varphi(v) = \frac{1 - e^{-\lambda v}}{1 + e^{-\lambda v}} \quad (3.7)$$

b) Sigmoidea 2

$$\varphi(v) = \frac{1}{1 + e^{-\lambda v}} \quad (3.8)$$

6. Función gaussiana

$$\varphi(v) = ae^{-\frac{(v-b)^2}{2c}} \quad (3.9)$$

Siendo:

- a: Pico de la función gaussiana;
- n: Centro del pico de la función gaussiana;
- c: Ancho de la función gaussiana.

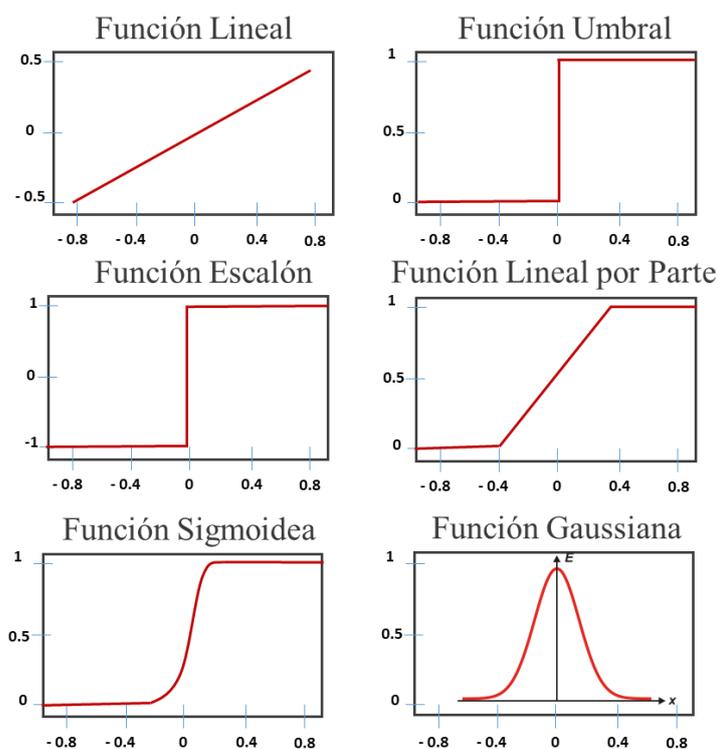


Fig. 3.7 Funciones de activación.

(Fuente: Elaborado por el autor)

Estructura de las redes neuronales

La estructura de las redes neuronales se puede subdividir en tres categorías básicas, no recurrentes de una sola capa, no recurrente de varias capas y recurrentes [30]. A pesar de no tener la misma estructura, la misma filosofía y obedecer los mismos principios, comparten las mismas características, la característica importante de una red neuronal, la capacidad de

aprender. El aprendizaje es la capacidad de las redes neuronales para ajustar los parámetros internos a través de una estrategia de entrenamiento. Además, dependiendo de la estructura básica en la elección del análisis de datos, la red está íntimamente ligada con el algoritmo de aprendizaje que puede ser supervisado o no supervisado.

Las redes neuronales no recurrentes se definen como redes que carecen de bucles de retroalimentación. En esta topología, las neuronas de una capa reciben información solo de la capa anterior. En la Fig. 3.8 hay una representación de la capa única, para este caso la red tiene cuatro nodos de entrada y el mismo número en la salida, cabe mencionar que no se tiene en cuenta la capa de entrada de los nodos fuente, porque no realizar cualquier actividad de tratamiento.

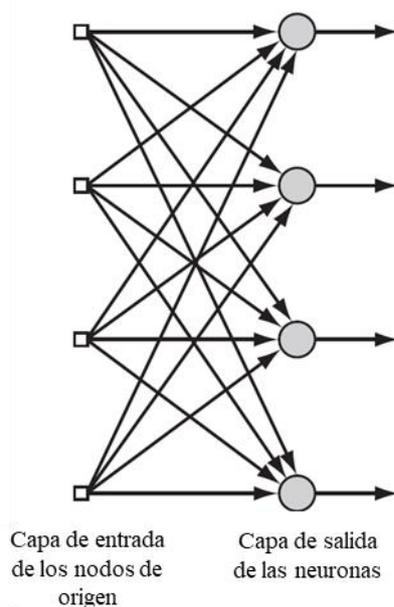


Fig. 3.8 Red no recurrente de una sola capa.

(Fuente: Adaptación de *Neural networks and learning machines*)

Las redes no recurrentes de varias capas se diferencian de la única por la existencia de una o más capas ocultas. La capacidad de las capas ocultas para intervenir entre las entradas y las salidas hace que la red sea capaz de extraer estadísticas de alto orden y sea especialmente valiosa cuando la capa de entrada es grande. La red de la Fig. 3.8 está completamente conectada, ya que todos los nodos de la capa están conectados con los nodos de las capas adyacentes, caso contrario, se diría que la red está parcialmente conectada [30].

La red neuronal recurrente se caracteriza porque hay al menos un bucle de retroalimentación dentro de su estructura. Hay dos formas básicas de aplicar la retroalimentación en la red, la

global que se dirige a toda la red y la local a nivel de una sola neurona en la red. Las redes recurrentes, como las de alimentación directa, se pueden construir en una capa o en varias capas como Fig. 3.9.

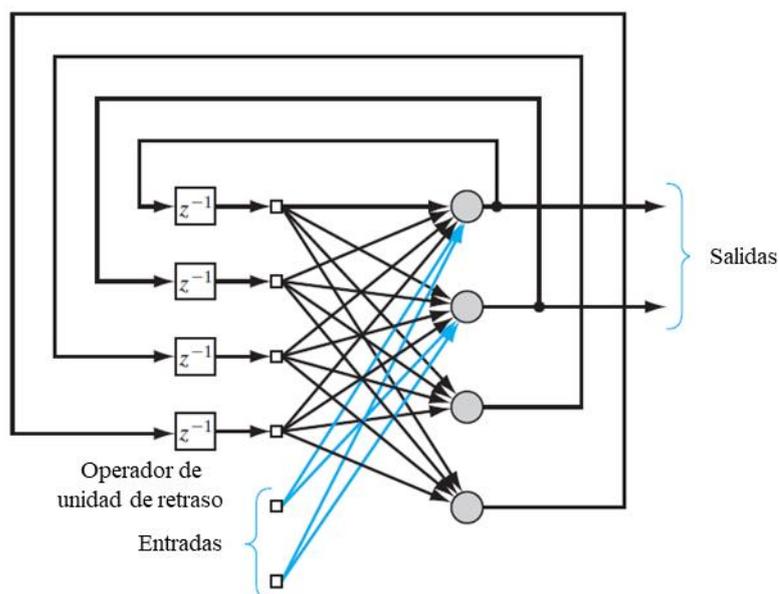


Fig. 3.9 Red recurrente con neuronas ocultas.

(Fuente: Adaptación de *Neural networks and learning machines*)

3.3.2 La lógica *Fuzzy* (Nebulosa)

La lógica *fuzzy* conocida también como nebulosa o difusa nace de la necesidad de aproximar las decisiones tomadas por las máquinas a las humanas, especialmente al trabajar con informaciones inciertas e imprecisas [34]. Esta lógica de Zadeh representa, de una forma adecuada, la lingüística y la inteligencia humana partiendo de la premisa de que las palabras explican mejor diversos fenómenos comparadas con las matemáticas. Para representar mejor el pensamiento humano, la lógica *fuzzy* es sustentada por la lógica multivalorada, las ANN, teorías probabilísticas, inteligencia artificial.

Teoría de Conjuntos

En la teoría clásica de conjuntos se define la pertenencia de un elemento, o no, a un determinado conjunto A en base a la siguiente función característica:

$$f_A(x) = \begin{cases} 1 & , x \in A \\ 0 & , x \notin A \end{cases} \quad (3.10)$$

Se observa de la función que el universo está constituido por el conjunto $\{0,1\}$, la cual asume valores discretos y está dividido en dos fronteras definidas.

En la teoría de conjuntos *fuzzy*, la función característica es generalizada, pudiendo asumir un número infinito de valores en el intervalo $[0,1]$ de la función de pertinencia. Un conjunto A en un universo X es definido por una función de pertinencia.

$$\mu_A(x): X \rightarrow [0,1] \quad (3.11)$$

x : Elemento x ;

X : Universo de discurso;

A : Conjunto difuso;

μ : Función de pertinencia;

De la ecuación (3.11) puede distinguirse que la función de pertinencia está asociada a cada elemento x , pertenece a X un número real $\mu_A(x)$ en el intervalo $[0,1]$, el cual representa el grado de pertinencia del elemento x en el conjunto A . En diversas ocasiones, las situaciones del mundo real no son verdaderas y no pueden ser descritas con precisión, existen expresiones de incertezas *e.g.*, regular, más o menos, bueno, excelente, y son llamadas de difusas. Las función que caracteriza a un conjunto difuso A en un universo X , que asocia cada punto de X con un número real en el intervalo $[0,1]$, se conoce como función de pertinencia.

Cabe indicar que no existe una regla específica para definir una función de pertinencia. En la gran mayoría de veces depende del problema a ser abordando, pudiéndose determinar de forma heurística y subjetiva. Las funciones de pertinencia más utilizadas son la triangular, trapezoidal, gaussiana y de forma de campana.

Operaciones entre conjuntos *Fuzzy*

Las operaciones entre conjunto *fuzzy* están definidos de la siguiente forma.

- Unión:

$$A \cup B \leftrightarrow \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x), \text{ para } \forall x \in X \quad (3.12)$$

- Intersección:

$$A \cap B \leftrightarrow \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x), \text{ para } \forall x \in X \quad (3.13)$$

- Complemento:

$$\mu_{\sim A}(x) = 1 - \mu_A(x), \text{ para } \forall x \in X \quad (3.14)$$

Propiedades de las operaciones

- Involutiva:

$$(A^c)^c = A \quad (3.15)$$

- Conmutativa:

$$A \cup B = B \cup A \quad (3.16)$$

$$A \cap B = B \cap A \quad (3.17)$$

- Asociativa:

$$(A \cup B) \cup C = A \cup (B \cup C) \quad (3.18)$$

$$(A \cap B) \cap C = A \cap (B \cap C) \quad (3.19)$$

- Distributiva:

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C) \quad (3.20)$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C) \quad (3.21)$$

- Idempotencia:

$$A \cup A = A \quad (3.22)$$

$$A \cap A = A \quad (3.23)$$

- Absorción:

$$A \cup (A \cap B) = A \quad (3.24)$$

$$A \cap (A \cup B) = A \quad (3.25)$$

- Identidad:

$$A \cup \emptyset = A \quad (3.26)$$

$$A \cap X = A \quad (3.27)$$

Funciones de pertinencia

Las funciones de pertinencia son descripciones de los conjuntos difusos, consecuencia de las diferentes interpretaciones lingüísticas que podría almacenar una variable *e.g.*, la variable temperatura Fig. 3.10 puede tener estados como fría, fresca, moderada, caliente, muy caliente.

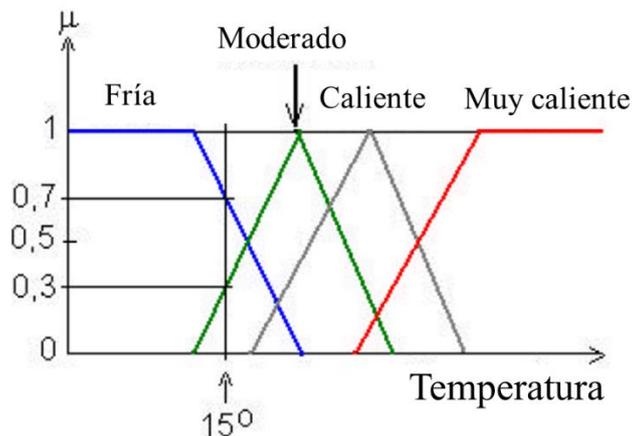


Fig. 3.10 Función triangular característica de un conjunto difuso Temperatura.

(Fuente: Elaboración propia.)

Las ideas mencionadas sobre los estados están sujetas a diferentes interpretaciones *e.g.*, ¿qué es caliente comparado con muy caliente, o tal vez con un extremadamente caliente? Por lo tanto, la forma de interpretación de esas descripciones se conoce como funciones de pertinencia, las cuales pueden adquirir diferentes formas como triangular, gaussiana, trapezoidal y campana.

- Triangular

$$f(x; a, b, c) = \begin{cases} 0 & x \leq a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ \frac{c-x}{c-b} & b \leq x \leq c \\ 0 & x \geq c \end{cases} \quad (3.28)$$

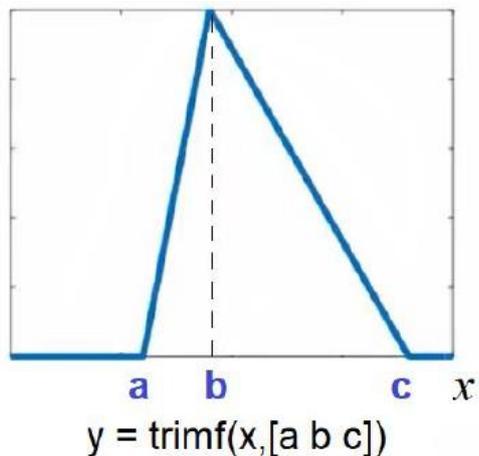


Fig. 3.11 Función de pertinencia Triangular

(Fuente: Elaboración propia.)

- Gaussiana

$$f(x; \sigma, x_0) = e^{-\frac{1}{2}\left(\frac{x-x_0}{\sigma}\right)^2} \quad (3.29)$$

σ : Controla el ancho de la campana; x_0 : posición del centro de la campana

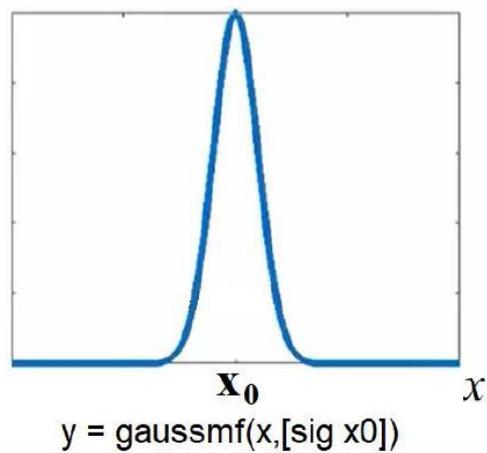


Fig. 3.12 Función de pertinencia Gaussiana

(Fuente: Elaboración propia.)

- Trapezoidal

$$f(x; a, b, c, d) = \begin{cases} 0 & x \leq a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1 & b \leq x \leq c \\ \frac{d-x}{d-c} & c \leq x \leq d \\ 0 & x \geq d \end{cases} \quad (3.30)$$

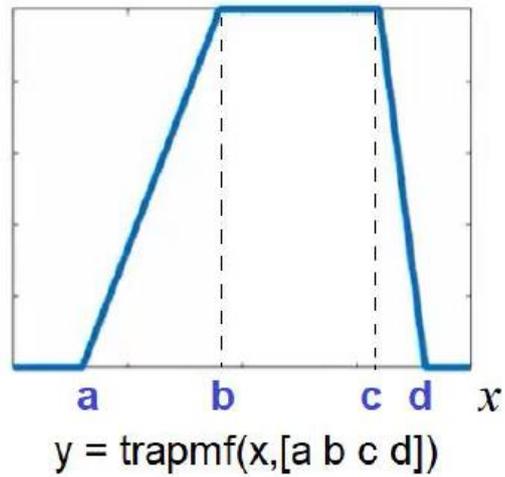


Fig. 3.13 Función de pertenencia Trapezoidal
(Fuente: Elaboración propia.)

- Campana Generalizada

$$f(x; a, b, x_0) = \frac{1}{1 + \left| \frac{x - x_0}{a} \right|^{2b}} \quad (3.31)$$

a : Ancho de la función; b : Pendiente; x_0 : posición del centro de la campana

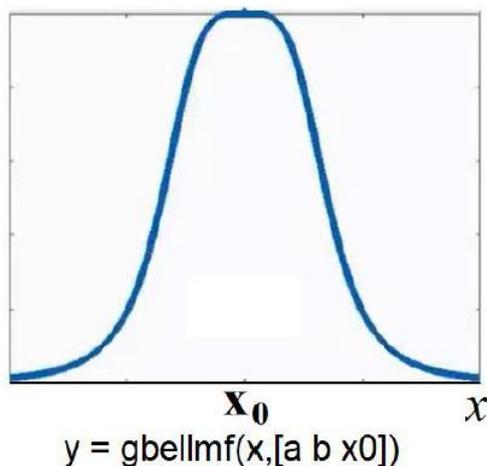


Fig. 3.14 Función de pertinencia Campana

(Fuente: Elaboración propia.)

3.4 Teoría de la resonancia adaptativa (ART)

La teoría de la resonancia adaptativa (*Adaptive Resonance Theory* - ART) desarrollada por Gail Carpenter y Stephen Grossberg propone una solución al dilema de la plasticidad y estabilidad que enfrentan los diseñadores de sistemas de aprendizaje [35]. El primer término, plasticidad, está referido a la capacidad de la red neuronal para adquirir conocimientos sin perder información previamente ya aprendida, y la estabilidad es la capacidad de aprender sometido a un proceso de adaptación de pesos por medio del parámetro de test de vigilancia. Por tanto, las redes ART son respuestas a los patrones arbitrarios de entradas desarrolladas con el fin de codificar reconocimientos estables, en tiempo real, utilizando como base la auto-organización. Además, los principios planteados en la solución del problema de plasticidad-estabilidad, ocurre en función del aprendizaje por correspondencia, el aprendizaje basado en el error y el aprendizaje rápido y estable.

3.4.1 Red neuronal ARTMAP

Es una arquitectura de red neuronal propuesta por Carpenter *et al.* [36] basado en un aprendizaje supervisado. Esta red tiene la capacidad de aprender a clasificar de forma automática vectores ordenados arbitrariamente en categorías de reconocimiento basados en éxitos predictivos.

El tipo de algoritmo de entrenamiento de ARTMAP ocurre de forma supervisada tomando como base la estructura de los módulos ARTa y ARTb. Durante el proceso de entrenamiento, a grandes rasgos, el módulo ARTa es responsable por la recepción de los vectores de entrada $\{a^{(p)}\}$ mientras que ARTb recibe como entrada $\{b^{(p)}\}$, donde $\{b^{(p)}\}$ viene a ser la predicción

correcta para el patrón $\{a^{(p)}\}$. Estos dos módulos al trabajar de forma conjunta, son vinculados a una red aprendizaje asociativo y un control interno que asegura el funcionamiento autónomo del sistema en tiempo real mediante el concepto de inter-ART, tercer módulo.

El tercer módulo, conocido como inter-ART, se encarga de analizar la correspondencia y/o compatibilidad entre los patrones de entrada y salida esperada, mencionada anteriormente, operación denominada como *match tracking*. Este mecanismo de operación posee la función de maximizar las generalizaciones, y al mismo tiempo, minimizar el error. Al realizar un pronóstico errado, vía esta conexión asociativa instruida, el parámetro de vigilancia que se encarga de la selectividad en el módulo ARTa, es aumentado progresivamente hasta un grado que sea posible atender una corrección del error, para así satisfacer una categoría de predicción coincidente en el módulo ARTb.

3.4.2 Red neuronal ARTMAP Fuzzy

De forma análoga a la red ARTMAP, la arquitectura ARTMAP *Fuzzy* es una red de aprendizaje incremental supervisado aplicado al reconocimiento de categoría y mapas multidimensionales en respuesta a una secuencia arbitraria de vectores de entrada analógica o binaria, esto debido a su capacidad de representar conjuntos difusos y convencionales [37].

La estructura que compone la red ARTMAP *Fuzzy* está constituida por los módulos ARTa y ARTb, los cuales son formados por componentes ART nebulosos [38], diferentes al ARTMAP tratado anteriormente [36], que crean categorías de reconocimiento estable en respuesta a secuencias arbitrarias de patrones de entrada .

La arquitectura mostrada en la Fig. 3.15 representa a ARTMAP *Fuzzy*, el cual está dividido en un sistema ARTa y ARTb, cada sistema está constituido por tres campos: un campo F_0 formado por nodos que representan el vector de entrada, un campo F_1 alimentado por las entradas *bottom-up* del campo F_0 y por las entradas *top-down* del campo F_2 que representa la categoría activa.

El vector I perteneciente al campo F_0 , conserva los valores ya normalizados dentro del intervalo de $[0; 1]$.

$$I = [I_1 \ I_2 \ \dots \ I_{2M}] \quad (3.32)$$

Las actividades de los campos F_1 y F_2 es representado por los vectores x y y , respectivamente.

$$x = [x_1 \ x_2 \ \dots \ x_{2M}] \tag{3.33}$$

$$y = [y_1 \ y_2 \ \dots \ y_{2M}] \tag{3.34}$$

Para el módulo ARTa, $x^a = [x_1^a \ \dots \ x_{2Ma}^a]$ denota el vector de salida del campo F_1^a ; $y^a = [y_1^a \ \dots \ y_{2Na}^a]$ denota el vector de salida del campo F_2^a y $w_j^a = [w_{j1}^a \ \dots \ w_{j,2Ma}^a]$ denota el j -ésimo vector peso. Para el módulo ARTb, $x^b = [x_1^b \ \dots \ x_{2Mb}^b]$ denota el vector de salida del campo F_1^b ; $y^b = [y_1^b \ \dots \ y_{2Nb}^b]$ denota el vector de salida del campo F_2^b y $w_k^b = [w_{k1}^b \ \dots \ w_{k,2Mb}^b]$ denota el k -ésimo vector peso. Para el mapa el campo, $x^{ab} = [x_1^{ab} \ \dots \ x_{Nb}^{ab}]$ denota el vector de salida del campo F_{ab} y $w_j^{ab} = [w_{j1}^{ab} \ \dots \ w_{j,Nb}^{ab}]$ denota el vector peso que parte del j -ésimo nodo de F_2^a para F^{ab} .

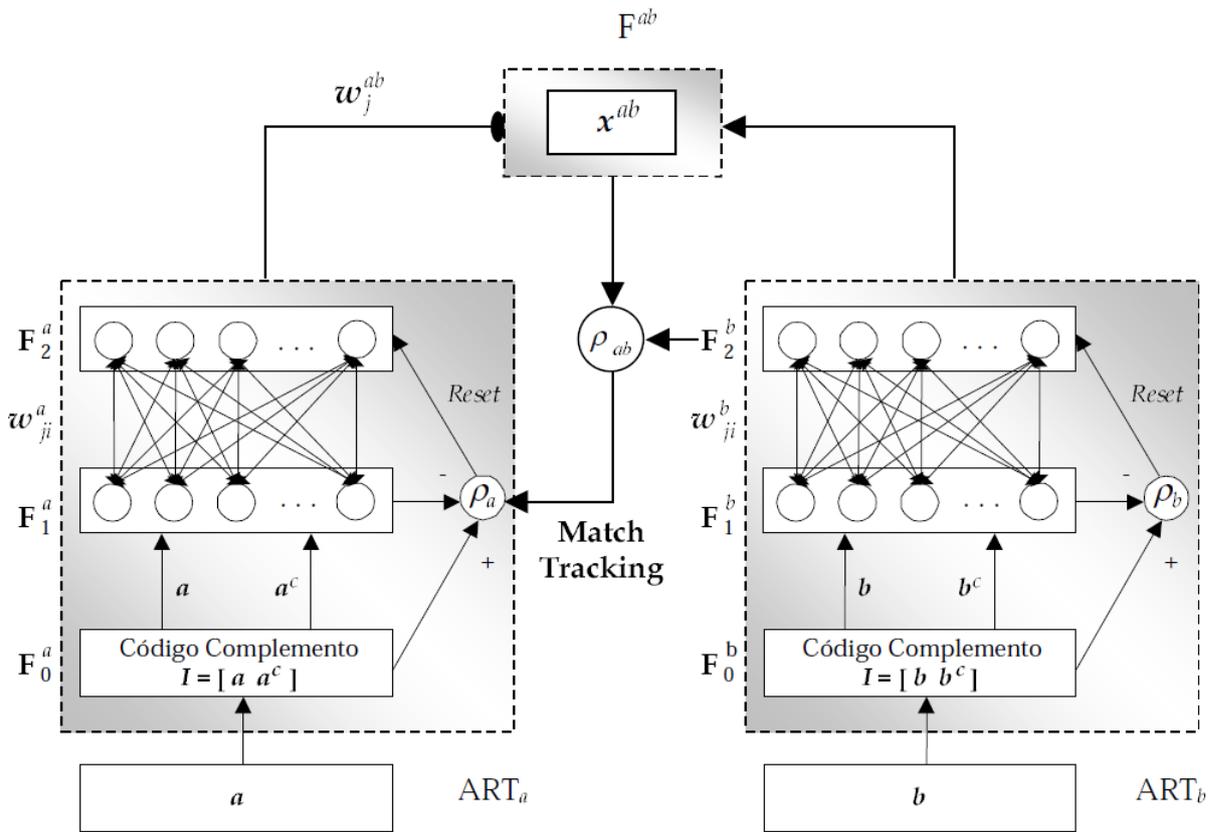


Fig. 3.15 Arquitectura ARTMAP Fuzzy

(Fuente: Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica)

Parámetros ARTMAP *Fuzzy*

La estructura de la red neuronal ARTMAP *Fuzzy* está constituida por diversos parámetros los cuales deben ser ajustados de forma previa. Los parámetros guardan una relación intrínseca con el problema, es de esta forma que juegan un papel relevante en relación a la velocidad del aprendizaje, a la eficiencia y eficacia del sistema.

1. Parámetro de selección (α): La función de este parámetro es controlar la secuencia de búsqueda entre los nodos de la capa F_2 , su valor debe ser positivo $\alpha > 0$.
2. Tasa de entrenamiento (β): El intervalo de trabajo está Incluida entre $[0; 1]$, es responsable de la velocidad de adaptación de los pesos en la red. Cuanto menor sea el valor asignado al parámetro, más lento será el proceso de aprendizaje.
3. Parámetro de vigilancia (ρ): Este parámetro comprendido en el intervalo $[0; 1]$ es responsable por controlar la resonancia en la red. Comprueba la compatibilidad de los patrones de entrada y los pesos para que se produzca la resonancia. Está directamente relacionado con el número de categorías creadas Fig. 3.16. Cuanto mayor sea el valor asignado al parámetro, mayor será el número de categorías creadas, sin embargo, menor será la capacidad de generalización de la red. El análisis de la ocurrencia de resonancia, llamado también criterio de vigilancia, se aplica en el módulo ARTa (ρ_a), en el módulo ARTb (ρ_b) y en el módulo interART (ρ_{ab})

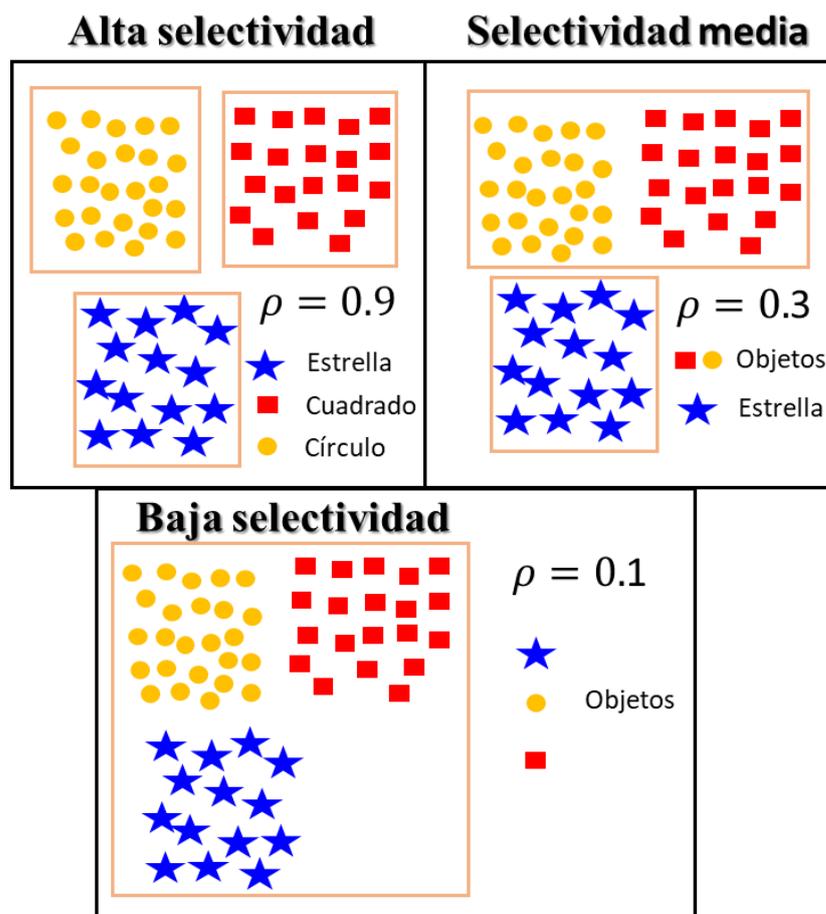


Fig. 3.16 Efecto del parámetro de vigilancia en el entrenamiento de la red neuronal ART.

(Fuente: Autor propio)

3.4.3 Algoritmo de entrenamiento para ARTMAP Fuzzy

El funcionamiento de la red neuronal ARTMAP Fuzzy, para el pronóstico de la demanda eléctrica, está sustentado en las siguientes fases: Fase de entrenamiento y fase del análisis. La fase de entrenamiento consiste en la adaptación de los pesos, teniendo en consideración los diferentes patrones proporcionados por una base de datos. Estos patrones son utilizados tanto en la entrada y salida de la red neuronal. El de entrada, de manera independiente, es utilizado para el tipo de entrenamiento no supervisado, en contraste con el supervisado que utiliza patrones tanto en la entrada y salida. La fase del análisis consiste en un proceso de evaluación del desempeño de la red basado en alguna métrica de comparación de datos reales con los pronosticados.

El proceso de entrenamiento o adaptación de los pesos es un proceso que sigue una secuencia de pasos, este se desarrolla en base al siguiente algoritmo:

Lectura de patrones de entrada

Los vectores de entrada $a = [a_1 a_2 a_3 \dots a_{Ma}]$ y $b = [b_1 b_2 b_3 \dots b_{Ma}]$, respectivamente, so pre-procesados usando la técnica de normalización y codificación por complemento.

La normalización es utilizada para evitar la proliferación de categorías.

$$\bar{a} = \frac{a}{|a|} \quad (3.35)$$

Siendo:

\bar{a} : Vector de entrada normalizada y $|a|$ la norma definida por la siguiente ecuación.

$$|a| = \sum_{i=1}^M a_i \quad (3.36)$$

La codificación es realizada con el fin de preservar la amplitud de la información.

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (3.37)$$

Siendo:

\bar{a}_i^c : Complemento normalizado.

El pre-procesador del complemento, transforma un vector de M dimensiones a un vector de 2M-dimensional, representado por la siguiente forma.

$$I = A = [\bar{a}_i \bar{a}_i^c] = [\bar{a}_1 \bar{a}_2 \dots \bar{a}_M \bar{a}_1^c \bar{a}_2^c \dots \bar{a}_M^c] \quad (3.38)$$

Iniciación de pesos

La inactividad de la categoría es representada por pesos unitarios, este valor se irá adaptando conforme a la ejecución entrenamiento en la red. La disminución de este valor, a medida que se realice el entrenamiento, determinará la actividad de la categoría. Los pesos iniciales son presentados por la siguiente forma

$$w_{j1}^a(0) = w_{k1}^b(0) = w_j^{ab}(0) = 1 \quad (3.39)$$

Lectura de parámetros

El rendimiento de los módulos ART *fuzzy* depende de la elección de tres parámetros: parámetro de selección, tasa de entrenamiento, y el parámetro de vigilancia.

Selección de categorías

Para cada entrada I y nodo j de F_2 , la función de selección es definida por

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (3.40)$$

Siendo definido a \wedge como el operador nebuloso AND, por:

$$(p \wedge q)_i = \min(p_i, q_i) \quad (3.41)$$

Y la norma $|\cdot|$, definida por:

$$|p| = \sum_{i=1}^M |p_i| \quad (3.42)$$

Para cualquier vector M -dimensional p y q .

Una categoría es escogida si y solamente si un nodo de F_2 se activa en un determinado instante. La elección de esta activación es almacenada e indicada en el índice J .

$$T_j = \max\{T_j: j = 1, 2, 3 \dots N\} \quad (3.43)$$

El vector de actividad $y = [y_1 y_2 y_3 \dots y_N]$ de la capa F_2 , presenta N cantidades de categorías creadas. Es así que la que para la categoría j -ésima se tiene:

$$y_j = \begin{cases} 1, & \text{si } j = J \\ 0, & \text{si } j \neq J \end{cases} \quad (3.44)$$

En un sistema de elección, el vector de actividad F_1 , denotado como $x = [x_1 x_2 x_3 \dots x_{2M}]$, atiende el siguiente criterio.

$$x = \begin{cases} I, & \text{si } F_2 \text{ es inactivo} \\ I \wedge w_j, & \text{si } F_2 \text{ es activo} \end{cases} \quad (3.45)$$

Test de Vigilancia

Este test tiene la función de identificar sobre la existencia de resonancia o no en el sistema. La resonancia ocurre en relación a la correspondencia de la categoría escogida para atender el criterio de vigilancia, mediante:

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (3.46)$$

Caso no sea satisfecha esta correspondencia, representado por:

$$\frac{|I \wedge w_j|}{|I|} < \rho \quad (3.47)$$

Se activará un dispositivo llamado *reset*, el cual atribuye un valor 0 para la categoría T_j que no consiguió la correspondencia. Posteriormente se realizará una nueva selección de aplicando la ecuación $T_j \max$. Este proceso se repetirá hasta satisfacer el criterio de vigilancia, ecuación (3.46).

Aprendizaje

El aprendizaje de la red es efectuado mediante el proceso de modificación de los pesos, evento sucedido después de efectuarse la resonancia en el inter-ART. Los pesos se actualizan de la siguiente manera:

$$w_j^{nuevo} = \beta(I \wedge w_j^{Antiguo}) + (1 - \beta)w_j^{Antiguo} \quad (3.48)$$

La tasa de entrenamiento β controla la velocidad como se adaptan los pesos. Para el β más alto, el sistema tendrá un rápido aprendizaje, este parámetro está limitado al siguiente rango $0 < \beta < 1$.

3.5 Sistema adaptativo *Neuro-Fuzzy* (ANFIS)

3.5.1 Arquitectura ANFIS

La red presentada se asemeja a una *perceptron* de múltiples capas, y está desarrollada en base a la regla de inferencia *fuzzy Takagi-Sugeno* (T-S) [39][40]. Esta arquitectura está dividida en cinco capas interconectadas por medio de pesos unitarios, cada uno es responsable de la propagación de información, tarea que será realizada hasta la última capa.

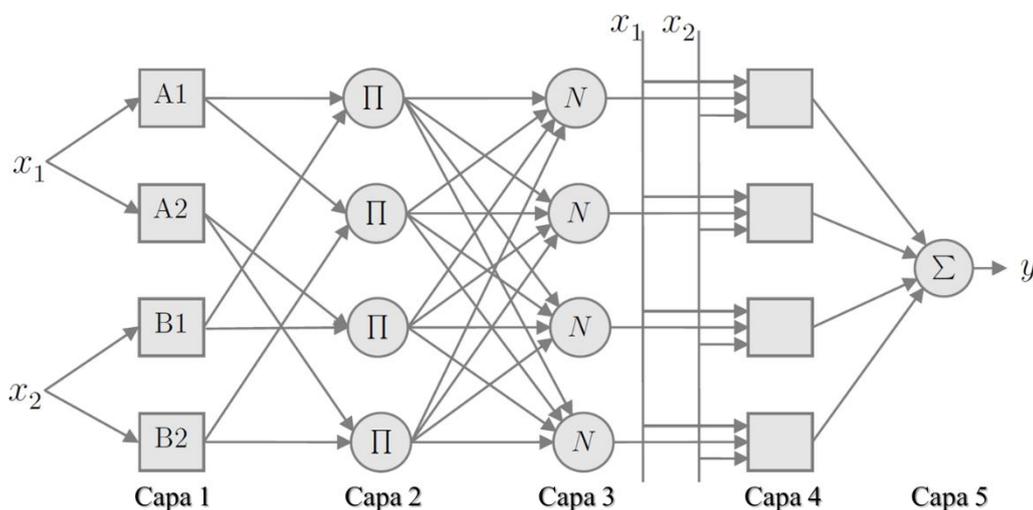


Fig. 3.17 Estructura da ANFIS.

(Fuente: Artificial Intelligence 3e e-book *A Guide to Intelligent Systems*)

- Capa 1:

Esta es conocida como la capa que se encarga de traducir los valores de los conjuntos clásicos en valores *fuzzy* (fuzzificación), las neuronas son estrictamente responsables de realizar este proceso.

$$O_i^{11} = \mu_{A_i}(x_1), \quad i = 1,2, \quad (3.49)$$

$$O_i^{12} = \mu_{B_i}(x_2), \quad i = 1,2, \quad (3.50)$$

x_1, x_2 : son las entradas de la red;

A_i, B_i : representan las variables lingüísticas asociadas a la función de las respectivas neuronas i ;

O_i^{11}, O_i^{12} : representa las funciones de pertinencia de las entradas, las cuales pueden adquirir diferentes formas como trapezoidales, triangulares, Gaussianas;

$$\mu A_i(x_1) = \frac{1}{1 + \left(\frac{x_1 - c_i}{a_i}\right)^{2b_i}}, \quad (3.51)$$

$$\mu B_i(x_2) = \frac{1}{1 + \left(\frac{x_2 - c_i}{a_i}\right)^{2b_i}}, \quad (3.52)$$

$\{a_i, b_i, c_i\}$: son parámetros que controlan, respectivamente, el centro, el ancho y la pendiente de la función de activación de campana de la neurona i .

A medida que cambian los valores de estos parámetros, las funciones en forma de campana varían, exhibiendo así varias formas de funciones de pertenencia en la variable lingüística.

- Capa 2:

Esta capa es conocida como la capa de reglas, a cada neurona de esta le corresponde una única regla de tipo Sugeno. Una neurona en esta capa tiene como salida la conjunción de sus señales de entrada, ecuación (3.53).

$$O_i^2 = \omega_i = \mu A_i(x_1) \times \mu B_i(x_2), \quad i = 1, 2, \quad (3.53)$$

ω_i : Las reglas *Fuzzy* del tipo T-S;

O_i^2 : La salida de la capa 2.

$$\omega_1: \text{SI } x_1 \text{ ES } A_1 \text{ Y } x_2 \text{ ES } B_1, \text{ ENTONCES } y_1 = p_1x_1 + q_1x_2 + r_1, \quad (3.54)$$

$$\omega_2: \text{SI } x_1 \text{ ES } A_1 \text{ Y } x_2 \text{ ES } B_2, \text{ ENTONCES } y_2 = p_2x_1 + q_2x_2 + r_2, \quad (3.55)$$

$$\omega_3: \text{SI } x_1 \text{ ES } A_2 \text{ Y } x_2 \text{ ES } B_1, \text{ ENTONCES } y_3 = p_3x_1 + q_3x_2 + r_3, \quad (3.56)$$

$$\omega_4: \text{SI } x_1 \text{ ES } A_2 \text{ Y } x_2 \text{ ES } B_2, \text{ ENTONCES } y_4 = p_4x_1 + q_4x_2 + r_4, \quad (3.57)$$

- Capa 3:

Está capa es la de normalización, cada neurona de esta capa recibe entradas de todas las otras neuronas, para calcular de esa forma un disparo normalizado de una regla en particular, ecuación (3.58).

$$O_i^3 = \bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2 + \omega_3 + \omega_4}, \quad (3.58)$$

$\bar{\omega}_i$: El valor de normalización de las reglas;

O_i^3 : La salida de la capa 3.

- Capa 4:

Esta es la capa que se encarga de la desfuzzificación. Cada neurona de esta capa está conectada a las entradas iniciales x_1, x_2 y también a la neurona de normalización respectiva.

$$O_i^4 = \bar{\omega}_i y_i = \bar{\omega}_i (p_i x_1 + q_i x_2 + r_i), \quad (3.59)$$

$\{p_i, q_i, r_i\}$: El conjunto de parámetros consecuente de la regla i ;

O_i^4 : Representa la salida de la capa 4.

- Capa 5:

Esta neurona calcula la suma de las salidas de todas las neuronas de desfuzzificación y produce la salida ANFIS general, ecuación (3.60).

$$O_i^5 = \sum_{i=1}^n \bar{\omega}_i y_i = \sum_{i=1}^n \bar{\omega}_i (p_i x_1 + q_i x_2 + r_i), \quad (3.60)$$

$$y = \frac{\omega_1}{\omega_1 + \omega_2} y_1 + \frac{\omega_2}{\omega_1 + \omega_2} y_2$$

$$= \bar{\omega}_1 y_1 + \bar{\omega}_2 y_2$$

(3.61)

$$= \bar{\omega}_1 (p_1 x_1 + q_1 x_2 + r_1) + \bar{\omega}_2 (p_2 x_1 + q_2 x_2 + r_2)$$

3.5.2 Aprendizaje ANFIS

El proceso de entrenamiento de la red neuronal ANFIS es realizado por medio de un algoritmo híbrido de aprendizaje, *backpropagation* basado en el gradiente decreciente y *least-squares estimator* (LSE) [39]. Cada parte de este algoritmo está compuesta por dos fases Tabla N° 3.1.

Tabla N° 3.1 Dos fases del algoritmo de aprendizaje ANFIS.

	Antecedentes	Consecuentes	Señales propagadas
Fase forward	Parámetros Fijos	LSE	Salida de las neuronas
Fase backward	Backpropagation	Parámetros fijos	Señales de error

(Fuente: Adaptado de ANFIS: *adaptive-network-based fuzzy inference system*)

Utilizando la fase *forward* se efectúa el entrenamiento de los patrones de entrada, la salida de las neuronas son calculadas capa por capa, los parámetros consecuentes son entrenados por LSE, mientras que los antecedentes se consideran fijos.

$$y_d = \begin{bmatrix} y_d(1) \\ y_d(2) \\ \vdots \\ y_d(p) \\ \vdots \\ y_d(P) \end{bmatrix}, \quad (3.65)$$

A : Matriz de $P \times n(1 + m)$ dimensiones,

$$A = \begin{bmatrix} \bar{\omega}_1(1) & \bar{\omega}_1(1)x_1(1) & \dots & \bar{\omega}_1(1)x_m(1) & \dots & \bar{\omega}_n(1) & \bar{\omega}_n(1)x_1(1) & \dots & \bar{\omega}_n(1)x_m(1) \\ \bar{\omega}_1(2) & \bar{\omega}_1(2)x_1(2) & \dots & \bar{\omega}_1(2)x_m(2) & \dots & \bar{\omega}_n(2) & \bar{\omega}_n(2)x_1(2) & \dots & \bar{\omega}_n(2)x_m(2) \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ \bar{\omega}_1(p) & \bar{\omega}_1(p)x_1(p) & \dots & \bar{\omega}_1(p)x_m(p) & \dots & \bar{\omega}_n(p) & \bar{\omega}_n(p)x_1(p) & \dots & \bar{\omega}_n(p)x_m(p) \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ \bar{\omega}_1(P) & \bar{\omega}_1(P)x_1(P) & \dots & \bar{\omega}_1(P)x_m(P) & \dots & \bar{\omega}_n(P) & \bar{\omega}_n(P)x_1(P) & \dots & \bar{\omega}_n(P)x_m(P) \end{bmatrix}, \quad (3.66)$$

λ : Vector de los parámetros del consecuente de dimensión $n(1 + m) \times 1$,

$$\lambda = [\lambda_{10}\lambda_{11}\lambda_{12} \dots \lambda_{1m}\lambda_{20}\lambda_{21}\lambda_{22} \dots \lambda_{2m} \dots \lambda_{n0}\lambda_{n1}\lambda_{n2} \dots \lambda_{nm}]^T \quad (3.67)$$

En la ecuación (3.64) debido a que el número P de patrones de entrada-salida usados en el entrenamiento es demasíadamente grande que $n(1 + m)$, se genera el problema de sistemas de ecuaciones sobredeterminadas, y por tanto posiblemente ni siquiera podría encontrarse la solución exacta a este problema. En ese sentido, se planteó en [40] utilizar los mínimos cuadrados, porque así permite halla una estimación por mínimos cuadrados que minimice el error cuadrático $\|A\lambda - y_d\|^2$.

$$\lambda^* = (A^T A)^{-1} A^T y_d \quad (3.68)$$

A^T : Transpuesta de A ;

$(A^T A)^{-1} A^T$: Pseudoinversa de A o inversa de Moore-Penrose;

Una vez calculado los parámetros consecuentes, es posible calcular la salida y , de esta forma se procede a calcular la ecuación (3.69) para dar comienzo a la fase *backward*.

$$\epsilon = y_d - y \quad (3.69)$$

En la fase *backward*, se utiliza el algoritmo de *backpropagation* [41] propagando la señal de error para las capas anteriores hasta alcanzar la primera capa, se ajusta los parámetros del antecedente utilizando la regla de la cadena. En esta fase los parámetros consecuentes son considerados fijos.

Para realizar el ajuste en el parámetro a , perteneciente a la función de activación tipo campana generalizada de la neurona A1, debe calcularse la ecuación (3.70).

$$\Delta a = -\alpha \frac{\delta E}{\delta a} = -\frac{\delta E}{\delta \epsilon} \times \frac{\delta \epsilon}{\delta y} \times \frac{\delta y}{\delta(\bar{\omega}_i y_i)} \times \frac{\delta(\bar{\omega}_i y_i)}{\delta \bar{\omega}_i} \times \frac{\delta \bar{\omega}_i}{\delta \omega_i} \times \frac{\delta \omega_i}{\delta \omega_{A1}} \times \frac{\delta \omega_{A1}}{\delta a} \quad (3.70)$$

α : Tasa de aprendizaje y E representa el valor cuadrático instantáneo de la neurona a la salida de la red.

$$E = \frac{1}{2} \epsilon^2 = \frac{1}{2} (y_d - y)^2, \quad (3.71)$$

Entonces la ecuación (3.70) quedaría de esta forma,

$$\Delta a = -\alpha (y_d - y) (-1) y_i \times \frac{\bar{\omega}_i (1 - \bar{\omega}_i)}{\omega_i} \times \frac{\omega_i}{\omega_{A1}} \times \frac{\delta \omega_{A1}}{\delta a}, \quad (3.72)$$

Siendo,

$$\begin{aligned} \frac{\delta \omega_{A1}}{\delta a} &= -\frac{1}{\left[1 + \left(\frac{x_1 - a}{c}\right)^{2b}\right]^2} \times \frac{1}{c^{2b}} \times 2b \times (x_1 - a)^{2b-1} \times (-1) \\ &= \omega_{A1}^2 \times \frac{2b}{c} \times \left(\frac{x_1 - a}{c}\right)^{2b-1} \end{aligned} \quad (3.73)$$

Del mismo modo deberá ser realizado para ajustar otros parámetros de la función campana generalizada, la misma metodología es usada para ajustar los parámetros de otras funciones de pertinencia.

CAPÍTULO IV
METODOLOGÍA PARA EL PRONÓSTICO DIARIO DE DEMANDA
ELÉCTRICA

4.1 Metodología utilizada por COES – procedimiento técnico 03

La metodología para el cálculo del pronóstico de la demanda utilizado por el COES está establecido en [1]. El cálculo está dividido en dos partes excluyentes, la primera es sobre el cálculo del pronóstico para días normales u ordinarios y el otro respecto a los días feriados.

4.1.1 Pronóstico para un día ordinario

El presente cálculo está basado en el siguiente proceso:

Paso 1: Selección de datos históricos de los últimos días no feriados basados en el siguiente Tabla.

Tabla N° 4.1 Datos históricos seleccionados para el pronóstico de demanda.

Día a pronostica	Días Seleccionados
Sábado	5 últimos sábados no feriados
Domingo	5 últimos domingos no feriados
Lunes	5 últimos lunes no feriados
Martes	5 últimos días que no incluye sábados, domingos, lunes y feriados.
Miércoles	5 últimos días que no incluye sábados, domingos, lunes y feriados.
Jueves	5 últimos días que no incluye sábados, domingos, lunes y feriados.
Viernes	5 últimos días que no incluye sábados, domingos, lunes y feriados.

(Fuente: PROCEDIMIENTO TÉCNICO DEL COMITÉ DE OPERACIÓN ECONÓMICA DEL SISTEMA)

Paso 2: Depuración de los datos.

- ✓ Para cada uno de los días seleccionados de la Tabla N° 4.1, la demanda total es separada en demanda vegetativa e industrial. La demanda vegetativa incluye la demanda industrial menor a 10MW, y la industrial, usuarios libres con demanda mayor o igual a 10MW. En el escenario de veda, el incremento de la demanda será considerada como una carga industrial mayor a 10MW.
- ✓ Para cada fila de la matriz de demanda vegetativa se calcula la mediana de los cinco valores.
- ✓ Después, para cada fila de la matriz de demanda vegetativa se calcula el porcentaje de la diferencia de cada una de las demandas vegetativas con respecto a la mediana.
- ✓ Se la diferencia del punto anterior es menor al 5%, el dato será válido, caso contrario será reemplazado por el promedio de todos los datos válidos obtenidos.
- ✓ Este proceso permitirá obtener una matriz de demandas vegetativas depuradas.

Paso 3: Cálculo del perfil diario de demanda.

- ✓ En la demanda vegetativa depurada, para cada día se calcula el valor mínimo de demanda en periodo base y valores máximos para los periodos de media y punta.
- ✓ A partir del paso anterior se calcula la demanda vegetativa de matriz por unidad para cada periodo horario.
- ✓ Para cada fila de la matriz por unidad se calcula la mediana de los cinco datos, con este cálculo se obtiene un perfil de demanda vegetativo preliminar.
- ✓ En esta última matriz se calcula el valor mínimo para el Periodo de Base y los valores máximos para el Periodo de Media y Periodo de Punta. Luego se divide cada valor de la matriz con su correspondiente valor mínimo o máximo obtenido anteriormente. La matriz obtenida será el perfil de la demanda vegetativa por unidad.

Paso 4: Pronóstico de la potencia mínima y potencias máximas

- ✓ Con los valores obtenidos en el paso 3 se obtendrá cinco valores mínimos en periodo base, cinco valores máximos en el periodo base y otros cinco en la punta.
- ✓ Para los periodos base, medio y punta, con los cinco valores de demanda obtenidos mediante el método de mínimos cuadrados se pronosticará un sexto.

Paso 5: Pronóstico de la demanda

- ✓ El pronóstico de demanda vegetativo se calcula de la multiplicación de todos los valores de la matriz de demanda vegetativa por unidad, del paso 3, por las potencias obtenidas en el paso 4.
- ✓ La demanda industrial, Usuarios Libres con demanda mayor o igual a 10 MW, será la suma de las demandas previstas e informadas al COES por cada uno de ellos.
- ✓ El pronóstico será la suma de demanda vegetativa e industrial.
- ✓ El resultado de la demanda podrá ser reajustado cuando el día a ser pronosticado esté antes o después de un feriado, permitiéndose el uso de datos históricos para su verificación.

4.1.2 Pronóstico para un día Feriado

Para el cálculo del pronóstico de un día feriado se toma en consideración los siguientes pasos establecido en el procedimiento técnico 03 del COES.

Paso 1: Determinar el día de la semana al que se atribuye el feriado.

Paso 2: Dentro de la base de datos se buscará un feriado que se asemeje al día del pronóstico, esta semejanza será válida cuando ambos feriados correspondan al mismo día de la semana.

Paso 3: Se divide la demanda total, del feriado semejante, en dos partes: Demanda vegetativa e industrial. La demanda vegetativa incluye la demanda industrial menor a 10MW, y la industrial, usuarios libres con demanda mayor o igual a 10MW.

Paso 4: Se calcula un factor de proporción dividiendo la demanda vegetativa futura de un no feriado, día anterior al pronosticado, entre la demanda vegetativa del día anterior al feriado escogido en el paso 3.

Paso 5: Para obtener la demanda vegetativa del feriado a ser pronosticado, se multiplica el factor de proporción del paso 4 por la demanda vegetativa del paso 2.

Paso 6: Los usuarios libres deberán informar al COES sobre sus previsiones de demanda, la suma de todas estas serán consideradas como la demanda industrial.

Paso 7: La suma de la demanda total será igual a la suma de la demanda vegetativa e industrial prevista en los pasos anteriores.

4.1.3 Resultados de la metodología COES

En base a los datos de los IEOD 2019 y 2020 se elaboraron las Fig. 4.1 y Fig. 4.2. Estas permiten observar el comportamiento del MAPE de forma diaria, los cuales representan errores constituidos por los datos ejecutados con respecto a los pronosticados resultados de las programaciones de operación diaria.

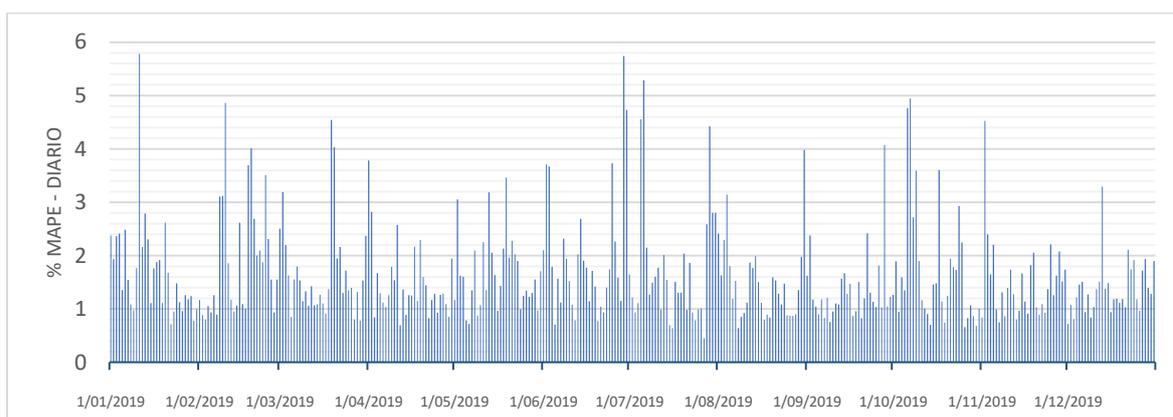


Fig. 4.1 MAPE diario comparando la demanda ejecutada y pronosticada PR-03 para 2019.

(Fuente: Elaboración propia)

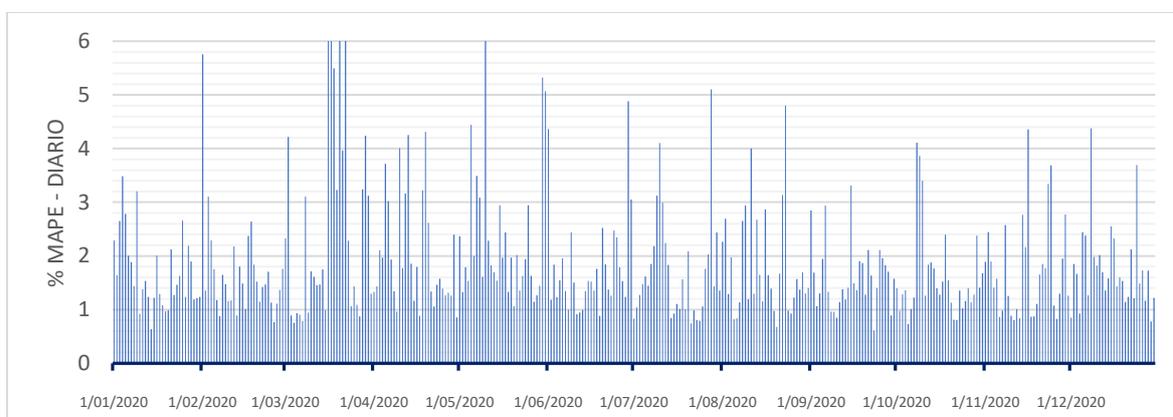


Fig. 4.2 MAPE diario comparando la demanda ejecutada y pronosticada PR-03 para 2020.

(Fuente: Elaboración propia)

4.2 Metodología usando herramientas de *Machine Learning*

En esta sección son presentadas dos metodologías que utilizan las herramientas de *Machine Learning* para resolver el problema del pronóstico de demanda diaria, para la validación de las metodologías se escogieron de manera aleatoria datos semanas dentro de los años 2019 y 2020. Las metodologías son desarrolladas utilizando la red Neuronal ARTMAP *Fuzzy* de la Teoría de la Resonancia Adaptativa y ANFIS pertenecientes a los Sistemas Adaptativos

Neuro-Fuzzy, además como forma de mejorar el desempeño se utilizó una metodología de pre-procesamiento de información. La validación en cuanto a los desempeños de las redes neuronales son medidos y comparados en relación al MAPE.

La Tabla N° 4.2 y Tabla N° 4.3 muestran de forma organizada los días aleatorios a ser analizados, también presenta información los días que serán sometidos a un pre-procesamiento y la cantidad de datos involucrados en el proceso entrenamiento.

Tabla N° 4.2 Días aleatorios para el pronóstico de demanda aplicado en el análisis de la primera metodología.

	Pre-procesamiento	Pronóstico			Datos entrenados
		Mes	Día	Año	
Primera metodología ARTMAP- Fuzzy	NO	Febrero	15 al 21	2019	a) 2688 b) 4032
		Mayo	17 al 23		
		Agosto	12 al 18		
		Octubre	20 al 26		
		Enero	11 al 17	2020	
		Marzo	1 al 7		
		Setiembre	14 al 20		
		Noviembre	08 al 14		
	SI	Febrero	15 al 21	2019	
		Mayo	17 al 23		
		Agosto	12 al 18		
		Octubre	20 al 26		
		Enero	11 al 17	2020	
		Marzo	1 al 7		
Setiembre	14 al 20				
Noviembre	08 al 14				

(Fuente: Elaboración propia)

Tabla N° 4.3 Días aleatorios para el pronóstico de demanda aplicado en el análisis de la segunda metodología.

	Pre-procesamiento	Pronóstico			Datos entrenados
		Mes	Día	Año	
Segunda metodología ANFIS	NO	Febrero	15 al 21	2019	a) 2688 b) 4032
		Mayo	17 al 23		
		Agosto	12 al 18		
		Octubre	20 al 26		
		Enero	11 al 17	2020	
		Marzo	1 al 7		
		Setiembre	14 al 20		
		Noviembre	08 al 14		
	SI	Febrero	15 al 21	2019	
		Mayo	17 al 23		
		Agosto	12 al 18		
		Octubre	20 al 26		
		Enero	11 al 17	2020	
		Marzo	1 al 7		
Setiembre	14 al 20				
Noviembre	08 al 14				

(Fuente: Elaboración propia)

4.2.1 Pre-procesamiento de datos

Con el objetivo de obtener resultados eficientes en el pronóstico de la demanda, se utiliza un análisis de pre-procesamiento para ajustar los datos de los días anómalos asociados a contingencias relevantes en el sistema eléctrico. Este pre-procesamiento de datos es parte de la metodología es una herramienta para garantizar un buen desempeño de resultados del pronóstico de la demanda eléctrica, el cual está constituido por un análisis que garantiza una buena gestión de información proporcionado datos de calidad al entrenamiento de las técnicas propuestas.

Esta sección está dividida en dos partes, la primera es sobre la presentación de los datos brutos extraídos directamente del IEOD, y la segunda parte es sobre la metodología del pre-procesamiento.

a) Datos Brutos

Estos datos son los obtenidos directamente a partir del IEOD, extraídos y organizados según los días de la semana. De la representación gráfica es posible identificar días anómalos o ruidos, estas no conservan características en común a días convencionales. Las características anómalas generan conflictos en el proceso de aprendizaje debido a falsas

asociaciones, por tanto es imprescindible una gestión de forma lógica los datos de entrada con el fin de obtener resultados coherentes.

Las Fig. 4.3, Fig. 4.4 y Fig. 4.5 representan los diagramas de carga semanales totales del SEIN pertenecientes a los años 2018, 2019 y 2020. Las variaciones en las curvas características son resultados de posibles pérdidas de lecturas en medidores, contingencias, y también de los días feriados decretados por el gobierno peruano. Además se debe resaltar que los datos a partir de marzo del 2020, son resultados de las medidas de confinamiento interpuestas por el estado para salvaguardar la salud pública, presentaron una caída dramática y recuperación proporcionada a lo largo del año 2020.

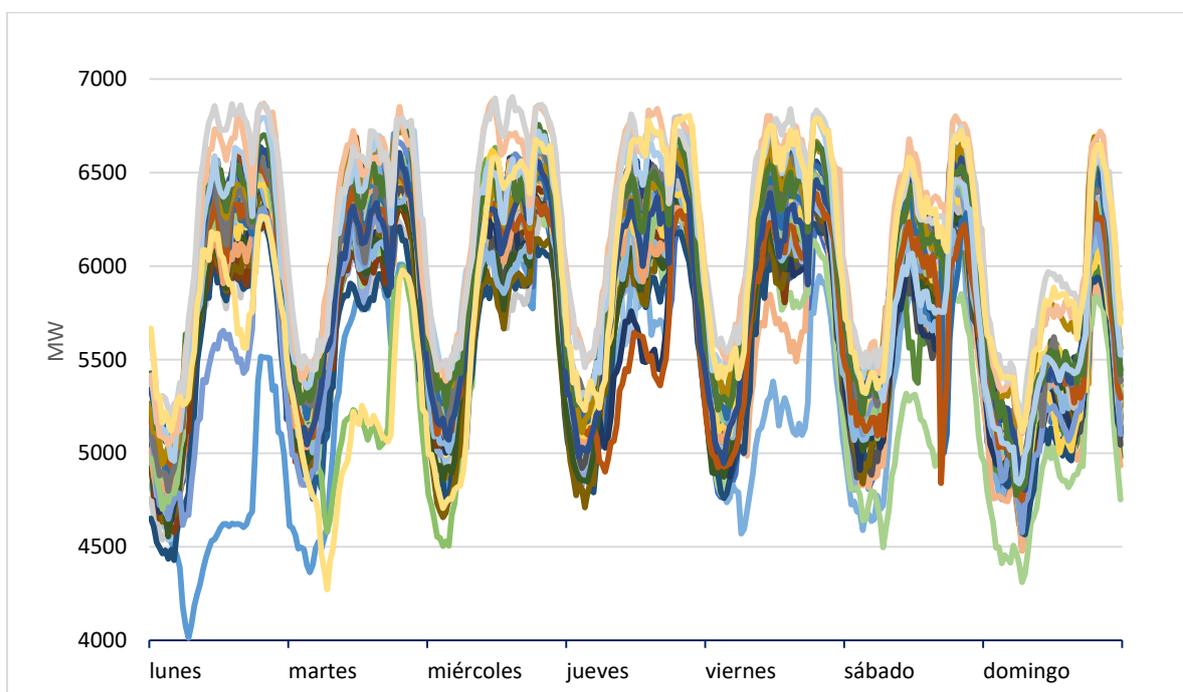


Fig. 4.3 Diagramas de cargas semanales SEIN perteneciente al 2018.

(Fuente: Elaboración propia)

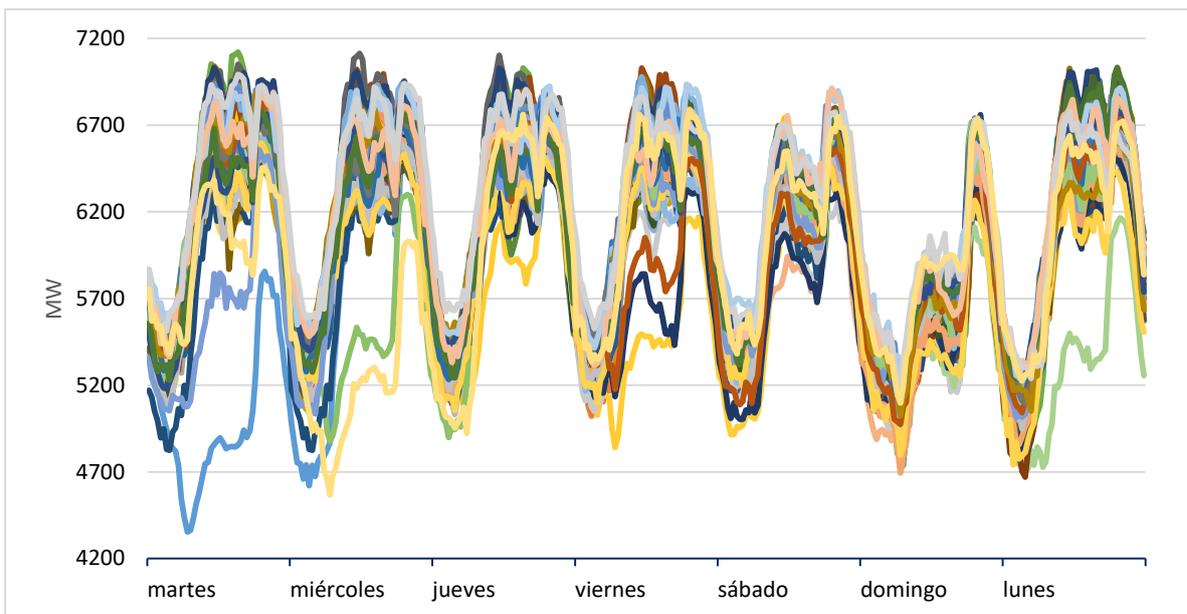


Fig. 4.4 Diagramas de cargas semanales SEIN perteneciente al 2019.
(Fuente: Elaboración propia)

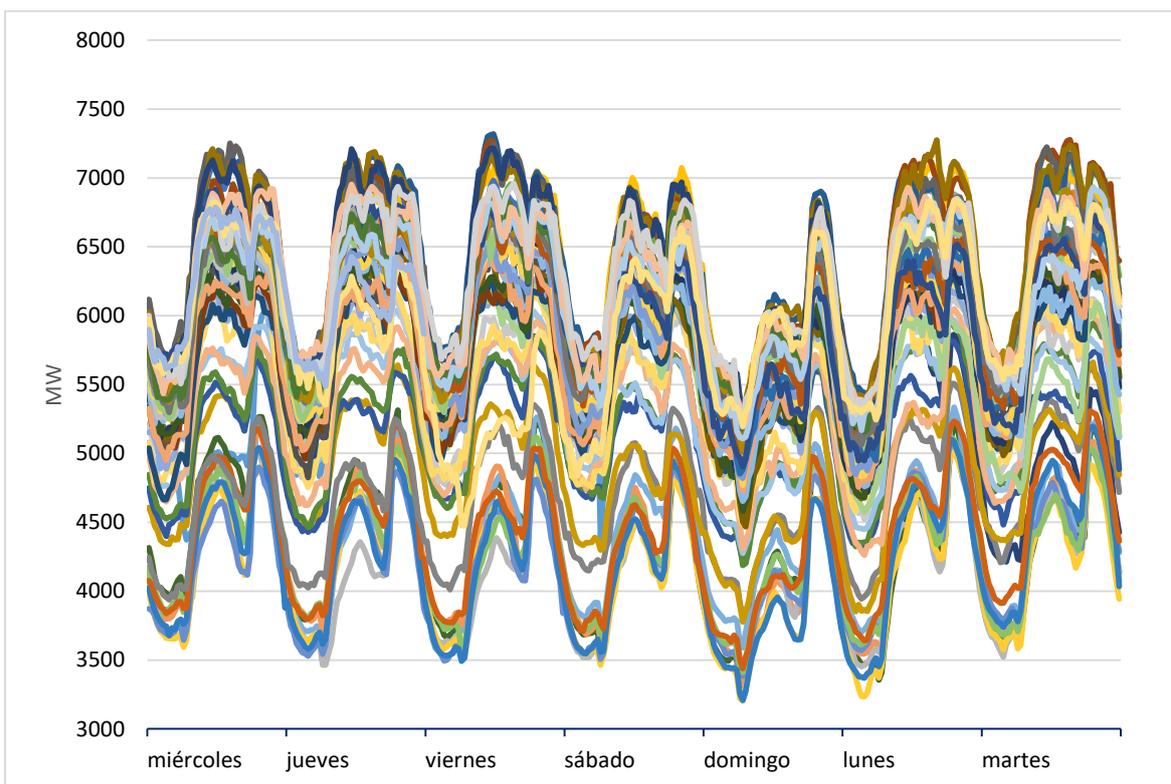


Fig. 4.5 Diagramas de cargas semanales SEIN perteneciente al 2020.
(Fuente: Elaboración propia)

b) Datos Pre-procesados

En aras de obtener el mejor desempeño en el pronóstico de la demanda eléctrica, se presenta la siguiente metodología en el tratamiento de los datos:

Primero se calcula la energía acumulada de forma diaria para toda la base de datos, cabe indicar que los IEOD presentan datos de demanda eléctrica cada media hora. Después para identificar los días anómalos, se evalúa el desvío energético mediante la métrica MAPE comparando la energía diaria calculada anteriormente con valor del promedio aritmético mostrado en la ecuación (4.1), si no se tuviera los datos de semanas posteriores solo se utiliza el promedio de datos de las semanas anteriores. El proceso aplicado para los datos de la demanda total garantiza una visión analítica rápida para su pronta gestión. A partir de este resultado se construye la Fig. 4.6, el cual nos muestra informaciones relevantes debido a que identifican días con anomalías en la base de datos.

$$E_{pcom}(d) = \frac{\sum_{n=1}^r E(d - 7n) + \sum_{m=1}^t E(d + 7m)}{r + t}, \quad (4.1)$$

Donde: $r = 2, t = 2$

$$DesvioEnergético = MAPE(E(d); E_{pcom}(d)), \quad (4.2)$$

d : Día evaluado; E_{pcom} : Energía promedio a ser comparado; E : Energía;

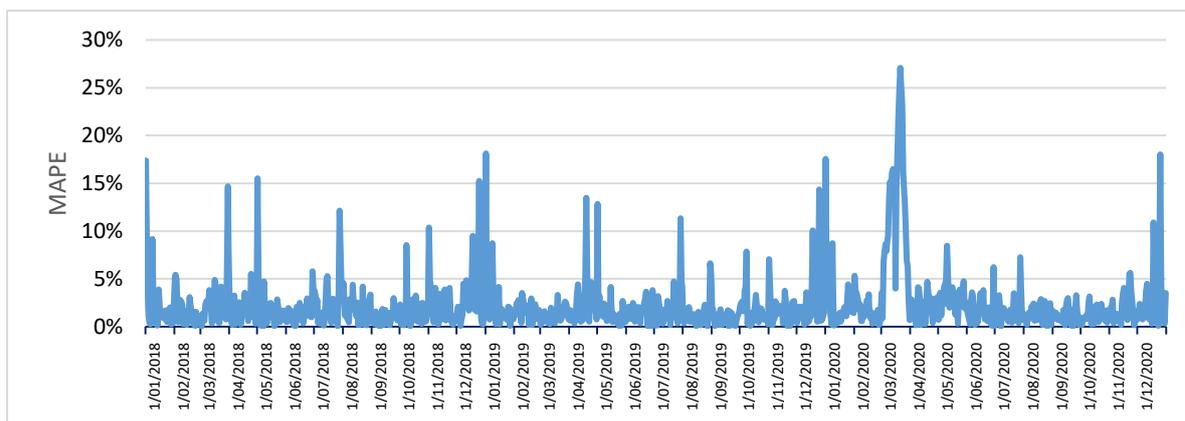


Fig. 4.6 MAPE respecto al desvío energético diario.

(Fuente: Elaboración propia)

Utilizando los datos de la Fig. 4.6 se construye la distribución normal acumulada de probabilidades Fig. 4.7. Se considera un límite de corte de aceptación para el proceso de

filtrado, este se realiza a una probabilidad acumulada de 0.8 perteneciente a los datos de los desvíos energéticos diarios. En otras palabras, para los días evaluados mayores al corte 5% de MAPE en el desvío, los datos de la demanda de los datos medio horarios serán reevaluados y/o modificados por de la siguiente ecuación.

$$\tilde{x}(h) = \frac{\sum_{n=1}^r \tilde{x}(h - 336n) + \sum_{m=1}^t x(h + 336m)}{r + t}, \quad (4.3)$$

Donde: $r = 2, t = 2$

h : Hora evaluada; x : Demanda media horaria sin pre-procesar; E : Demanda media horaria pre-procesada;

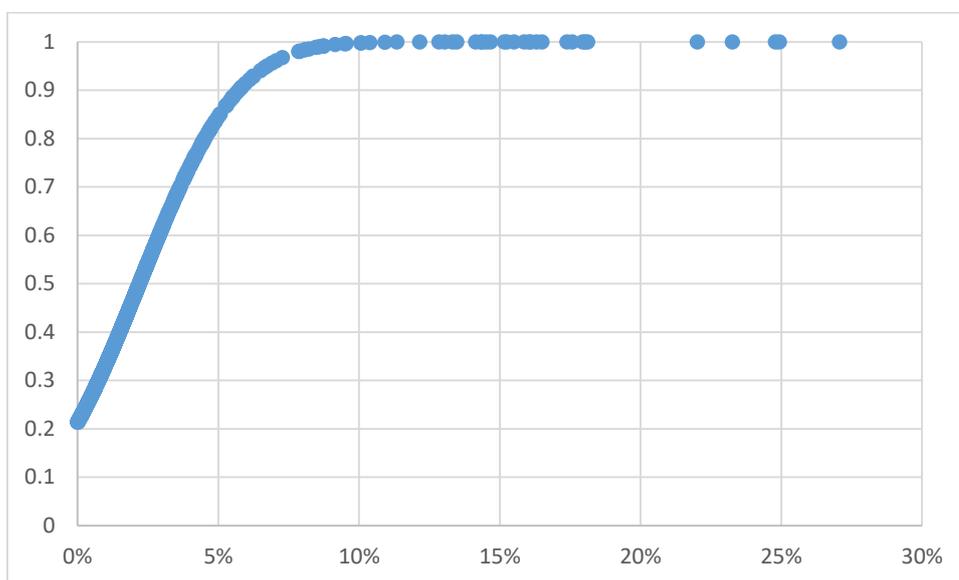


Fig. 4.7 Distribución acumulada de los datos del desvío energético diario.

(Fuente: Elaboración propia)

Finalmente, resultado de la metodología del pre-procesamiento son presentados los diagramas de cargas semanales Fig. 4.8, Fig. 4.9 y Fig. 4.10, los cuales serán utilizados para mejorar el desempeño de las metodologías propuestas.

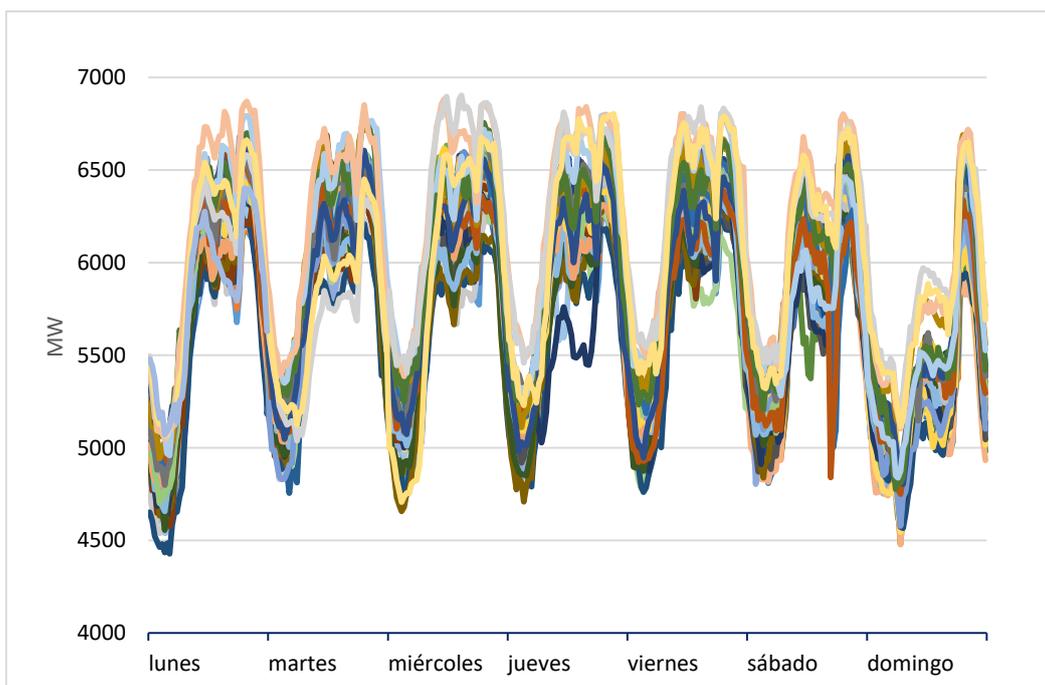


Fig. 4.8 Diagramas pre-procesadas de cargas semanales SEIN perteneciente al 2018.

(Fuente: Elaboración propia)

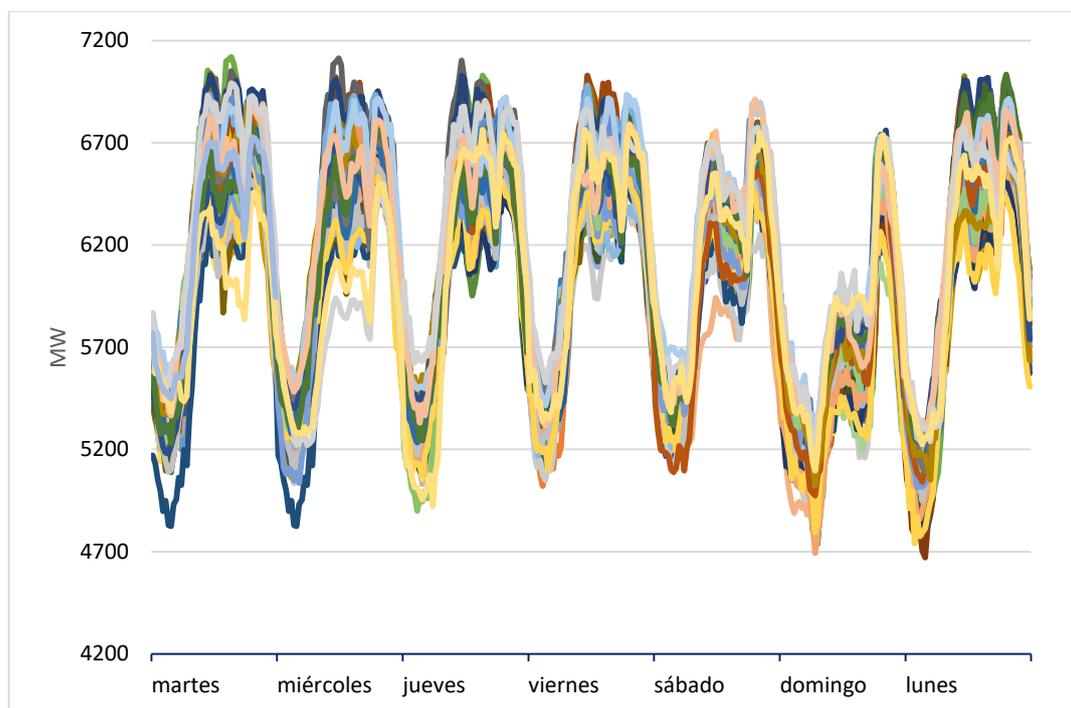


Fig. 4.9 Diagramas pre-procesadas de cargas semanales SEIN perteneciente al 2019.

(Fuente: Elaboración propia)

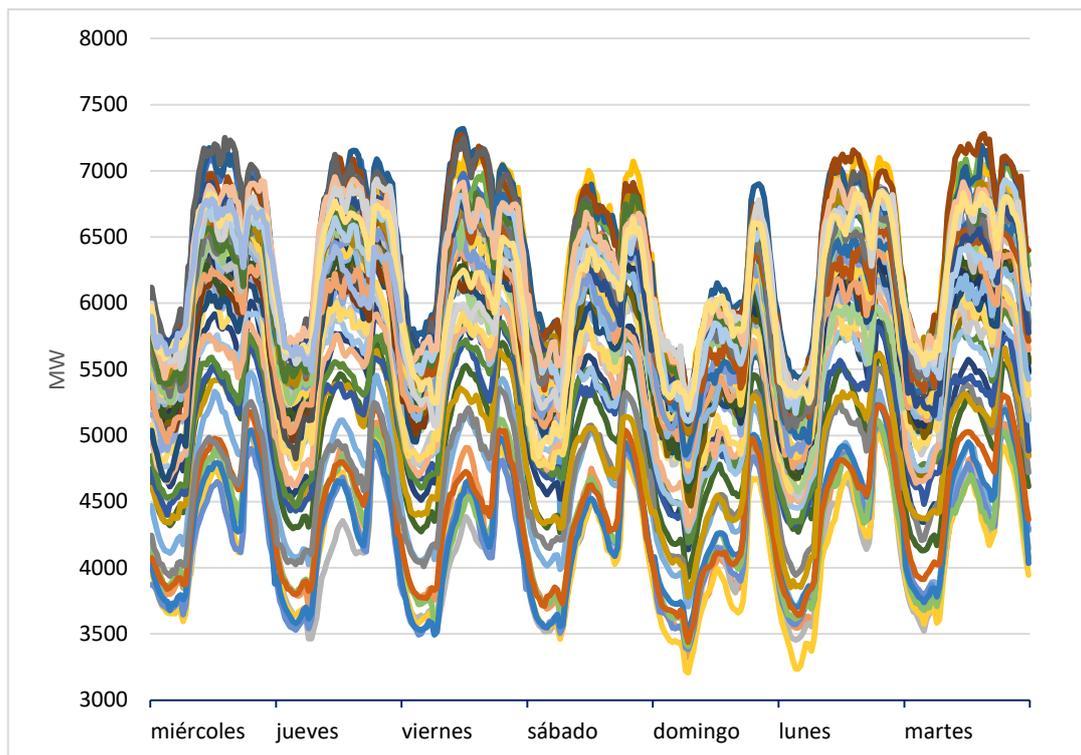


Fig. 4.10 Diagramas pre-procesadas de cargas semanales SEIN perteneciente al 2020.
(Fuente: Elaboración propia)

4.2.2 Primera metodología

Esta primera metodología utiliza la teoría de la resonancia adaptativa, red neuronal ARTMAP *Fuzzy*, para el pronóstico de la demanda eléctrica. La organización de los patrones de entrada de la red es basada en la ventana móvil [42], la cual es utilizada para gestionar los patrones de entrada en las redes neuronales. En este sentido, se define el vector de entrada a de la siguiente forma:

$$a = [h \ dS \ D(h-3) \ D(h-2) \ D(h-1) \ D(h)], \quad (4.4)$$

h : Codificación respecto a la hora en intervalos de 30 minutos (Vector de seis bits de 00:30- [000001] a las 24:00 - [110000])

dS : Codificación respecto al día de la semana (Vector de tres bits Lunes- [001] a Domingo - [111])

$D(h-3)$: Demanda del SEIN referente al instante $h-3$.

$D(h-2)$: Demanda del SEIN referente al instante $h-2$.

$D(h - 1)$: Demanda del SEIN referente al instante $h - 1$.

$D(h)$: Demanda del SEIN referente al instante h .

El vector de salida b corresponde al instante $h + 1$, esta representa el valor futuro de 30 minutos en adelante.

$$b = [D(h + 1)], \quad (4.5)$$

Una de las ventajas de esta red neuronal es que las variables de entrada pueden estar constituidas por valores de carga presentes y pasados, así como también por variables exógenas como condiciones ambientales, climáticas, entre otras. Esta amplia gama de variables en la entrada se debe a que la arquitectura no posee restricciones en relación a la dimensión del vector de entrada, y lo mismo para el conjunto de patrones en la fase de entrenamiento.

Una vez completado la fase de entrenamiento de la red neuronal, utilizando el algoritmo presentado en el capítulo 3, se procede con la evaluación para verificar que los pesos se adaptaron correctamente. Si los resultados no consiguieron alcanzar las expectativas deseadas, se puede modificar o alterar los parámetros de la red, para de esta forma realizar un nuevo entrenamiento. Finalmente para comparar la precisión del pronóstico se utiliza la métrica del error porcentual medio absoluto MAPE.

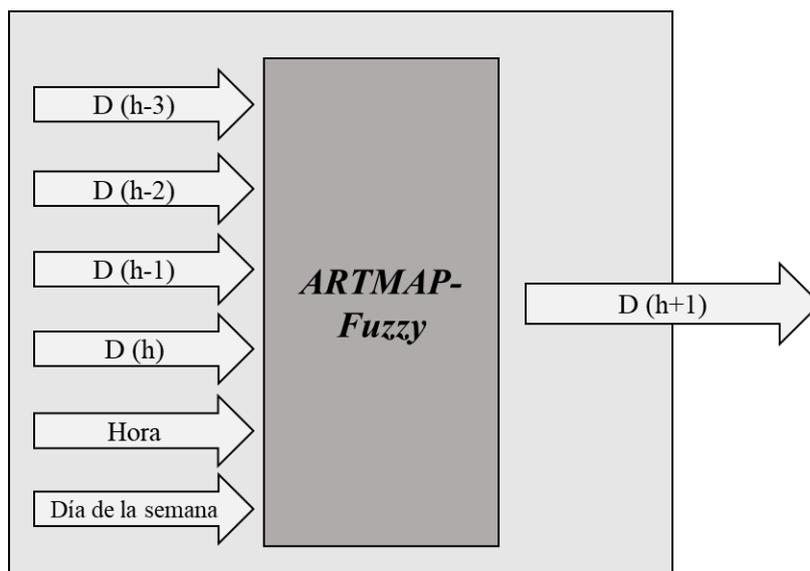


Fig. 4.11 Sistema de pronóstico ARTMAP Fuzzy

(Fuente: Elaboración propia)

4.2.3 Segunda metodología

Esta segunda metodología utiliza la teoría neuro-*fuzzy*, red neuronal ANFIS, para el pronóstico de demanda eléctrica. En esta metodología se utilizan valores históricos como una forma de pronosticar el futuro. El método estándar para este tipo de pronóstico es creado a partir de un mapeo de D puntos de datos de muestra, presentados para cada Δ unidades de tiempo $x(t - (D - 1)\Delta), \dots, x(t - \Delta), x(t)$ a un valor pronosticado $x(t + P)$. Siguiendo los ajustes pertinentes a las características de los datos, se establece $D = 4$ y $\Delta = P = 336$. Los datos de entrenamiento en la entrada son representados de la siguiente forma, vector de cuatro columnas.

$$E = [x(t - 1008) \ x(t - 972) \ x(t - 336) \ x(t)] \quad (4.6)$$

Los datos del pronóstico son representados de la siguiente forma.

$$S = [x(t + 336)] \quad (4.7)$$

t : Valores de muestras de la base de datos.

x : Demanda del SEIN

En el proceso de adaptación, 80% de las muestras se utilizan para el proceso de entrenamiento y el 20% restante para verificar la validación. Una vez completado la fase de entrenamiento de la red neuronal y validación, empleando el algoritmo presentado en el capítulo 3 para ANFIS, se procede con la evaluación para verificar que los pesos se adaptaron correctamente. Si los resultados no consiguieron alcanzar las expectativas deseadas, se tiene la opción de utilizar funciones de pertinencia de tipo triangular, trapezoidal, gaussiana y campana generalizada. Finalmente para evaluar el desempeño del pronóstico se utiliza la métrica del error porcentual medio absoluto MAPE.

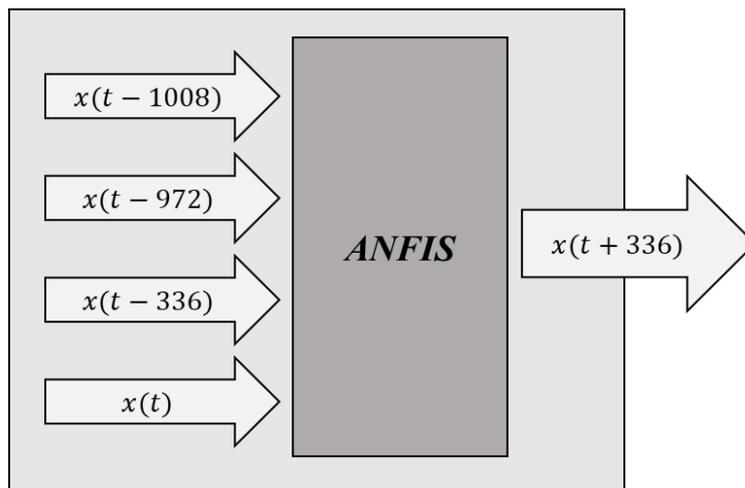


Fig. 4.12 Sistema de pronóstico ANFIS

(Fuente: Elaboración propia)

CAPITULO V

ANÁLISIS Y DISCUSIÓN DE RESULTADOS

5.1 Resultados de la primera metodología

En esta sección se presentan los resultados en términos del MAPE diario obtenidos en base a la primera metodología, en un primer escenario se trabajó con datos sin pre-procesar y en el siguiente con datos pre-procesados, esto con el fin de medir el grado de desempeño de la técnica utilizada. Es necesario mencionar que se utilizó la Tabla N° 5.1 como los parámetros necesarios para el entrenamiento la red neuronal, y además para un aporte de flexibilidad en los resultados los parámetros de vigilancia ρa se consideraron en el intervalo entre 0.89 y 0.99, como un aporte sustancial a la procura de una respuesta de alta calidad en relación al desempeño característico de la red. También, para garantizar una alta velocidad en la adaptación de los pesos se consideró la tasa de entrenamiento de una unidad, un parámetro de selección de 0.1. Esta simplicidad en la gestión de diferentes parámetros garantiza que esta propuesta sea flexible de forma que permita adecuar, con fines de pronóstico de demanda, parámetros específicos capaces de resolver problemas característicos.

Tabla N° 5.1 Configuración de los parámetros para la metodología usando ARTMAP
Fuzzy

ρ_b	ρ_{ab}	β	α	ϵ
0.99	0.99	1	0.1	0.0001

(Fuente: Elaboración propia)

Durante el primer escenario se trabajó con los datos medio-horarios brutos obtenidos directamente de los IEOB, estos pertenecientes a los años 2018, 2019 e 2020. Se seleccionó semanas aleatorias mostrados en la Tabla N° 4.2 para diferentes meses dentro de los años 2019 y 2020 con la finalidad de realizar pronósticos diarios individuales.

En la Tabla N° 5.2 y Tabla N° 5.3 se muestran las validaciones en términos de MAPE para pronósticos diarios pertenecientes a los meses de febrero, mayo, agosto y octubre del 2019.

Como se puede observar en las tablas, existen diferentes resultados para los parámetros de vigilancia seleccionados, de los cuales los más destacados son para 0.92 y 0.97 por presentar una mayor cantidad de valores menores iguales a 1.5 en el MAPE.

Tabla N° 5.2 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP *Fuzzy* para 2688 datos sin pre-procesamiento - 2019.

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia														
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99				
2688	2019	Febrero	15	2.7792	2.7539	1.9924	2.2748	2.3011	2.3011	2.3011	2.3011	2.3011	2.3011	2.3011	2.3011	2.3011	1.8320	
			16	3.3865	3.3865	3.0290	3.1855	3.1509	3.1509	3.1509	3.1509	3.1509	3.1509	3.1509	3.1509	3.1509	3.1509	2.1422
			17	3.5564	3.5297	2.6579	3.3777	3.3777	3.3777	3.3777	3.3777	3.3777	3.3777	3.3777	3.3777	3.3777	3.3777	2.4968
			18	1.5158	1.3896	1.3790	1.5293	1.5293	1.5293	1.5293	1.5293	1.5293	1.5293	1.5293	1.5293	1.5293	1.5293	1.5632
			19	1.5165	1.5165	1.4998	1.2190	1.3156										
			20	2.1843	2.2162	2.0509	2.0509	2.0509	2.0509	2.0509	2.0509	2.0509	2.0509	2.0509	2.0510	2.0510	2.0510	2.0140
			21	2.4952	2.5184	2.2076	2.5437	2.4032	2.4032	2.4032	2.4032	2.4032	2.4032	2.4032	2.4032	2.4032	2.4032	2.2891
		Mayo	17	2.0351	1.8683	1.7655	1.8300	1.8300	1.8300	1.8300	1.8300	1.8300	1.8300	1.8300	1.8300	1.8300	1.8300	1.6754
			18	2.0006	1.9605	2.0321	1.7962	1.8993	1.8993	1.8993	1.8993	1.8993	1.8993	1.8993	1.8993	1.8993	1.8993	1.8242
			19	1.8001	1.8325	1.5780	1.4236											
			20	1.9957	1.9957	1.8246	1.7825	1.7825	1.7825	1.7825	1.7825	1.7825	1.7825	1.7825	1.7825	1.7825	1.7825	1.7358
			21	1.3172	1.3172	1.2564	1.2282	1.1978	1.2206									
			22	1.2680	1.2680	1.2587	1.1906	1.3344	1.3479									
			23	2.5389	2.5389	2.4410	3.0216	2.4887	2.4887	2.4887	2.4887	2.4887	2.4887	2.4887	2.4887	2.4887	2.4887	3.1226
		Agosto	12	1.7974	1.7974	1.8630	1.4479	1.6322	1.6322	1.6322	1.6322	1.6322	1.6322	1.6322	1.6322	1.6322	2.0831	
			13	1.5301	1.5301	1.6864	1.4086	1.3722	1.5611									
			14	2.2273	2.2273	2.0403	2.1981	2.1981	2.1981	2.1981	2.1981	2.1981	2.1981	2.1981	2.2361	2.2361	2.1756	
			15	1.5552	1.5552	1.5045	1.3340	1.2399	1.2664									
			16	1.1329	1.1329	1.3513	1.0870	1.0625										
			17	0.8233	0.8233	0.7255	0.6165	0.5341	0.5677									
			18	1.7621	1.7621	1.2736	1.2951	1.4394										
		Octubre	20	1.5294	1.7663	4.454	1.1597	1.1354	1.8092									
			21	1.4511	1.4511	2.3649	1.267	1.2008	1.5053									
			22	1.9623	1.9623	2.0572	1.8178	1.8178	1.8178	1.8178	1.8178	1.8178	1.8178	1.8178	1.8178	1.8178	1.8178	1.9276
			23	1.4593	1.43	1.5669	1.2955	1.268	2.4761									
			24	1.907	1.907	2.0243	1.7924	1.7714	1.7714	1.7714	1.7714	1.7714	1.7714	1.7714	1.7714	1.7714	1.7714	2.4018
25	1.1517		1.1517	1.5185	0.9442	1.3058												
26	1.2865		1.32	1.1237	1.1074	1.7709	1.8519											

(Fuente: Elaboración propia)

Para términos de *benchmark* comparamos Fig. 5.1 las validaciones efectuadas en Tabla N° 5.2 con las calculadas basadas en los IEOD COES. En esa gráfica se puede identificar una mejora considerable respecto a la validación efectuado por la primera metodología; sin embargo, esta no es definitiva por la baja cantidad de datos usados para entrenar la red y al mismo tiempo por usar datos sin ser sometidos a un pre-proceso.

Las validaciones para los días 16 y 17 del mes de febrero, presentaron distorsiones con respecto a lo evaluado por COES. Las distorsiones se suscitaron por un incremento repentino de la demanda ejecutada, este no fue reconocido por la red neuronal en el proceso de adaptación consecuencia de un entrenamiento con baja cantidad de datos, el histórico no tenía contemplado ese cambio.

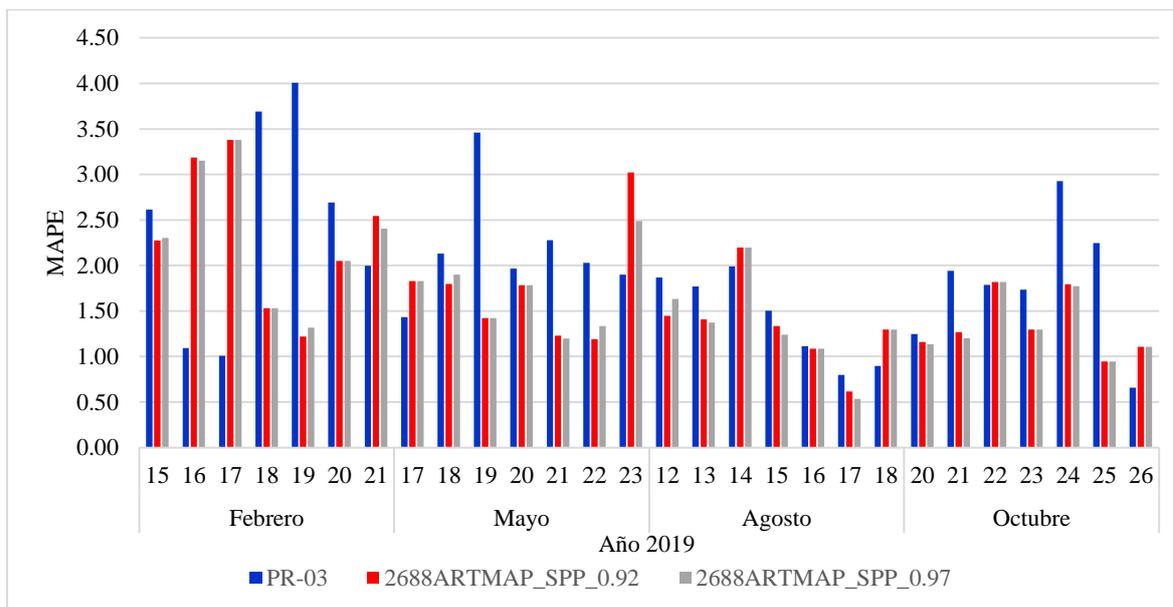


Fig. 5.1 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP *Fuzzy* para 2688 datos sin pre-procesamiento – 2019.

(Fuente: Elaboración propia)

Tabla N° 5.3 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP
Fuzzy para 4032 datos sin pre-procesamiento - 2019

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia											
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99	
4032	2019	Febrero	15	2.7324	2.6040	2.4011	2.3102	2.3102	2.3102	2.3102	2.3102	2.3102	2.2081	2.1955	
			16	3.3446	3.3066	3.1482	3.0085	3.0085	3.0085	3.0085	3.0085	3.0085	3.0085	3.0085	3.0224
			17	3.3903	3.3726	3.1757	3.3274	3.3274	3.3274	3.3274	3.3274	3.3274	3.3274	3.1333	1.5262
			18	1.7323	1.7356	1.5728	1.5063	1.5518	1.5518	1.5518	1.5518	1.5518	1.5518	1.5518	1.5657
			19	1.6100	1.6100	1.5102	1.4567	1.7609							
			20	2.1421	2.4165	2.4750	1.9882	1.9882	1.9882	1.9882	1.9882	1.9882	1.9882	1.9812	1.7682
			21	2.3821	2.4032	2.3382	2.2708	2.2708	2.2708	2.2708	2.2708	2.2708	2.2708	2.2708	2.3009
		Mayo	17	2.1146	1.9343	1.8755	1.7641	1.7879	1.7879	1.7879	1.7879	1.7879	1.7879	1.7879	1.8229
			18	2.1360	1.9858	2.1331	2.0720	1.9241	1.9241	1.9241	1.9241	1.9241	1.9241	1.9241	1.6710
			19	1.8169	1.8252	1.5662	1.4332								
			20	1.9964	1.9964	2.0486	1.7854	1.7854	1.7854	1.7854	1.7854	1.7854	1.7854	1.7854	2.1984
			21	1.3660	1.4826	1.6103	1.2531	1.2142	1.2142	1.2142	1.2142	1.2142	1.2142	1.6312	1.4560
			22	1.3360	1.3602	1.2043	1.3734	1.3008							
		Agosto	23	2.5559	2.5559	3.3654	3.0163	2.4971	2.4971	2.4971	2.4971	2.4971	2.4971	2.4971	2.4185
			12	1.8744	1.8744	2.0208	1.6823	1.6823	1.6823	1.6823	1.6823	1.6823	1.6823	1.6823	1.6912
			13	1.5108	1.5108	1.4557	1.3473	1.3598	1.3372						
			14	2.1391	2.1391	2.0198	2.2929	2.0811	2.0811	2.0811	2.0811	2.0811	2.0811	2.1349	1.6864
			15	1.5825	1.5825	1.2426	1.2671	1.2476	1.2302						
			16	1.1436	1.1436	1.2043	1.0324	1.1090	1.0953						
			17	0.7918	0.7918	0.7346	0.6757	0.5503	0.7848						
			18	1.7278	1.7278	1.4096	1.2775	1.2404							
			20	1.5187	1.7350	3.1556	1.1470	4.5961							
			21	1.5162	1.4680	2.6450	1.2338	1.2445	2.2971						
		Octubre	22	1.9499	1.9499	2.1158	1.8944	1.7740	1.7740	1.7740	1.7740	1.7740	1.7740	1.7740	2.0691
			23	1.4694	1.8006	1.3596	1.3243	1.5645	2.5088						
			24	1.8848	1.8299	1.9398	1.9090	1.6799	1.6799	1.6799	1.6799	1.6799	1.6799	1.6799	1.6799
25	1.2317		1.1542	1.7414	0.9715	0.9306	2.7302								
26	1.2061		1.4729	1.7205	1.1095	1.5318	1.9624								

(Fuente: Elaboración propia)

De la misma forma que fue comentado sobre la Fig. 5.1, se efectúa una comparación entre las validaciones de COES en la Fig. 5.2 respecto a los resultados obtenidos mostrados en la Tabla N° 5.3. Las observaciones tienden a ser las mismas que para la Tabla N° 5.2, no generó un incremento significativo del desempeño entrenando la red neuronal con 4032 datos.

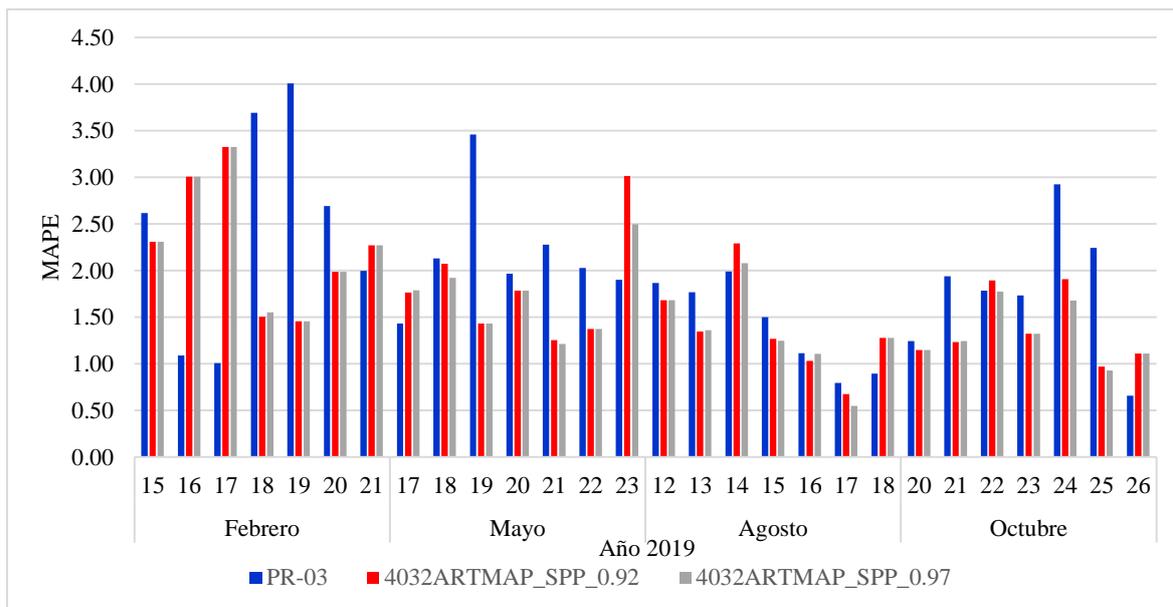


Fig. 5.2 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP *Fuzzy* para 4032 datos sin pre-procesamiento – 2019.

(Fuente: Elaboración propia)

En la Tabla N° 5.4 y Tabla N° 5.5 se muestran las validaciones en términos de MAPE para pronósticos diarios pertenecientes a los meses de enero, marzo, setiembre y noviembre del 2020 utilizando datos sin pre-procesar. Como se puede observar existen diferentes resultados para una variedad de parámetros de vigilancia, de los cuales los más destacados se encuentran en el intervalo de 0.92 a 0.98 por presentar en mayor proporción, entre otros parámetros, valores eficientes en términos del MAPE.

Tabla N° 5.4 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 2688 datos sin pre-procesamiento - 2020

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia												
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99		
2688	2020	Enero	11	3.7379	3.9112	3.7020	3.6220	3.6220	3.6220	3.6220	3.6220	3.6220	3.6220	3.6220	3.5915	
			12	2.8936	2.8936	2.1743	1.9778	2.6129	2.6129	2.6129	2.6129	2.6129	2.6129	2.6129	2.6129	1.9830
			13	1.8213	1.9317	2.0666	1.8381	1.8476	1.8476	1.8476	1.8476	1.8476	1.8476	1.8832	1.8832	1.8355
			14	2.7664	2.8273	5.8907	3.0766	2.6679	2.6679	2.6679	2.6679	2.6679	2.6679	2.6861	2.6861	2.5924
			15	2.2688	2.2688	1.9975	1.9953	1.8671	1.8671	1.8671	1.8671	1.8671	1.8671	1.8671	1.8671	2.3925
			16	2.7639	2.7639	2.7386	3.5603	2.3852	2.3852	2.3852	2.3852	2.3852	2.3852	2.3852	2.3852	2.3922
			17	1.2452	1.3050	0.7490	0.8075	0.5846	0.6462							
		Marzo	1	2.7082	2.7174	2.0308	2.3752	2.3752	2.3752	2.3752	2.3752	2.3752	2.3752	2.3752	2.3752	2.3100
			2	2.2425	2.2132	2.5440	2.0119	2.0119	2.0119	2.0119	2.0119	2.0119	2.0119	2.0119	2.0119	1.8816
			3	1.2040	1.0990	1.5862	0.9720	0.9705	0.9705	2.5331						
			4	1.3565	1.1158	1.1633	1.0233	1.1087	1.1087	1.1389						
			5	1.7952	1.7872	1.6128	1.5708	1.5708	1.5708	1.5708	1.5708	1.5708	1.5708	1.5806	1.5806	1.7511
			6	1.2957	1.3046	1.1706	1.0025	1.1516								
			7	1.9414	1.9414	1.9362	1.7762	1.7984	1.7984	1.7984	1.7984	1.7984	1.7984	1.7984	1.7984	2.7059
		Setiembre	14	1.5697	1.4358	1.3298	1.2423	1.2766	1.3752							
			15	1.8574	1.8574	1.6893	1.6936	1.6936	1.6936	1.6936	1.6936	1.6936	1.6936	1.6936	1.6936	1.3873
			16	2.4103	2.4103	2.1396	2.1219	2.1219	2.1219	2.1219	2.1219	2.1219	2.1219	2.1219	2.1219	2.0911
			17	2.5412	2.4812	2.2063	1.9937	2.3819	2.3819	2.3819	2.3819	2.3819	2.3819	2.3216	2.3216	1.2460
			18	1.3669	1.3669	1.2685	1.2538	0.9928								
			19	2.3245	2.3245	2.3412	2.1734	2.1734	2.1734	2.1734	2.1734	2.1734	2.1734	2.1734	2.1734	1.9544
			20	1.5954	1.5954	2.1857	1.4415	2.2127								
		Noviembre	8	3.1934	3.1934	3.1335	3.0185	3.0185	3.0185	3.0185	3.0185	3.0185	3.0185	3.0185	3.0185	3.0576
			9	1.8678	1.8521	1.3639	1.5151	1.5151	1.5151	1.5151	1.5151	1.5151	1.5151	1.5151	1.5151	1.5704
			10	1.3146	1.3535	1.2593	0.9156	1.2162	1.2552							
			11	2.3148	2.2753	1.9874	2.0258	2.0258	2.0258	2.0258	2.0258	2.0258	2.0258	1.9969	1.9969	2.0427
			12	1.187	1.152	0.8332	0.8275	0.8442	0.8275							
			13	1.074	1.0151	1.0599	0.6182	0.6922								
			14	3.1755	3.0021	3.4644	3.2862	3.1603	3.1603	3.1603	3.1603	3.1603	3.1603	2.9036	2.9036	3.2266

(Fuente: Elaboración propia)

Los resultados de la validación mostrados en la Tabla N° 5.4 exponen categóricamente que los MAPE para los días 11, 14, 16 el mes de enero y para 8 y 14 de noviembre desbordaron un 3% consecuencia de grandes variaciones de carga en diferentes bloques horarios en el SEIN. Además los datos históricos usados en la adaptación de pesos en los días mencionados presentaron comportamiento atípicos *e.g.*, los primeros días del año los cuales no permitieron obtener un alto desempeño de la red comparada con la de COES presentadas en la Fig. 5.3.

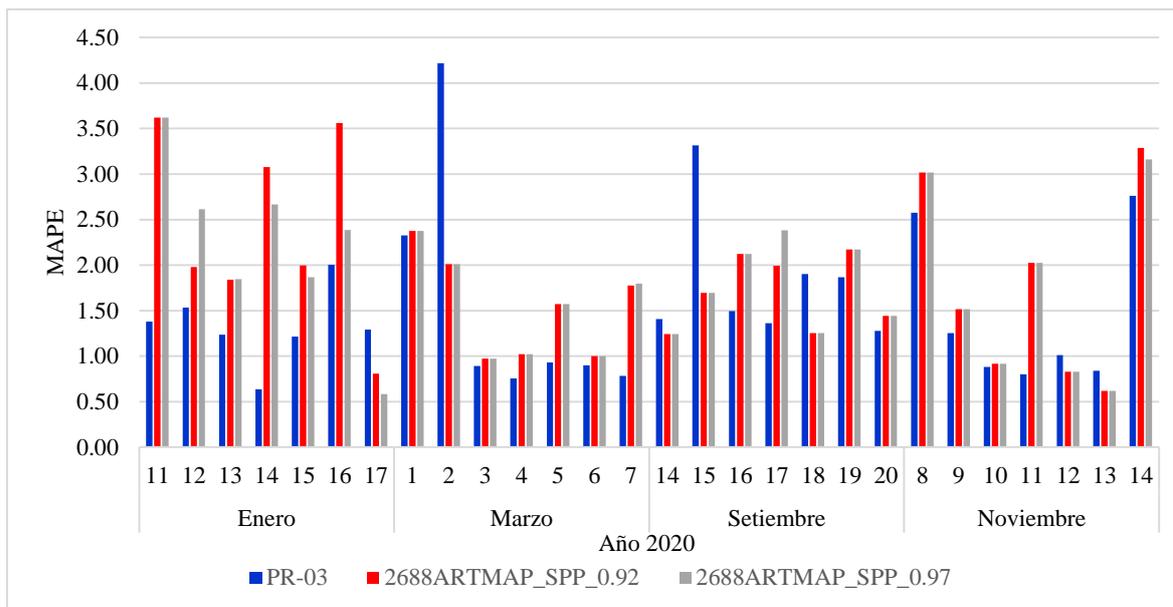


Fig. 5.3 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP *Fuzzy* para 2688 datos sin pre-procesamiento – 2020.
(Fuente: Elaboración propia)

Tabla N° 5.5 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP
Fuzzy para 4032 datos sin pre-procesamiento - 2020

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia												
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99		
4032	2020	Enero	11	3.7764	3.8520	3.5571	3.5695	3.6346	3.6346	3.6346	3.6346	3.6346	3.6346	3.6346	3.5702	
			12	2.7167	2.7167	1.6974	2.0390	2.5911	2.5911	2.5911	2.5911	2.5911	2.5911	2.5911	2.5911	2.0810
			13	1.9243	2.0341	2.4257	2.0364	1.9144	1.9144	1.9144	1.9144	1.9144	1.9144	2.0223	2.1427	
			14	2.7535	2.9636	3.6601	2.8337	2.6983	2.6983	2.6983	2.6983	2.6983	2.6983	2.6983	2.6983	2.4392
			15	2.2812	2.2812	1.6623	1.9512	1.8969	1.8969	1.8969	1.8969	1.8969	1.8969	1.8969	1.8969	2.4666
			16	2.8084	2.8084	2.7964	2.4389	2.4604	2.4604	2.4604	2.4604	2.4604	2.4604	2.4604	2.4604	2.4605
			17	1.1761	1.2326	0.9409	1.2337	0.6129	0.6510							
		Marzo	1	2.6560	2.6560	2.3932	2.2340	2.3015	2.3015	2.3015	2.3015	2.3015	2.3015	2.3015	2.3074	1.9358
			2	2.3008	2.0555	2.0211	2.0605	2.0605	2.0605	2.0605	2.0605	2.0605	2.0605	2.0605	1.6584	2.1969
			3	1.1669	1.0165	2.3365	0.9043	3.6153								
			4	1.4236	2.1364	1.9065	1.0111	1.1129	1.2486							
			5	1.8982	2.2964	2.3870	1.6811	1.6811	1.6811	1.6811	1.6811	1.6811	1.6884	2.2134	2.5720	
			6	1.3867	1.8527	1.0472	0.9682	0.9401	0.9401	0.9401	0.9401	0.9401	0.9401	1.7661	2.6254	
			7	2.0011	1.9225	1.7377	2.1473	1.7919	1.7919	1.7919	1.7919	1.7919	1.7919	1.7919	1.7919	1.3413
		Setiembre	14	1.3632	1.2103	1.0444	1.1487	1.1487	1.1487	1.1487	1.1487	1.1487	1.3398	1.1480	1.0745	
			15	1.8982	1.7858	1.8068	1.8068	1.8068	1.8068	1.8068	1.8068	1.7588	1.7923	1.7191		
			16	2.3085	1.5799	2.1329	2.1689	2.1689	2.1689	2.1689	2.1689	2.0855	2.1689	2.0483		
			17	2.4757	2.3770	2.4643	2.4643	2.4643	2.4643	2.4643	2.4643	2.4643	2.4643	2.4643	2.4678	
			18	1.1874	1.3674	1.2646	1.8254	1.3181								
			19	2.3882	2.0820	2.3561	2.2664	2.2664	2.2664	2.2664	2.2664	2.2664	2.2664	1.8690	2.1012	
			20	1.6117	1.6883	2.4911	1.3726	1.7631	2.6418							
		Noviembre	8	3.2065	3.0407	3.0190	3.0009	3.0009	3.0009	3.0009	3.0009	3.0009	3.0009	3.0467	4.3283	
			9	1.9514	1.8065	1.6567	1.6074	1.6074	1.6074	1.6074	1.6074	1.6074	1.6074	1.8260	1.6137	
			10	1.2627	1.2882	0.8656	1.1842	0.8826								
			11	2.2596	2.2012	1.9733	2.0009	2.0009	2.0009	2.0009	2.0009	2.0009	2.0009	1.9577	2.6969	
			12	1.2496	1.1503	0.8318	0.8213	0.8318								
			13	0.9466	0.8884	0.6020	0.5603	0.6659								
			14	3.1013	3.4364	3.5035	3.5863	3.1988	3.1988	3.1988	3.1988	3.1988	3.1988	2.8991	6.2584	

(Fuente: Elaboración propia)

Los resultados presentados en la Tabla N° 5.5 continúan mostrando las mismas observaciones realizadas en la Tabla N° 5.4, incrementar el número de datos en el entrenamiento no ayudó a mejorar la validación. En la Fig. 5.4 se compara las validaciones de la Tabla N° 5.5 con la de COES, y se pone en evidencia que la metodología propuesta presentó, en grande proporción, un mejor desempeño para los meses de marzo y setiembre; sin embargo, la metodología COES logró superarla categóricamente para los meses de enero y noviembre del 2020.

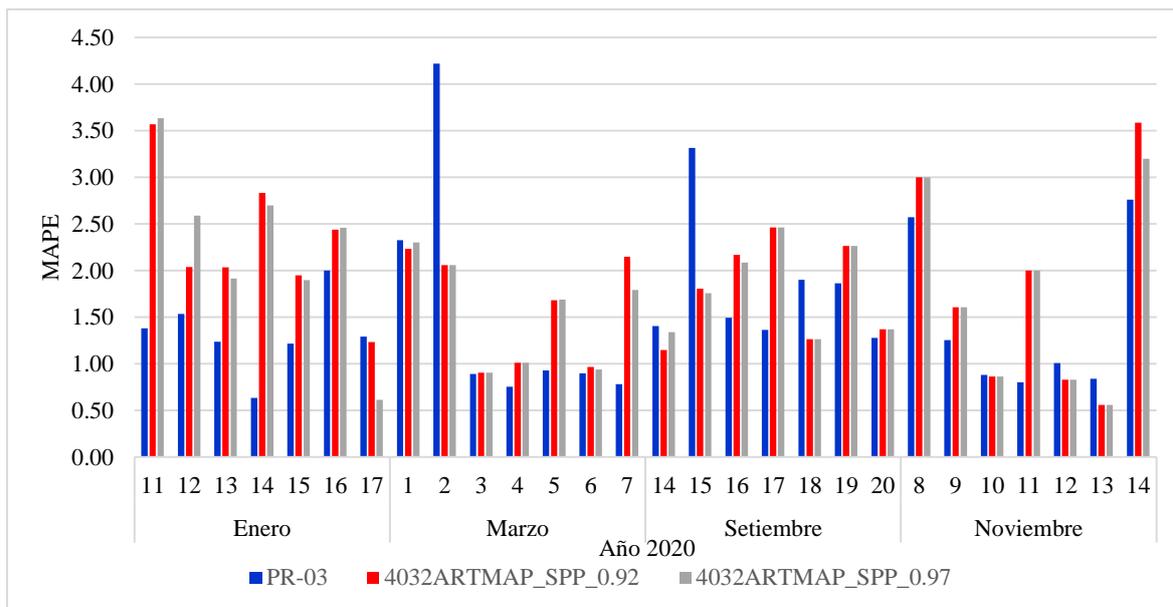


Fig. 5.4 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP *Fuzzy* para 4032 datos sin pre-procesamiento – 2020.
(Fuente: Elaboración propia)

Para el segundo escenario, se obtuvieron datos estandarizados utilizando la metodología del pre-procesamiento con un alcance medio-horario pertenecientes a los años 2018, 2019 e 2020. Se seleccionó semanas aleatorias Tabla N° 4.2 para diferentes meses dentro de los años 2019 y 2020 con la finalidad de realizar los pronósticos diarios. Finalmente para la validación del desempeño del pronóstico de demanda se utilizó los datos ejecutados reales de los días en cuestión.

En la Tabla N° 5.6 y Tabla N° 5.7 se muestran las validaciones en términos de MAPE para pronósticos diarios pertenecientes a los meses de febrero, mayo, agosto y octubre del 2019, las cuales fueron evaluados utilizando la metodología del pre-procesamiento en la gestión de datos históricos. Como se puede observar en estas tablas, existen diferentes resultados para una variedad amplia de parámetros de vigilancia, de los cuales los más destacados son para 0.92 y 0.97 por presentar en mayor proporción, entre otros parámetros, valores eficientes en términos del MAPE.

Tabla N° 5.6 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP *Fuzzy* para 2688 datos con pre-procesamiento - 2019.

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia														
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99				
2688	2019	Febrero	15	2.8246	2.8003	2.1046	2.2911	2.3350	2.3350	2.3350	2.3350	2.3350	2.3350	2.3350	2.3350	1.8885		
			16	3.2905	3.2905	3.0284	2.9631	2.9631	2.9631	2.9631	2.9631	2.9631	2.9631	2.9631	2.9631	2.9631	2.0957	
			17	3.4595	3.3440	1.4760	3.4021	3.4021	3.4021	3.4021	3.4021	3.4021	3.4021	3.4021	3.4021	3.4021	3.4021	2.4204
			18	1.6699	1.5453	1.3511	1.6896	1.6343	1.6343	1.6343	1.6343	1.6343	1.6343	1.6343	1.6343	1.6343	1.6343	1.3517
			19	1.5451	1.6105	1.2747	1.4043	1.4411	1.3462									
			20	2.1807	2.4614	2.2930	2.0209	2.0209	2.0209	2.0209	2.0209	2.0209	2.0209	2.0209	2.0209	2.0209	1.9718	2.1189
			21	2.4594	2.4831	2.1906	2.3877	2.4050	2.4050	2.4050	2.4050	2.4050	2.4050	2.4050	2.4050	2.4050	2.4050	2.4742
		Mayo	17	2.0597	1.8935	1.8026	1.8621	1.8621	1.8621	1.8621	1.8621	1.8621	1.8621	1.8621	1.8621	1.8621	1.7103	
			18	2.0927	2.0927	1.9036	1.4491	1.9000	1.9000	1.9000	1.9000	1.9000	1.9000	1.9000	1.9000	1.9000	1.5814	
			19	1.8025	1.8343	1.6048	1.4493											
			20	1.9364	1.9364	1.7498	1.7252	1.7252	1.7252	1.7252	1.7252	1.7252	1.7252	1.7252	1.7252	1.7252	1.6577	
			21	1.3046	1.3046	1.1355	1.2178	1.1842	1.2077									
			22	1.2710	1.2710	1.2620	1.1904	1.3356	1.3347									
		Agosto	23	2.5270	2.5270	2.3526	3.0336	2.4875	2.4875	2.4875	2.4875	2.4875	2.4875	2.4875	2.4875	2.4875	3.1091	
			12	1.8006	1.8006	1.8662	1.4543	1.6338	1.6338	1.6338	1.6338	1.6338	1.6338	1.6338	1.6338	1.6338	2.0847	
			13	1.5308	1.5308	1.6865	1.4101	1.3736	1.5627									
			14	2.2273	2.2273	2.0402	2.1982	2.1982	2.1982	2.1982	2.1982	2.1982	2.1982	2.1982	2.1982	2.2483	2.1757	
			15	1.5552	1.5552	1.5045	1.3340	1.2399	1.2664									
			16	1.1329	1.1329	1.3513	1.0870	1.0625										
			17	0.8233	0.8233	0.7224	0.6089	0.5261	0.5597									
			18	1.7624	1.7624	1.2739	1.2959	1.4401										
			20	1.5120	1.7346	4.4253	1.0899	1.8912										
			21	1.4499	1.4499	2.3513	2.4447	1.2053	1.5056									
		Octubre	22	1.9437	1.9437	2.0163	1.7477	1.8064	1.8064	1.8064	1.8064	1.8064	1.8064	1.8064	1.8064	1.8064	1.9217	
			23	1.4799	1.4609	1.5074	1.3006	1.3101	1.2772	2.4979								
			24	1.9115	1.9115	2.0471	1.7891	1.7655	1.7655	1.7655	1.7655	1.7655	1.7655	1.7655	1.7655	1.7655	2.4295	
25	1.2007		1.2007	0.9858	0.9088	1.2592												
26	1.2505		1.2505	1.1290	1.0732	1.0704	2.0855											

(Fuente: Elaboración propia)

En relación a la validación efectuada mediante la primera metodología, la *Tabla N° 5.6* muestra el desempeño de la red neuronal. Es así que por medio de esta, se selecciona los parámetros más destacados del intervalo comentados anteriormente para de esta forma ser comparado con las de COES, ilustrados en la *Fig. 5.5*. Los resultados demuestran de forma categórica la superioridad en cuanto a pronóstico de esta metodología, el entrenamiento para la obtención de estos desempeños eficientes se realizó con 2688 datos históricos pre-procesados.

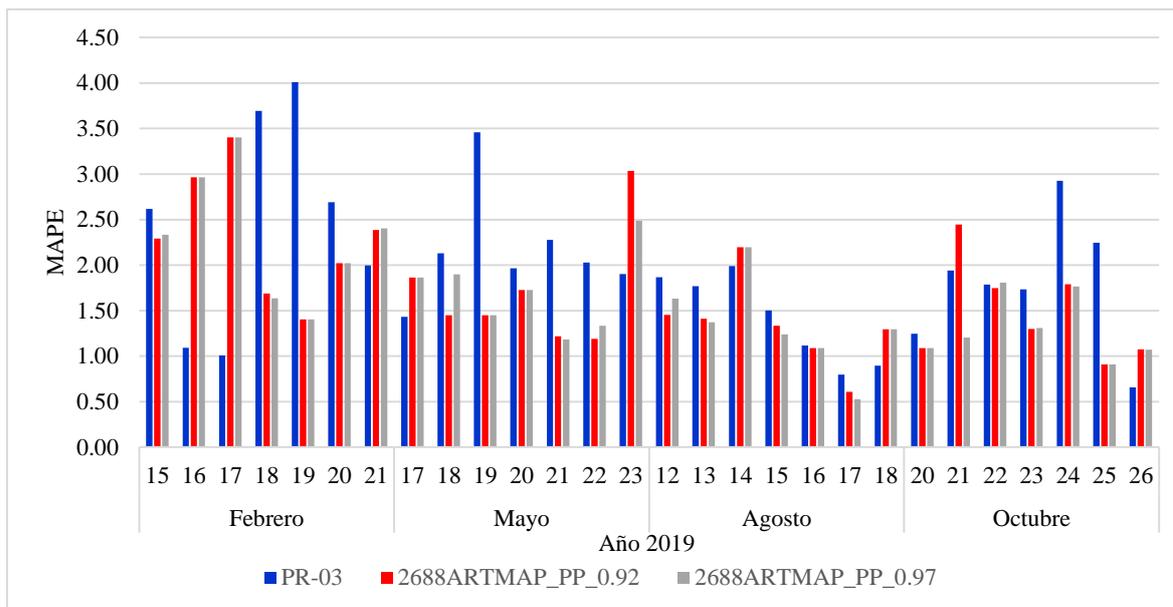


Fig. 5.5 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 2688 datos con pre-procesamiento – 2019.
(Fuente: Elaboración propia)

Tabla N° 5.7 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 4032 datos con pre-procesamiento - 2019.

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia												
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99		
4032	2019	Febrero	15	2.6987	2.5979	2.3946	2.3048	2.3048	2.3048	2.3048	2.3048	2.3048	2.3048	2.2048	2.1905	
			16	3.3062	3.2682	3.1087	2.9849	2.9849	2.9849	2.9849	2.9849	2.9849	2.9849	2.9849	2.9849	2.9990
			17	3.4161	3.3749	3.1689	3.3413	3.3413	3.3413	3.3413	3.3413	3.3413	3.3413	3.3413	3.1473	1.5274
			18	1.7260	1.7488	1.3476	1.5213	1.5332	1.5332	1.5332	1.5332	1.5332	1.5332	1.5332	1.5332	1.3501
			19	1.6120	1.6120	1.4786	1.7406	1.4409	1.4409	1.4409	1.4276	1.4409	1.6400	2.3499		
			20	2.1440	2.1440	2.0299	1.9890	1.9890	1.9890	1.9890	1.9890	1.9890	1.9890	2.0265	1.9775	
			21	2.3673	2.3884	2.3447	2.2596	2.2891	2.2891	2.2891	2.2891	2.2891	2.2891	2.2891	2.2891	2.3088
		Mayo	17	2.1098	1.9290	1.8697	1.7643	1.7867	1.7867	1.7867	1.7867	1.7867	1.7867	1.7867	1.7867	1.8203
			18	2.1185	2.1185	1.9867	1.9064	1.9109	1.9109	1.9109	1.9109	1.9109	1.9109	1.9109	1.9109	1.7023
			19	1.8201	1.8283	1.5674	1.4340									
			20	1.9721	1.9721	1.8958	1.7764	1.7764	1.7764	1.7764	1.7764	1.7764	1.7764	1.7764	2.1841	
			21	1.3660	1.5133	1.1138	1.2541	1.2149	1.6320	1.4560						
			22	1.3360	1.3602	1.2043	1.3740	1.3045								
			23	2.5526	2.6055	2.2288	3.0141	2.4945	2.4945	2.4945	2.4945	2.4945	2.4945	2.4945	2.4945	2.3890
		Agosto	12	1.8744	1.8744	2.0049	1.6823	1.6823	1.6823	1.6823	1.6823	1.6823	1.6823	1.6823	1.6823	1.6912
			13	1.5108	1.5108	1.5168	1.3473	1.3598	1.3372							
			14	2.1391	2.1391	2.0198	2.3053	2.0828	2.0828	2.0828	2.0828	2.0828	2.0828	2.1366	1.6881	
			15	1.5587	1.5587	1.2292	1.2522	1.2327	1.2136							
			16	1.1436	1.1436	1.1675	1.0324	1.1090	1.0953							
			17	0.8147	0.8147	0.7346	0.6890	0.5617	0.7972							
			18	1.7319	1.7319	1.3929	1.2609	1.2425								
			20	1.5120	1.7346	4.4253	1.0899	1.8912								
		Octubre	21	1.6548	1.6341	2.6096	1.2792	1.2929	2.6045							
			22	1.9499	1.9499	2.1158	1.8944	1.7740	1.7740	1.7740	1.7740	1.7740	1.7740	1.7740	1.7740	2.0691
			23	1.4694	1.8154	1.3930	1.3243	1.5645	2.5088							
			24	1.8742	1.8194	2.1079	1.9022	1.6717	1.6717	1.6717	1.6717	1.6717	1.6717	1.6717	1.6717	1.6717
25	1.2457		1.1686	1.7389	0.9826	0.9418	2.7539									
26	1.2019		1.2019	1.8481	1.1172	1.9574										

(Fuente: Elaboración propia)

En la Tabla N° 5.7 se muestra la validación del pronóstico de la demanda eléctrica utilizando la metodología de pre-procesamiento con 4032 datos, los resultados no difirieron al presentado en la Tabla N° 5.6 con 2688. En la figura Fig. 5.6 se puede observar que los resultados para los pronósticos diarios fueron superiores en referencia a la efectuada por COES.

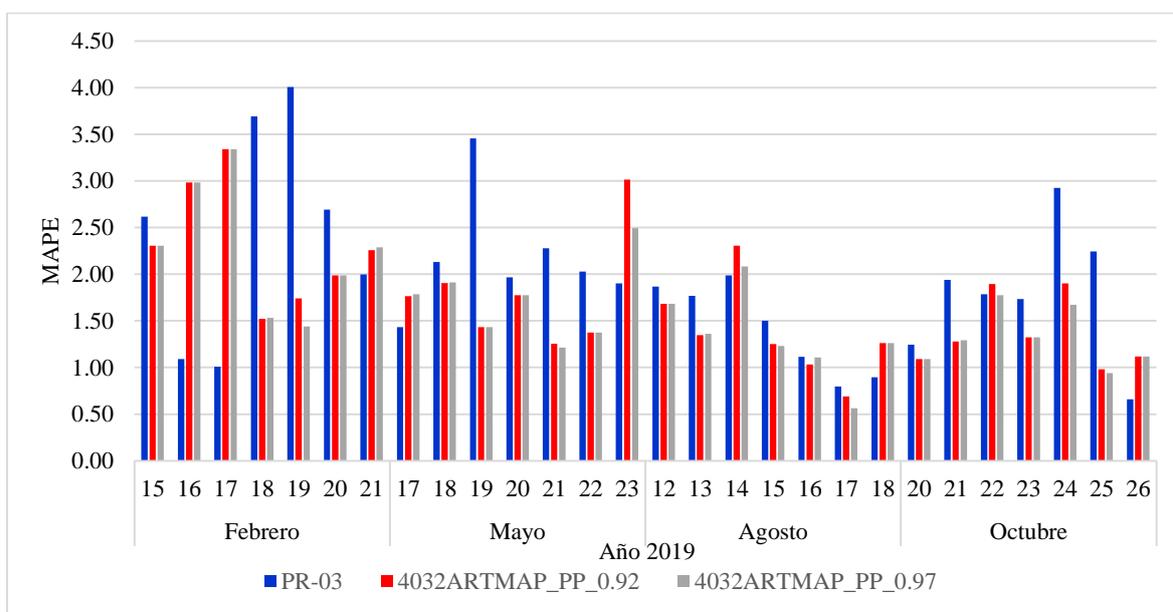


Fig. 5.6 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP *Fuzzy* para 4032 datos con pre-procesamiento – 2019.

(Fuente: Elaboración propia)

En la Tabla N° 5.8 y Tabla N° 5.9 se muestran las validaciones en términos de MAPE para los pronósticos de demanda eléctrica diaria pertenecientes a los meses de enero, marzo, setiembre y noviembre del 2020 utilizando la metodología del pre-procesamiento. En las tablas mencionadas, se muestran resultados para una variedad de parámetros de vigilancia, de los cuales los más destacados en términos de MAPE, se encuentran en el intervalo de 0.92 a 0.97 por presentar en mayor proporción, entre otros parámetros, valores eficientes.

Tabla N° 5.8 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP *Fuzzy* para 2688 datos con pre-procesamiento - 2020.

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia											
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99	
2688	2020	Enero	11	3.7303	3.9191	3.7100	3.6280	3.6280	3.6280	3.6280	3.6280	3.6280	3.6280	3.6280	3.5968
			12	2.8727	2.8727	2.1726	1.9796	2.6263	2.6263	2.6263	2.6263	2.6263	2.6263	2.6263	1.9999
			13	1.8196	1.9297	2.0580	1.8669	1.8731	1.8731	1.8731	1.8731	1.8731	1.8731	1.9090	1.8748
			14	2.8252	2.8861	2.6367	2.8286	2.7352	2.7352	2.7352	2.7352	2.7352	2.7086	2.4176	
			15	1.8059	1.8493	1.6575	1.5573	1.4822	1.6570						
			16	2.7586	2.7586	2.6470	2.3668	2.3917	2.3917	2.3917	2.3917	2.3917	2.3917	2.3917	2.3497
			17	1.2533	1.2533	0.8820	0.7929	0.5882	0.6648						
		Marzo	1	2.6462	2.6554	1.9933	2.3861	2.3861	2.3861	2.3861	2.3861	2.3861	2.3861	2.3861	2.3014
			2	2.2074	2.1781	2.5170	1.9962	1.9962	1.9962	1.9962	1.9962	1.9962	1.9962	1.9962	1.8813
			3	1.3456	1.1719	1.9476	1.1197	1.1399	3.0409						
			4	1.6445	1.1472	1.0327	1.1747	1.1167	1.1207						
			5	1.9638	1.8228	1.6264	1.7390	1.7390	1.7390	1.7390	1.7390	1.7390	1.5935	1.7635	
			6	2.0107	1.3312	1.1844	1.4893	1.8191	1.8191	1.8191	1.8191	1.8191	1.8191	1.1480	1.1152
			7	2.1237	2.1018	2.0445	1.7967	1.9794	1.9794	1.9794	1.9794	1.8176	1.8176	2.0199	
		Setiembre	14	1.5624	1.4342	1.3165	1.2396	1.2396	1.2396	1.2396	1.2396	1.2396	1.2747	1.3742	
			15	1.8987	1.8987	1.7312	1.7120	1.7120	1.7120	1.7120	1.7120	1.7120	1.7120	1.4088	
			16	2.4129	2.4129	2.1410	2.1271	2.1271	2.1271	2.1271	2.1271	2.1271	2.1271	2.1116	
			17	2.5425	2.4825	2.2040	1.9998	2.3900	2.3900	2.3900	2.3900	2.3900	2.3296	1.2299	
			18	1.2482	1.2482	1.2658	1.1705	0.9285							
			19	2.3300	2.3300	2.3596	2.1455	2.1743	2.1743	2.1743	2.1743	2.1743	2.1743	1.9562	
20	1.6296		1.6296	2.1572	1.4419	2.1946									
Noviembre	8	3.1934	3.1934	3.1335	3.0185	3.0185	3.0185	3.0185	3.0185	3.0185	3.0185	3.0576			
	9	1.8678	1.8521	1.3639	1.5151	1.5151	1.5151	1.5151	1.5151	1.5151	1.5151	1.5704			
	10	1.3146	1.3535	1.2593	0.9156	1.2162	1.2552								
	11	2.3148	2.2753	1.9874	2.0258	2.0258	2.0258	2.0258	2.0258	2.0258	1.9969	2.0427			
	12	1.1870	1.1520	0.8332	0.8275	0.8275	0.8275	0.8275	0.8275	0.8275	0.8442	0.8275			
	13	1.0740	1.0151	1.0599	0.6182	0.6922									
	14	3.1755	3.0021	3.4644	3.2862	3.1603	3.1603	3.1603	3.1603	3.1603	2.9036	3.2266			

(Fuente: Elaboración propia)

En la Tabla N° 5.8 se presenta la validación en términos de MAPE utilizando la red ARTMAP *Fuzzy* para 2688 datos pre-procesados. De forma general los resultados no lograron superar al presentado en la Tabla N° 5.4, la cual fue entrenada con la misma cantidad de datos y sin ser sometidos a un pre-proceso.

En la figura Fig. 5.7 se muestra un diagrama de barra que compara la validación utilizando la metodología de COES con los resultados obtenidos en la Tabla N° 5.8 para los parámetros de vigilancia de 0.92 y 0.97. Como conclusión se observa que para los días 11 de enero y 8 y 14 de noviembre desbordaron el tres por ciento en términos de MAPE.

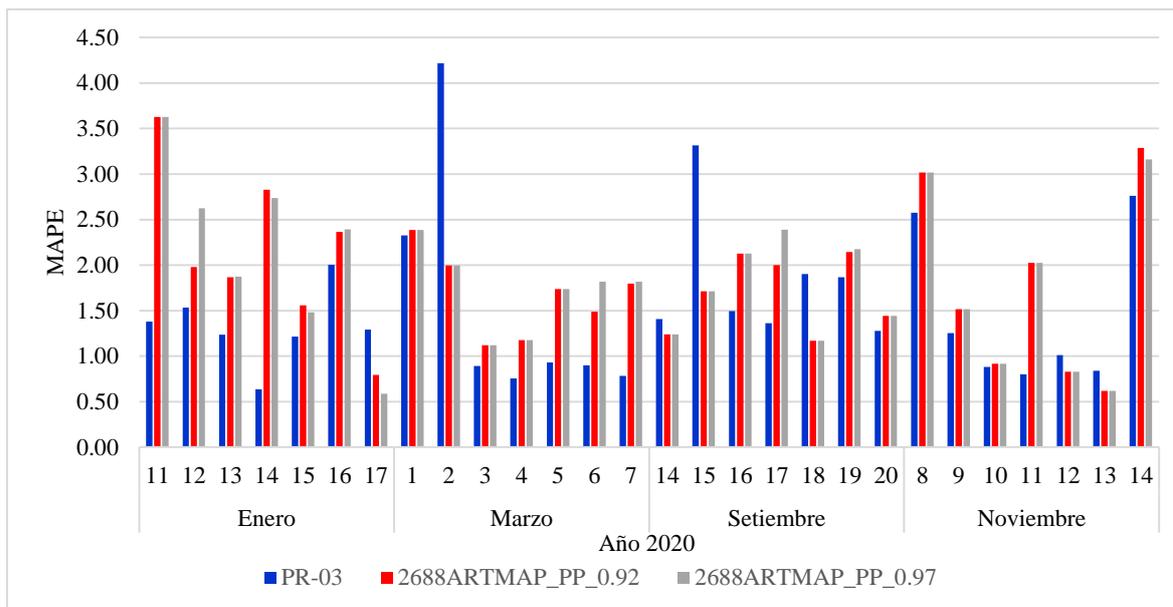


Fig. 5.7 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP *Fuzzy* para 2688 datos con pre-procesamiento – 2020.
(Fuente: Elaboración propia)

Tabla N° 5.9 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP *Fuzzy* para 4032 datos con pre-procesamiento - 2020.

Datos Entrenados	Año	Mes	Día	Parámetros de Vigilancia											
				0.89	0.9	0.91	0.92	0.93	0.94	0.95	0.96	0.97	0.98	0.99	
4032	2020	Enero	11	3.7319	3.9078	3.5791	3.5436	3.6087	3.6087	3.6087	3.6087	3.6087	3.6087	3.6087	3.5443
			12	2.7178	2.7178	1.8901	2.1538	2.6324	2.6324	2.6324	2.6324	2.6324	2.6324	2.6324	2.1113
			13	1.9251	2.0306	2.4406	2.0502	1.9268	1.9268	1.9268	1.9268	1.9268	1.9268	2.0353	2.1361
			14	2.7568	2.8829	3.4585	2.2425	2.7133	2.7133	2.7133	2.7133	2.7133	2.7133	2.7133	2.5320
			15	1.8134	1.8315	1.7912	1.4724	1.4322	1.5120						
			16	2.7995	2.7995	2.7335	2.4412	2.4412	2.4412	2.4412	2.4412	2.4412	2.4412	2.4412	2.2715
			17	1.1801	1.1801	1.1819	1.0798	0.6349	0.6730						
		Marzo	1	2.6356	2.6356	2.3754	2.2695	2.3326	2.3326	2.3326	2.3326	2.3326	2.3183	1.9918	
			2	2.3140	2.1093	2.0300	2.0414	2.0414	2.0414	2.0414	2.0414	2.0414	1.6284	2.2329	
			3	1.3241	1.1038	4.3984	1.0455	4.2280							
			4	1.4095	1.2337	1.0767	2.9339	1.1910	1.1910	1.1910	1.1910	1.1910	1.1910	1.0716	1.4204
			5	1.9930	1.8919	2.2591	1.7956	1.7956	1.7956	1.7956	1.7956	1.7828	1.4632	2.5459	
			6	2.1622	1.8431	1.1260	1.4417	1.8082	1.8082	1.8082	1.8082	1.8082	1.8807	2.5104	
			7	2.0279	1.9946	1.9066	2.2263	1.9516	1.9516	1.9516	1.9516	1.7856	1.7693	1.3085	
		Setiembre	14	1.3679	1.2276	1.0613	1.1656	1.1656	1.1656	1.1656	1.1656	1.3528	1.1284	1.0707	
			15	1.8337	1.6972	1.7547	1.7547	1.7547	1.7547	1.7547	1.7531	1.7531	1.7880	1.6969	
			16	2.3412	1.8489	2.1613	2.1973	2.1973	2.1973	2.1973	2.1139	2.1973	2.1973	2.0767	
			17	2.4300	2.3705	2.4631	2.4631	2.4631	2.4631	2.4631	2.4631	2.4631	2.4631	2.4666	
			18	1.1682	1.3775	1.2671	1.8501	1.3261							
			19	2.3480	2.0911	2.2671	2.1801	2.1801	2.1801	2.1801	2.1801	2.1801	1.8434	2.0909	
			20	1.5596	1.7484	2.5056	1.3760	1.3760	1.3760	1.3760	1.3760	1.3760	1.7462	2.6556	
		Noviembre	8	3.2065	3.0407	3.0190	3.0009	3.0009	3.0009	3.0009	3.0009	3.0009	3.0467	4.3283	
			9	1.9514	1.8065	1.6567	1.6074	1.6074	1.6074	1.6074	1.6074	1.6074	1.8260	1.6137	
			10	1.2627	1.2882	0.8656	1.1842	0.8826							
			11	2.2596	2.2012	1.9733	2.0009	2.0009	2.0009	2.0009	2.0009	2.0009	1.9577	2.6969	
			12	1.2496	1.1503	0.8318	0.8213	0.8318							
			13	0.9466	0.8884	0.6020	0.5603	0.6659							
			14	3.1013	3.4364	3.5035	3.5863	3.1988	3.1988	3.1988	3.1988	3.1988	2.8991	6.2584	

(Fuente: Elaboración propia)

En la Tabla N° 5.9 se muestra la validación de la primera metodología en la cual se utilizó 4032 datos históricos pre-procesados para entrenar a la red neuronal. Estos resultados comparados con la validación sin pre-proceso de la Tabla N° 5.5 no arrojaron ningún cambio sustancial en la validación.

En la figura Fig. 5.8 se muestra un diagrama de barra que compara la validación utilizando la metodología de COES con los resultados obtenidos en la Tabla N° 5.9 para los parámetros de vigilancia de 0.92 y 0.97. Como conclusión, al igual que la Fig. 5.7, se observa que para los días 11 de enero y 8 y 14 de noviembre desbordaron el tres por ciento en términos de MAPE.

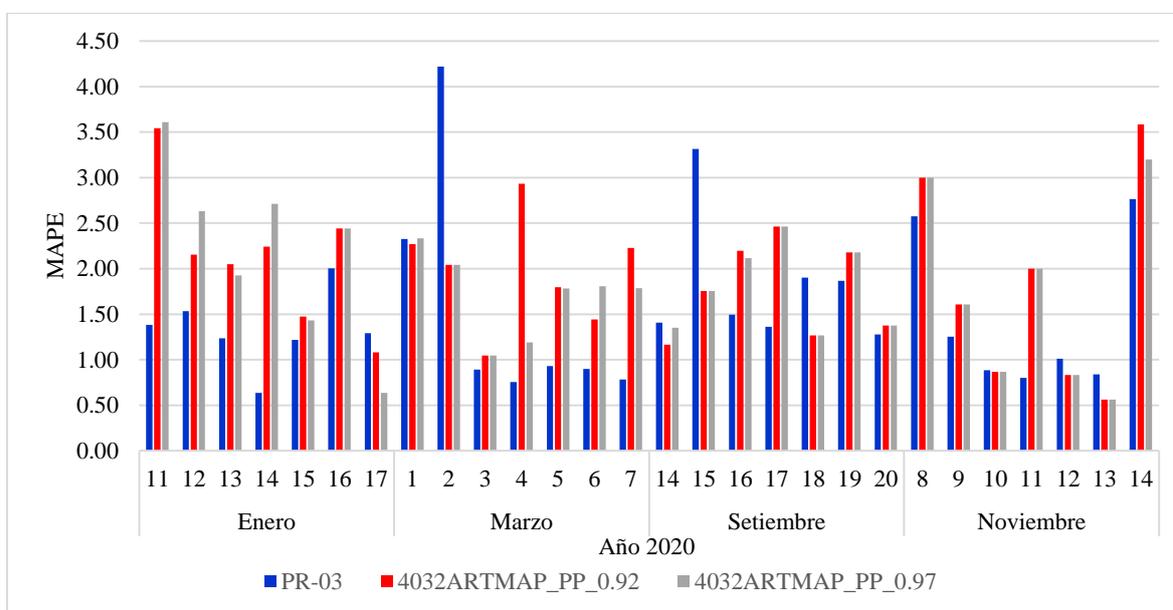


Fig. 5.8 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP *Fuzzy* para 4032 datos con pre-procesamiento – 2020.

(Fuente: Elaboración propia)

5.2 Resultados de la segunda metodología

En esta sub sección se presentan los resultados del pronóstico de demanda eléctrica de la Tabla N° 4.3 utilizando la segunda metodología. Los resultados se dividen en dos escenarios, el primero relacionado a un entrenamiento de la red neuronal con datos brutos obtenido directamente de los IEOB COES, y el segundo utilizando la metodología del pre-procesamiento de datos. Estos dos escenarios de trabajo fueron desarrollados con la finalidad

de comparar el grado de desempeño que puede resultar de una mejora en la calidad de datos de entrada. Además cada escenario fue dividido en entrenamientos sometidos a 2688 y 4032 datos históricos referentes al día de evaluación. Finalmente para ampliar una gama de opciones de resultados se sometió a una evaluación utilizando funciones de pertinencia del tipo Gaussiana, Campana, Trapezoidal y Triangular.

En la Tabla N° 5.10 y Tabla N° 5.11 se muestran las validaciones en términos del MAPE para pronósticos diarios pertenecientes a los meses de febrero, mayo, agosto y octubre del 2019, los cuales fueron resultados del proceso de entrenamiento con datos brutos extraídos de los IEOD COES.

Tabla N° 5.10 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos sin pre-procesamiento - 2019.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
2688	2019	Febrero	15	2.4272	2.3607	2.7854	2.5549
			16	1.4533	1.4386	1.5287	1.2695
			17	1.8642	1.9398	1.8482	2.0824
			18	1.7472	1.4735	1.5743	2.2666
			19	2.0703	1.9939	1.9910	2.1724
			20	1.9282	1.7753	1.6685	1.8792
			21	1.6034	1.6505	1.5345	1.3322
		Mayo	17	20.2922	18.1239	20.4229	11.4632
			18	1.8306	2.4457	2.2853	3.5844
			19	4.0395	4.0595	4.7727	2.8459
			20	3.5626	3.6061	3.8335	3.0733
			21	1.7639	1.7686	1.9167	2.0329
			22	1.0822	1.1261	1.1630	1.2734
		Agosto	23	2.2640	2.1861	2.3284	2.7419
			12	23.8555	5.6727	4.2251	197.4054
			13	2.2058	2.1176	2.3335	1.8029
			14	1.6952	1.8108	1.8955	1.6265
			15	1.5009	1.5492	1.4194	1.3856
			16	1.3498	1.2814	1.3038	0.9739
			17	2.8189	2.7284	2.5194	2.5645
			18	1.5371	1.5653	1.5655	1.4066
	20		5.8815	5.2593	5.2718	6.1375	
	Octubre	21	5.2867	5.6362	5.0261	6.1599	
		22	18.2938	18.0358	20.1237	17.1831	
		23	1.6085	1.3710	1.5435	1.8257	
		24	1.0411	1.1816	1.5182	1.9109	
25		1.0167	0.7552	0.7116	0.8575		
26		1.5768	1.5412	1.2680	1.3656		

(Fuente: Elaboración propia)

En la Tabla N° 5.10 se muestra la validación del pronóstico de la demanda eléctrica utilizando la segunda metodología, las funciones de pertinencia más destacadas fueron la de campana y la trapezoidal por presentar mejores resultados.

En la Fig. 5.9 se compara mediante diagramas de barras los resultados mostrados en la Tabla N° 5.10 con las calculadas basadas en la metodología COES. De la figura se observa un buen desempeño de los pronósticos; sin embargo, para los días 17 de mayo, 12 de agosto, 20, 21 y 22 de octubre los resultados escapan de forma categórica a los límites de comparación efectuadas.

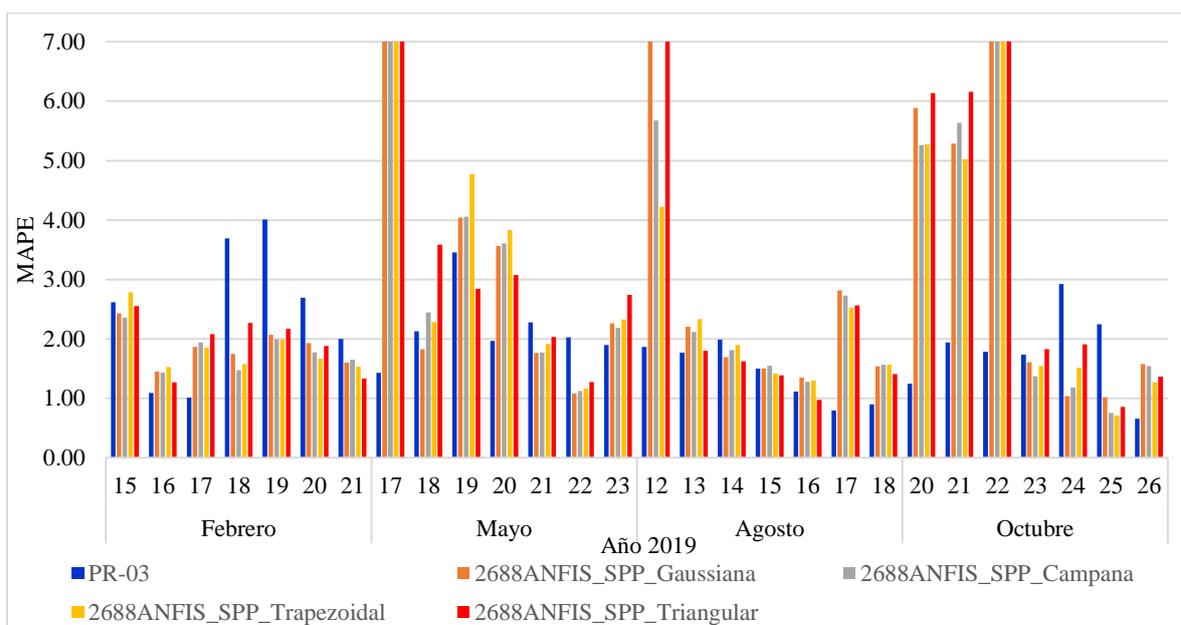


Fig. 5.9 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos sin pre-procesamiento – 2019.

(Fuente: Elaboración propia)

Tabla N° 5.11 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos sin pre-procesamiento - 2019.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
4032	2019	Febrero	15	1.6819	1.5724	1.6017	2.7384
			16	3.2470	3.3642	3.2118	1.8664
			17	3.6868	3.7653	3.8435	3.8078
			18	1.9024	1.8639	1.7711	1.6136
			19	1.5688	1.5593	1.4327	4.0926
			20	2.2643	2.1929	2.1110	2.1220
			21	1.8632	1.8077	1.7448	1.2043
		Mayo	17	47.1646	31.4491	27.1399	9.1880
			18	5.3624	5.4627	3.1824	4.9224
			19	2.4186	2.4932	2.2800	2.3738
			20	1.3513	1.4588	1.3453	2.5765
			21	1.2166	1.4324	1.4175	1.4232
			22	1.5021	1.5629	1.3679	0.9568
			23	1.6539	1.5795	1.7093	4.3363
		Agosto	12	13.0615	15.9081	3.9668	13.4402
			13	1.4256	1.5349	1.1726	1.3224
			14	1.3853	1.5080	1.2065	1.4369
			15	1.3905	1.3755	1.2424	1.5693
			16	0.9156	0.9426	1.0358	1.3571
			17	1.9385	1.9028	1.9062	1.7794
			18	1.4210	1.4630	1.3797	1.4299
			20	2.7752	2.5161	2.8269	2.4800
		Octubre	21	2.9176	3.0540	3.0759	1.7572
			22	3.7624	3.7399	3.8594	19.1707
			23	1.4714	1.4030	1.5644	23.2777
			24	0.9611	0.9970	0.9672	0.9084
25	1.5809		1.6825	1.7220	1.1682		
26	2.7834		2.7627	2.6924	2.6196		

(Fuente: Elaboración propia)

En la Tabla N° 5.11 se presenta la validación de los pronósticos para un entrenamiento con 4032 datos históricos, sin considerar la metodología del pre-procesamiento. Los resultados, en términos amplios, mejoraron considerablemente comparados con la Tabla N° 5.10, en tal sentido las validaciones respecto al MAPE, en el proceso de comparación, para los días 15 y 19 de febrero, 19 al 21 de mayo, el mes de agosto y del 20 al 24 de octubre demostraron ser eficientes y mejoraron de forma proporcional a la cantidad de datos entrenados.

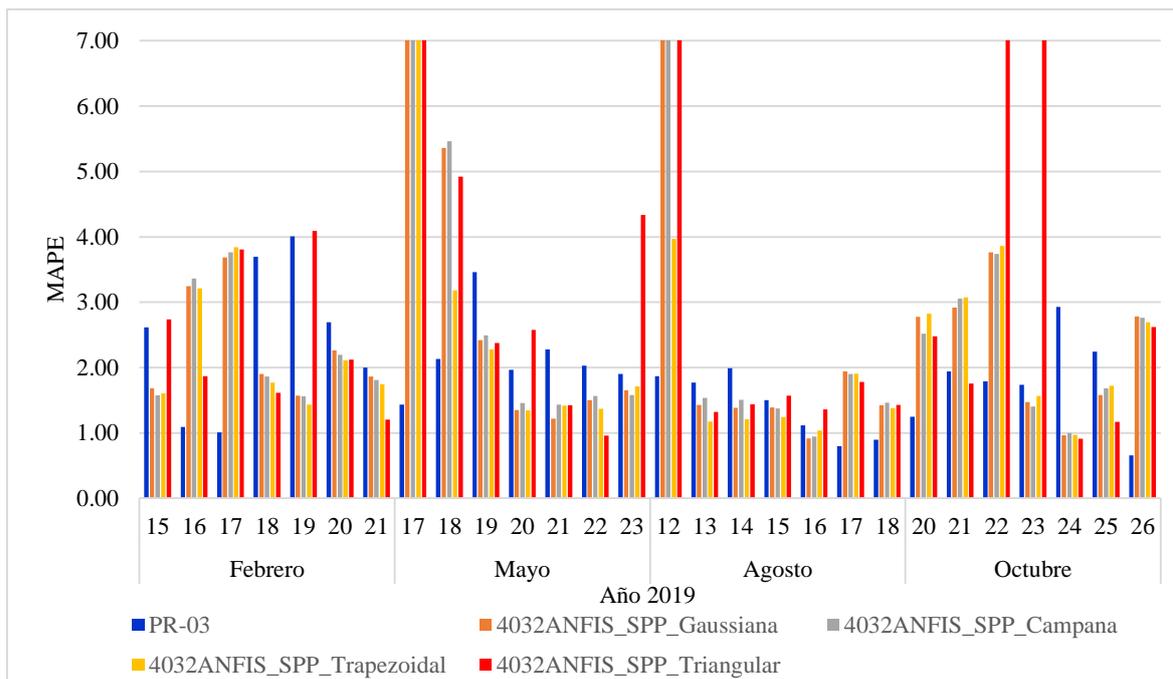


Fig. 5.10 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos sin pre-procesamiento – 2019.

(Fuente: Elaboración propia)

En la Tabla N° 5.12 y Tabla N° 5.13 se muestran las validaciones en términos del MAPE para pronósticos diarios pertenecientes a los meses de enero, marzo, setiembre y noviembre del 2020, en las cuales se usaron los datos brutos extraídos de los IEOD COES. Como se puede observar en las tablas presentadas, existen una amplia gama resultados para las diferentes funciones de pertinencia propuestas.

Tabla N° 5.12 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos sin pre-procesamiento – 2020.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
2688	2020	Enero	11	6.2383	5.7073	4.6867	5.3538
			12	3.3343	2.8680	3.4107	2.6356
			13	2.8137	2.6158	3.8023	2.3395
			14	4.4979	5.4201	6.5037	2.4906
			15	15.3879	28.7466	43.6174	45.9475
			16	7.9583	7.0299	7.4929	8.2349
			17	3.7503	3.7428	3.5161	2.6257
		Marzo	1	2.8720	2.9249	2.5627	2.9209
			2	1.9133	1.9333	1.7241	1.6002
			3	2.0321	2.0390	1.8378	1.9854
			4	1.8732	1.5978	1.4994	1.6832
			5	1.4035	1.2963	1.3253	1.2842
			6	1.2674	1.2973	1.1688	1.8053
			7	1.1201	1.1399	1.0644	0.8442
		Setiembre	14	1.8593	1.8821	1.7300	1.4595
			15	3.1455	3.1469	3.0552	3.3344
			16	4.3760	4.1598	3.9246	4.2355
			17	3.0277	2.9901	2.9921	3.0677
			18	1.3517	1.3188	1.4789	1.1114
			19	1.9597	2.0683	2.2154	1.9432
			20	3.0084	2.9883	2.9475	2.9056
		Noviembre	8	1.6711	1.7810	1.8190	1.4147
			9	0.9630	1.2151	1.0351	1.0161
			10	1.7106	1.7472	1.7289	1.9789
			11	1.1473	1.2383	1.0128	0.8185
			12	1.0705	1.0111	1.0278	2.0229
			13	0.9848	1.0774	0.8643	1.2344
			14	1.4086	1.5543	1.4254	1.3858

(Fuente: Elaboración propia)

En la Tabla N° 5.12 se muestra la validación del pronóstico de la demanda eléctrica utilizando 2688 datos históricos en el proceso de entrenamiento de la red neuronal, los datos utilizados no fueron sometidos a la metodología de pre-procesamiento. Como consecuencia de este entrenamiento se observa en la Fig. 5.11 grandes distorsiones en relación al MAPE para el mes de enero; sin embargo, para los otros meses se mantienen un comportamiento aceptable dentro de las comparaciones efectuadas.

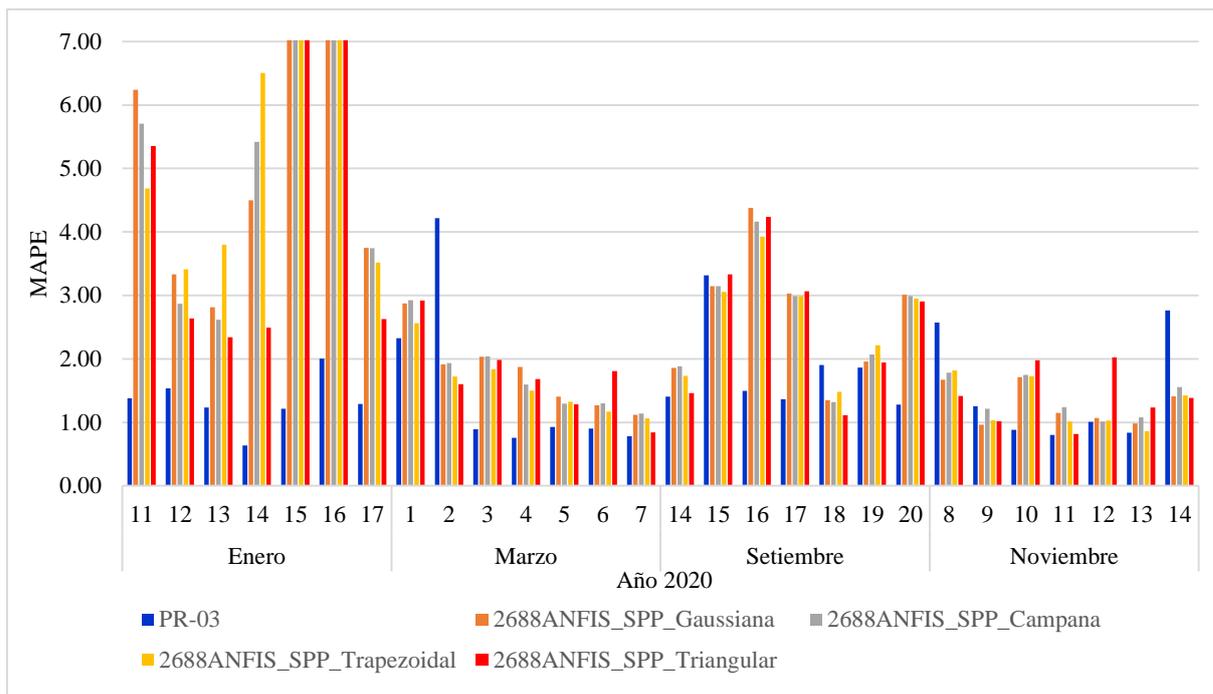


Fig. 5.11 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos sin pre-procesamiento – 2020.

(Fuente: Elaboración propia)

En la Tabla N° 5.13 se muestra las validaciones en términos de MAPE para un pronóstico de demanda eléctrica que utilizó 4032 datos históricos brutos. La Fig. 5.12 muestra una comparación de los resultados COES en relación a los obtenidos utilizando la segunda metodología, se observa que los datos para el mes de enero y noviembre no resultaron tener un buen desempeño, en contraste de los meses de marzo y noviembre.

Tabla N° 5.13 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos sin pre-procesamiento – 2020.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
4032	2020	Enero	11	3.6115	2.4370	3.2277	3.2623
			12	1.4222	1.4032	1.5015	2.2407
			13	2.0405	1.8557	1.8793	4.4922
			14	4.0326	6.2794	4.2013	3.9701
			15	44.8089	39.2016	15.2506	22.3872
			16	6.0992	6.4574	2.9443	5.5309
			17	1.6925	1.7205	1.5495	2.4214
		Marzo	1	2.9096	2.7074	2.8801	3.9274
			2	2.2606	2.2001	2.3439	2.3439
			3	1.9044	1.6809	1.4464	3.1378
			4	1.6352	1.5438	1.3384	1.4461
			5	1.4612	1.4316	1.4878	1.2923
			6	1.0120	1.0432	1.0786	1.0983
			7	0.9274	0.9414	1.0394	1.0078
		Setiembre	14	3.1292	2.8952	2.3964	2.8210
			15	4.5420	4.2525	3.8732	3.1483
			16	5.7984	5.2507	4.5872	5.4471
			17	4.4727	4.3583	4.2395	5.5438
			18	2.0700	2.0692	2.1228	1.4952
			19	2.3083	2.2893	2.3209	3.0787
			20	1.6225	1.6308	1.4929	1.6060
		Noviembre	8	1.4883	1.4911	1.4630	1.2993
			9	1.1905	1.1444	1.2963	5.1120
			10	0.9823	0.9625	0.8972	1.1565
			11	1.0033	0.9642	0.7501	2.4251
			12	1.5222	1.4811	1.2607	2.4031
			13	1.2954	1.2852	1.1802	2.0248
			14	1.2807	1.2956	1.2872	1.2000

(Fuente: Elaboración propia)

Realizando una comparación entre las Tabla N° 5.12 y Tabla N° 5.13, se puede distinguir una mejora considerable en los resultados para los meses de enero, marzo y noviembre; sin embargo para el mes de setiembre las validaciones incrementan en más de una unidad.

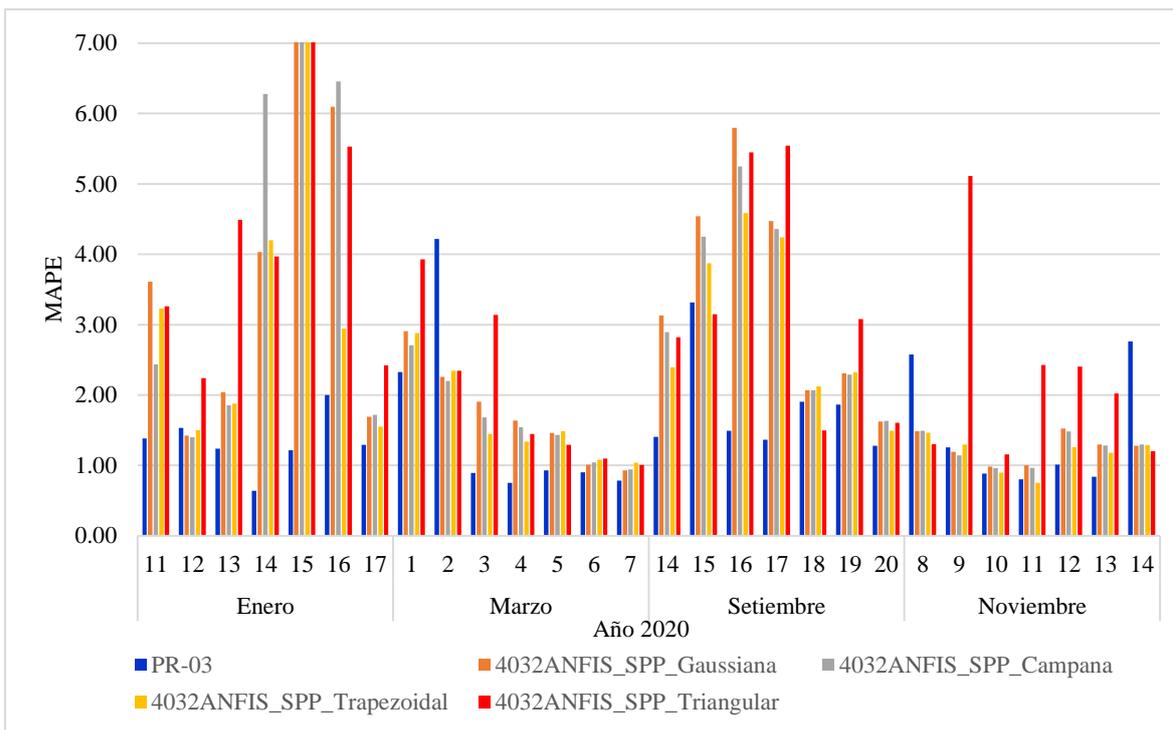


Fig. 5.12 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos sin pre-procesamiento – 2020.

(Fuente: Elaboración propia)

En la Tabla N° 5.14 y Tabla N° 5.15 se muestran las validaciones en términos del MAPE para pronósticos diarios pertenecientes a los meses de febrero, mayo, agosto y octubre del 2019, la cuales son resultados de la metodología del pre-procesamiento.

Tabla N° 5.14 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos con pre-procesamiento - 2019.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
2688	2019	Febrero	15	2.6285	2.5802	2.9848	2.5875
			16	1.3944	1.3243	1.7577	1.8598
			17	1.7080	1.6713	1.4333	2.1322
			18	2.0141	1.5301	1.7278	1.8576
			19	2.3440	2.3581	2.3171	2.0929
			20	1.8814	1.7704	1.6164	1.5543
			21	1.7488	1.7784	1.5214	1.5248
		Mayo	17	2.0729	2.0398	2.0636	2.1456
			18	2.6412	2.5878	2.5306	2.6720
			19	3.4032	3.9980	4.7733	3.5201
			20	3.6630	3.2959	3.7367	7.7425
			21	2.8042	2.5238	2.4877	3.1401
			22	1.4652	1.4023	1.4460	1.7539
			23	3.5837	3.6403	3.7294	3.5925
		Agosto	12	1.7007	1.7594	1.7820	1.6451
			13	1.9932	2.2709	1.8376	2.0196
			14	1.7435	1.9227	1.6596	2.2262
			15	1.1737	1.1931	1.0612	1.0986
			16	0.9548	0.9776	1.0230	0.8748
			17	1.4619	1.4944	1.7458	1.9322
			18	1.2804	1.3928	1.3534	1.2271
		Octubre	20	3.8127	4.7345	4.4888	4.7807
			21	2.9992	3.2572	3.6045	2.6811
			22	2.9175	2.9096	2.7022	2.8532
			23	1.6575	1.4113	1.4214	1.6983
			24	0.9308	1.1621	1.2485	1.1951
25	1.0713		0.7864	0.8829	0.9325		
26	1.6657		1.6431	1.4305	1.2403		

(Fuente: Elaboración propia)

En la Tabla N° 5.14 se presentan los resultados de las validaciones concernientes a la segunda metodología, de manera general, consecuencia del pre-procesamiento de datos se puede observar que los resultados se mantienen en valores tolerables. No se presentó ninguna distorsión en el pronóstico de la demanda, como consecuencia los resultados para los meses de agosto y octubre fueron superiores a la Tabla N° 5.10.

En la Fig. 5.13 se muestra un diagrama de barras en la cual se comparan los resultados en términos de MAPE obtenido por los IEOD COES y la Tabla N° 5.14. La metodología demuestra un comportamiento eficiente para funciones de pertinencia campana y trapezoidal, considerando un histórico de entrenamiento de 2688 datos.

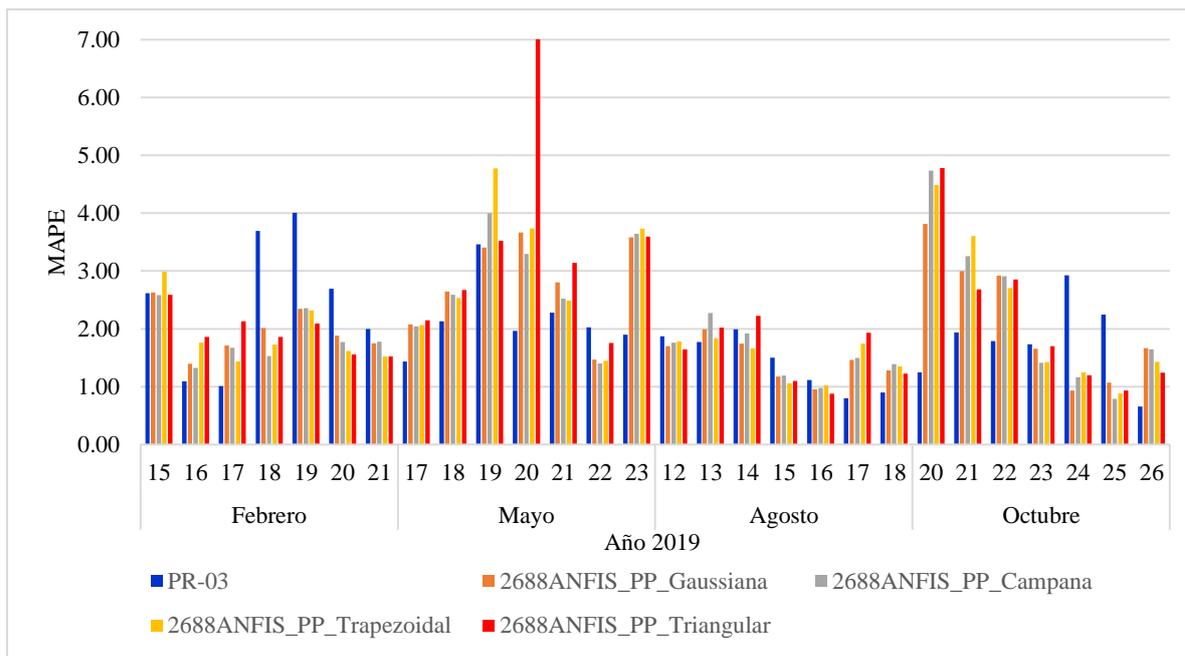


Fig. 5.13 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos con pre-procesamiento – 2019.

(Fuente: Elaboración propia)

Tabla N° 5.15 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos con pre-procesamiento – 2019.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
4032	2019	Febrero	15	1.7640	1.6896	1.7121	2.2004
			16	2.1217	1.9896	1.9223	1.7056
			17	2.9349	2.9012	2.7376	2.8198
			18	1.7094	1.5129	1.6080	2.4495
			19	1.9220	2.5263	2.3440	2.5454
			20	2.1110	2.0267	1.8093	1.8095
			21	1.5441	1.6971	1.2854	1.8717
		Mayo	17	1.6662	1.6862	1.6083	1.7736
			18	1.8352	1.8639	1.9545	2.2316
			19	2.5944	2.3905	2.3867	2.4058
			20	2.1893	2.1258	2.1319	2.3657
			21	1.8175	1.7639	1.3951	1.5070
			22	1.2775	1.1902	1.2294	1.2431
		Agosto	23	2.7959	2.7191	2.7015	2.2052
			12	1.5956	1.6040	1.6724	1.7941
			13	1.3324	1.3945	1.1671	1.6686
			14	1.6187	1.6494	1.5328	2.3170
			15	1.1636	1.1482	1.1287	1.1222
			16	0.7580	0.7877	0.8923	0.7526
			17	1.5385	1.4922	1.5907	1.5130
			18	1.1974	1.2107	1.1802	1.9359
		Octubre	20	2.9649	2.9291	2.7931	2.0925
			21	2.4347	2.5117	2.4567	1.4739
			22	2.3257	2.3141	2.3795	1.8648
			23	1.3292	1.2563	1.3515	12.5575
			24	0.9945	0.9447	0.9536	0.9680
25	1.1222		1.0287	1.1794	1.3377		
26	2.1939		2.2502	2.1281	2.4167		

(Fuente: Elaboración propia)

En la Tabla N° 5.15 se presentan los resultados de las validaciones concernientes a la segunda metodología, se utilizaron 4032 datos para el proceso de entrenamiento de la red, de manera general consecuencia del pre-procesamiento de datos se puede observar que los resultados se mantienen en valores tolerables de pronóstico promedio. Comparada con la Tabla N° 5.14, los resultados para las validaciones de todos los meses mejoraron significativamente.

La Fig. 5.14 muestra la comparación entre los MAPE resultados de la metodología COES comparado con los resultados de la Tabla N° 5.15, los mejores resultados se obtuvieron para las funciones de pertinencia Campana y Trapezoidal.

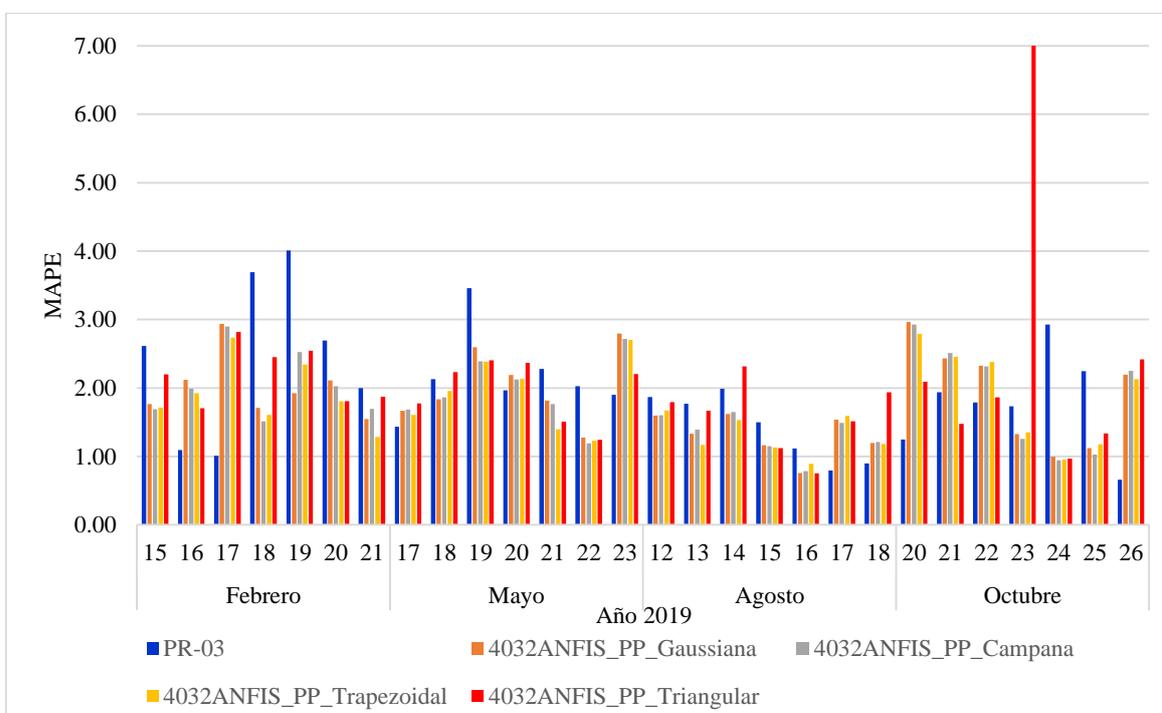


Fig. 5.14 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos con pre-procesamiento – 2019.

(Fuente: Elaboración propia)

En la Tabla N° 5.16 y Tabla N° 5.17 se muestran las validaciones en términos del MAPE para pronósticos diarios pertenecientes a los meses de enero, marzo, setiembre y noviembre del 2020, la cuales son resultados de la metodología del pre-procesamiento.

Tabla N° 5.16 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos con pre-procesamiento – 2020.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
2688	2020	Enero	11	4.1012	4.4850	4.3071	2.9204
			12	2.6558	2.4807	2.4419	2.5821
			13	2.6714	2.6967	2.7862	2.2045
			14	2.5664	2.5201	2.8171	2.3240
			15	5.4719	6.8380	5.1760	5.1272
			16	2.5168	2.5912	2.5000	2.7491
			17	1.7060	1.6631	1.8180	1.9237
		Marzo	1	2.7901	2.6410	2.2193	2.4250
			2	1.6695	1.6494	1.5377	1.4148
			3	1.6985	1.7820	1.5334	2.0005
			4	1.2614	1.2663	1.1978	1.5195
			5	1.4185	1.3638	1.3621	1.1801
			6	0.9292	1.0289	1.0288	1.1011
			7	3.2684	3.2731	3.3080	3.2539
		Setiembre	14	1.5920	1.8711	1.8179	1.4750
			15	3.1105	3.2071	3.2294	5.8900
			16	4.0258	4.1288	3.9056	3.6781
			17	2.9705	3.0750	2.9485	3.1446
			18	1.3142	1.3621	1.4649	1.1691
			19	1.9391	2.0358	2.0405	1.9497
			20	3.1314	3.1779	2.7641	2.8909
		Noviembre	8	1.6711	1.7810	1.8190	1.4147
			9	0.9630	1.2151	1.0351	1.0161
			10	1.7106	1.7472	1.7289	1.9789
			11	1.1473	1.2383	1.0128	0.8185
			12	1.0705	1.0111	1.0278	2.0229
13	0.9848		1.0774	0.8643	1.2344		
14	1.4086		1.5543	1.4254	1.3858		

(Fuente: Elaboración propia)

En la Tabla N° 5.16 se presentan los resultados de las validaciones para el 2020 utilizando la segunda metodología, en esta se entrenó a la red neuronal con 2688 datos históricos. Como consecuencia, los resultados para meses de enero, marzo, y setiembre presentaron desempeños razonablemente eficientes comparados con la Tabla N° 5.12. Sin embargo, el mes de noviembre no sufrió de ninguna variación debido a que los datos históricos considerados en el análisis del pronóstico de la demanda no presentaron modificación en la ejecución del pre-procesamiento.

La Fig. 5.15 muestra la comparación en términos del MAPE de los resultados obtenidos por la metodología COES y los resultados presentados en la Tabla N° 5.16. Gráficamente se observa que para diferentes funciones de pertinencia los meses de marzo y noviembre presentaron mejores desempeños comparados con enero y setiembre.

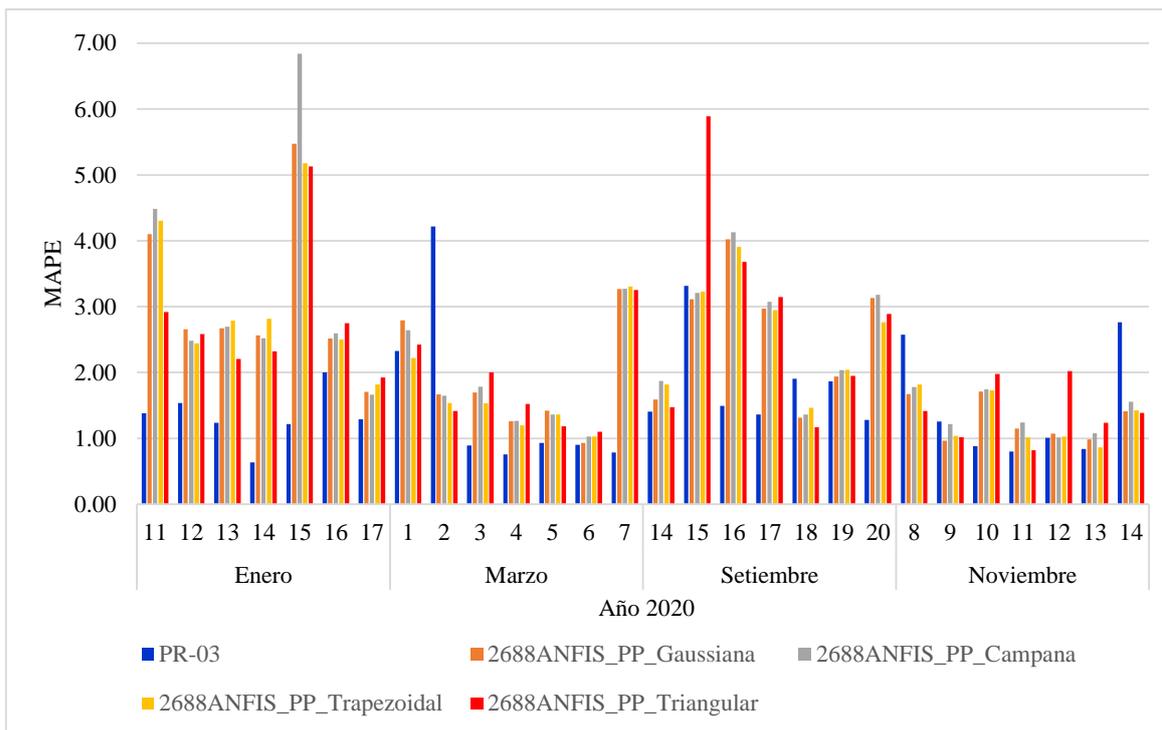


Fig. 5.15 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos con pre-procesamiento – 2020.

(Fuente: Elaboración propia)

Tabla N° 5.17 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos con pre-procesamiento – 2020.

Datos Entrenados	FECHA			MAPE			
	Año	Mes	Día	2 - Funciones de Pertinencia			
				Gaussiana	Campana	Trapezoidal	Triangular
4032	2020	Enero	11	2.5653	1.9812	1.6203	1.5596
			12	1.4751	1.5249	1.5577	1.5587
			13	1.4525	1.4934	1.6881	1.8791
			14	1.5646	1.5833	1.1155	1.1544
			15	2.8371	2.9438	3.0149	3.7398
			16	3.2026	3.2480	2.9368	10.6067
			17	1.2725	1.3095	1.2406	1.8177
		Marzo	1	3.0284	2.8394	3.1183	3.5587
			2	1.8399	1.9280	2.0051	2.2361
			3	1.8703	1.3211	1.3211	6.3623
			4	1.4488	1.3780	0.9701	1.4402
			5	1.4375	1.4525	1.4166	1.3715
			6	1.0706	1.0338	1.0432	8.1089
			7	2.6737	2.7835	3.0501	6.1282
		Setiembre	14	3.3196	2.9051	2.3960	3.4382
			15	4.8998	4.6335	4.0768	3.1031
			16	6.0394	5.4442	4.6333	5.3004
			17	4.5530	4.1012	4.1478	4.8589
			18	2.2437	2.2319	2.1586	1.9430
			19	2.2695	2.3104	2.3282	2.2428
			20	1.4395	1.4333	1.3056	1.9675
		Noviembre	8	1.4883	1.4911	1.4630	1.2993
			9	1.1905	1.1444	1.2963	5.1120
			10	0.9823	0.9625	0.8972	1.1565
			11	1.0033	0.9642	0.7501	2.4251
			12	1.5222	1.4811	1.2607	2.4031
			13	1.2954	1.2852	1.1802	2.0248
			14	1.2807	1.2956	1.2872	1.2000

(Fuente: Elaboración propia)

En la Tabla N° 5.17 se presentan los resultados de las validaciones para el 2020 utilizando la segunda metodología, en esta se entrenó a la red neuronal con 4032 datos históricos. Como consecuencia, los mejores meses que se adaptaron a la cantidad de datos entrenados fueron enero y noviembre, este desempeño es consecuencia de la selección de las funciones de pertinencia Campana y Trapezoidal como parte de la metodología de cálculo.

En la Fig. 5.16 se presenta un diagrama de barras que compara en términos del MAPE los resultados obtenidos por la metodología COES y los resultados presentados en la Tabla N° 5.17. Se observa del gráfico que la metodología usada por COES presenta un mejor desempeño, no en tanto, las funciones de pertinencia Campana y Trapezoidal utilizado en la segunda metodología compite diariamente de forma ajustada para los meses enero y noviembre, inclusive para algunos día de marzo.

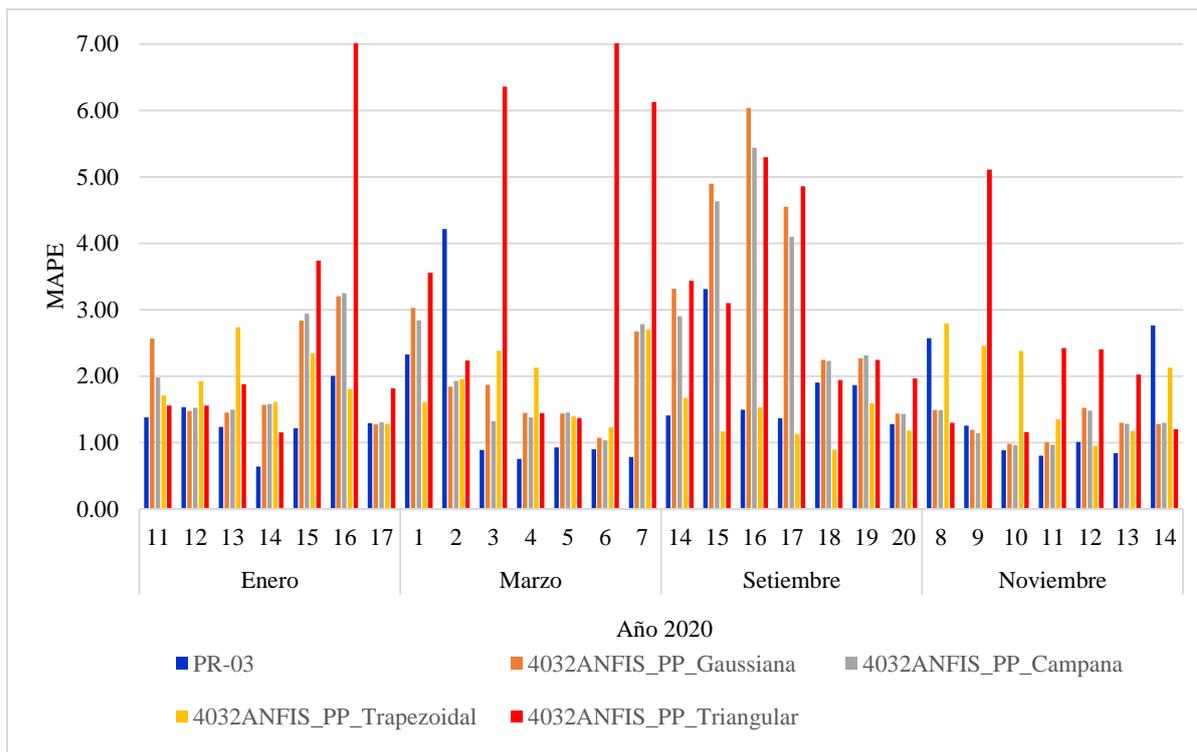


Fig. 5.16 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos con pre-procesamiento – 2020.

(Fuente: Elaboración propia)

5.3 Comentarios

De manera general, teniendo en cuenta las evaluaciones efectuadas en las dos metodologías propuestas. Se observó que para algunos días de análisis futuros existen incrementos de cargas muy por encima a los datos históricos pasados, esto trae consigo que al momento de efectuar validaciones, en términos del MAPE, se presente grandes errores que por naturaleza no podrían ser auxiliados por la propuesta de la metodología del pre-procesamiento de datos.

En relación a los resultados presentados de la primera metodología, se preservó notablemente la plasticidad y estabilidad característica de la red ARTMAP *Fuzzy* para los diferentes escenarios de entrenamiento, siguiendo la tabla de los parámetros definidos de la red neuronal. Además, no existió una diferencia significativa en el proceso de entrenamiento de la red neuronal con 2688 y 4032 datos históricos, de la misma forma al ser sometidos a la metodología del pre-procesamiento. Esto demuestra que las variaciones de los resultados en términos de MAPE, para el análisis de los días aleatorios evaluados, no fueron considerables. El mejor resultado promedio anual para el 2019 fue 1.659 el cual se obtuvo entrenando a la red con 4032 datos históricos brutos para cada uno de los días establecidos

en el año. De la misma forma para 2020, el mejor resultado fue 1.812, el cual se obtuvo por medio de un entrenamiento de 2688 datos sometidos al pre-procesamiento.

Para la segunda metodología, en la cual se utilizó la red neuronal ANFIS, se muestra que para una mayor cantidad de datos entrenados, los resultados en términos de MAPE mejoran significativamente. No obstante, se observa limitaciones en la asociación de los datos, los resultados en términos del MAPE se dispararon para algunos días en evaluación. Estos disparos fueron consecuencia de los entrenamientos y validaciones de la red utilizando datos históricos brutos aplicados a los diferentes escenarios. Sin embargo, se consiguió corregir esta limitación utilizando la metodología del pre-procesamiento. Con la aplicación de esta metodología en la evaluación de los días aleatorios propuestos, el mejor resultado MAPE promedio anual obtenido para el año 2019 fue de 1.758, esta utilizó dos funciones de pertinencia del tipo Trapezoidal. De la misma forma para el 2020, el mejor resultado fue 1.974, también para las dos funciones de pertinencia Trapezoidal.

Los resultados promedios de la metodología en términos de MAPE propuestas por el COES en base a los días aleatorios establecidos en el análisis de la tesis, para el año 2019 fue de 1.956, y para el 2020 fue de 1.53, cabe resaltar que según la metodología COES los datos de la demanda industrial, usuarios libres con demanda mayor o igual a 10 MW son informadas días previos del pronóstico al COES, prácticamente el pronóstico es realizado dirigido a las cargas vegetativas. Realizando una comparación del MAPE entre las metodologías mencionadas y las de COES, la primera metodología que utiliza la red neuronal ARTMAP *Fuzzy*, de alguna u otra forma, garantiza resultados muy próximos a los obtenidos por COES, lo cual significa que la metodología propuesta podría ser usada como candidata hacia un nuevo procedimiento técnico PR-03.

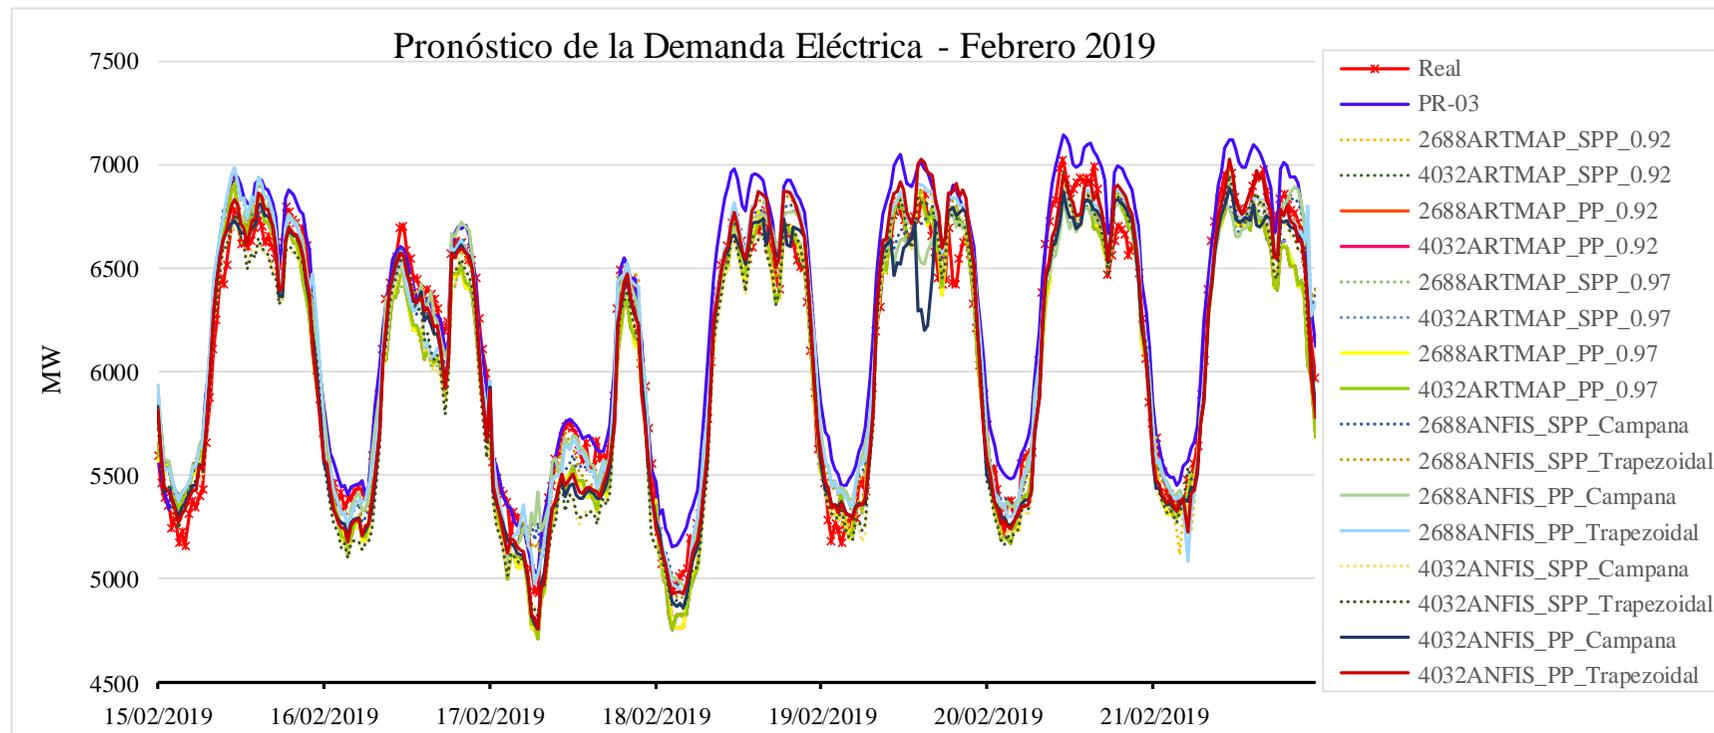


Fig. 5.17 Comparación del pronóstico de demanda aplicando diferentes metodologías-Febrero 2019.

(Fuente: Elaboración propia)

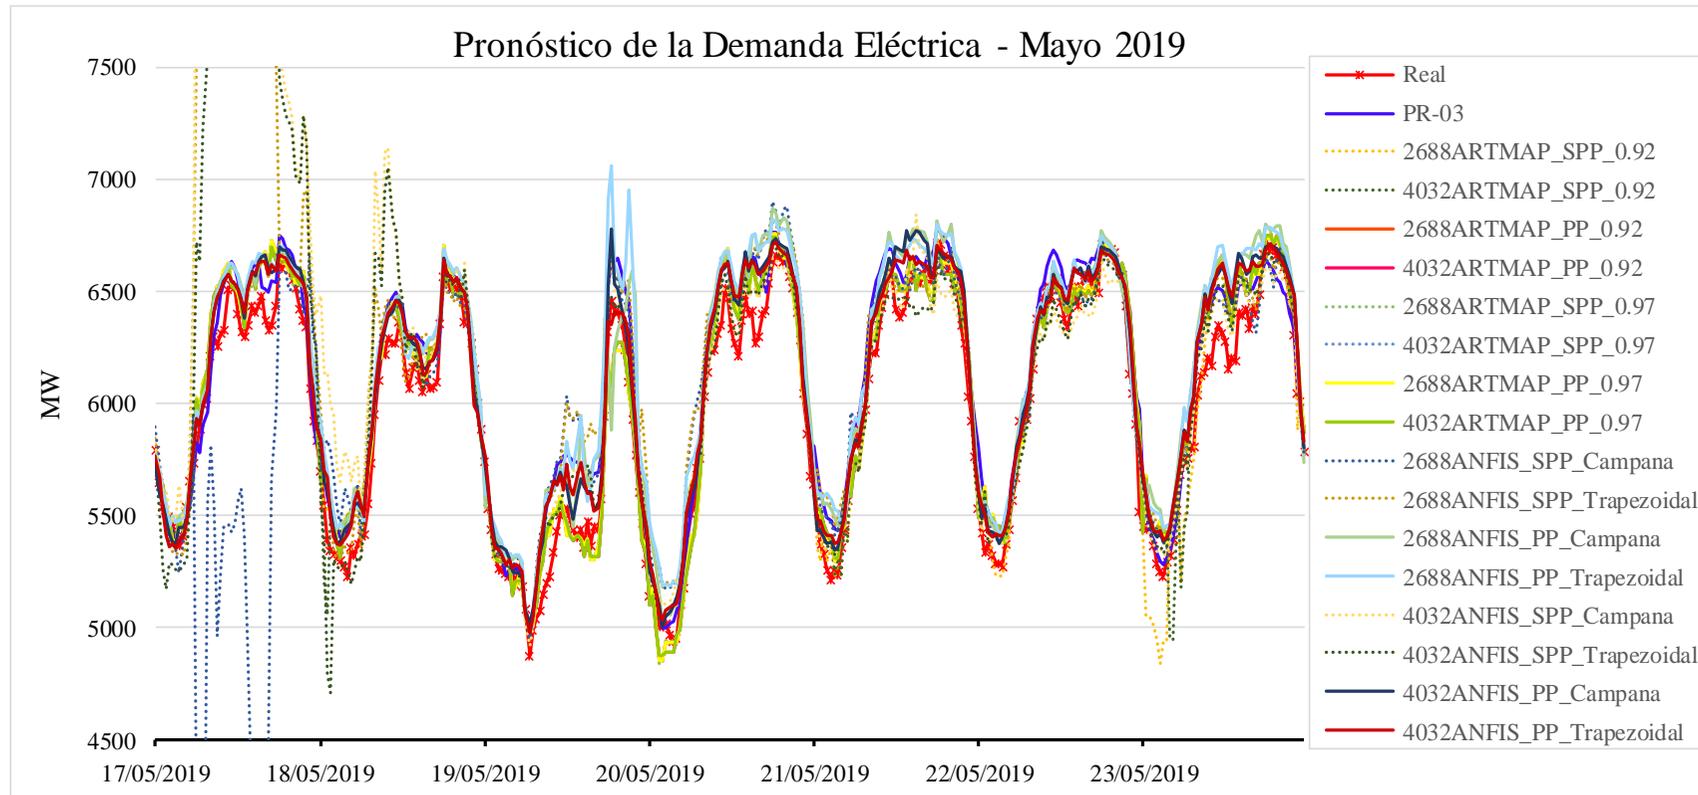


Fig. 5.18 Comparación del pronóstico de demanda aplicando diferentes metodologías-Mayo 2019.

(Fuente: Elaboración propia)

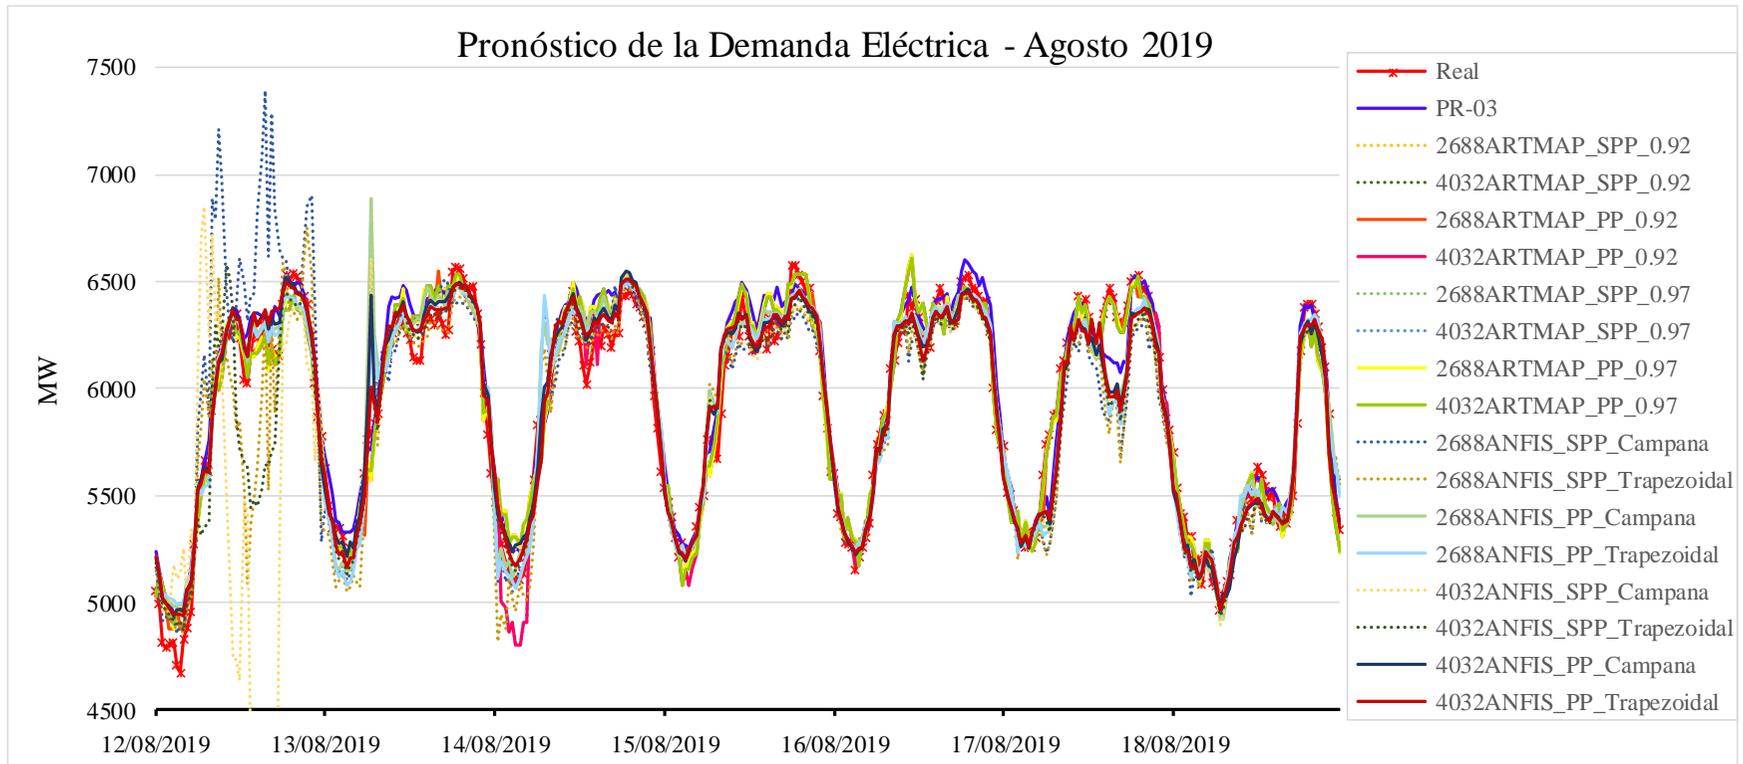


Fig. 5.19 Comparación del pronóstico de demanda aplicando diferentes metodologías-Agosto 2019.

(Fuente: Elaboración propia)

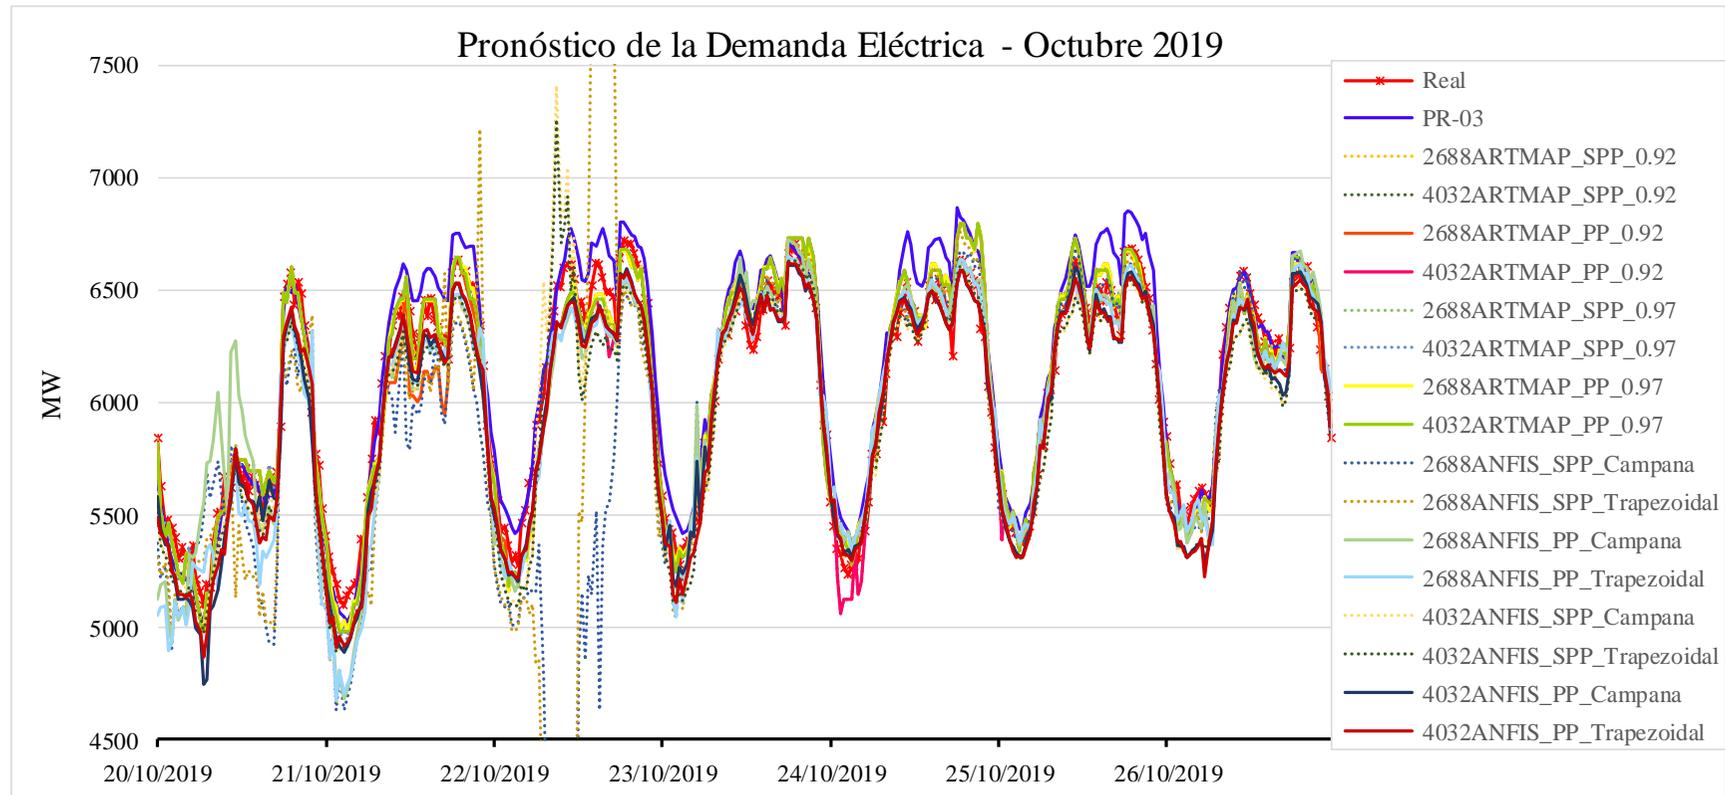


Fig. 5.20 Comparación del pronóstico de demanda aplicando diferentes metodologías-October 2019.

(Fuente: Elaboración propia)

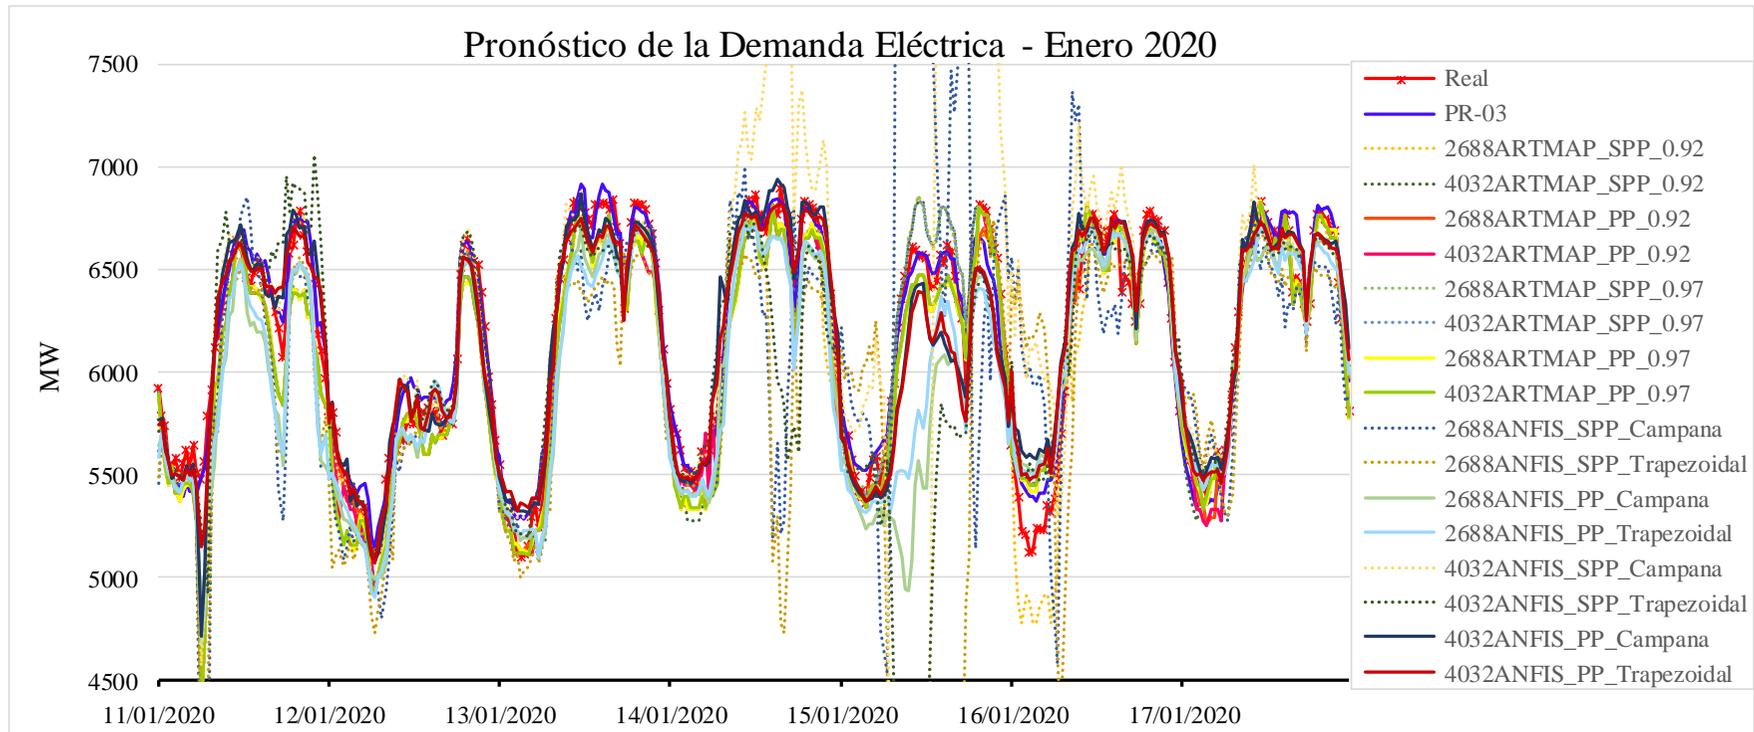


Fig. 5.21 Comparación del pronóstico de demanda aplicando diferentes metodologías-Enero 2020.

(Fuente: Elaboración propia)

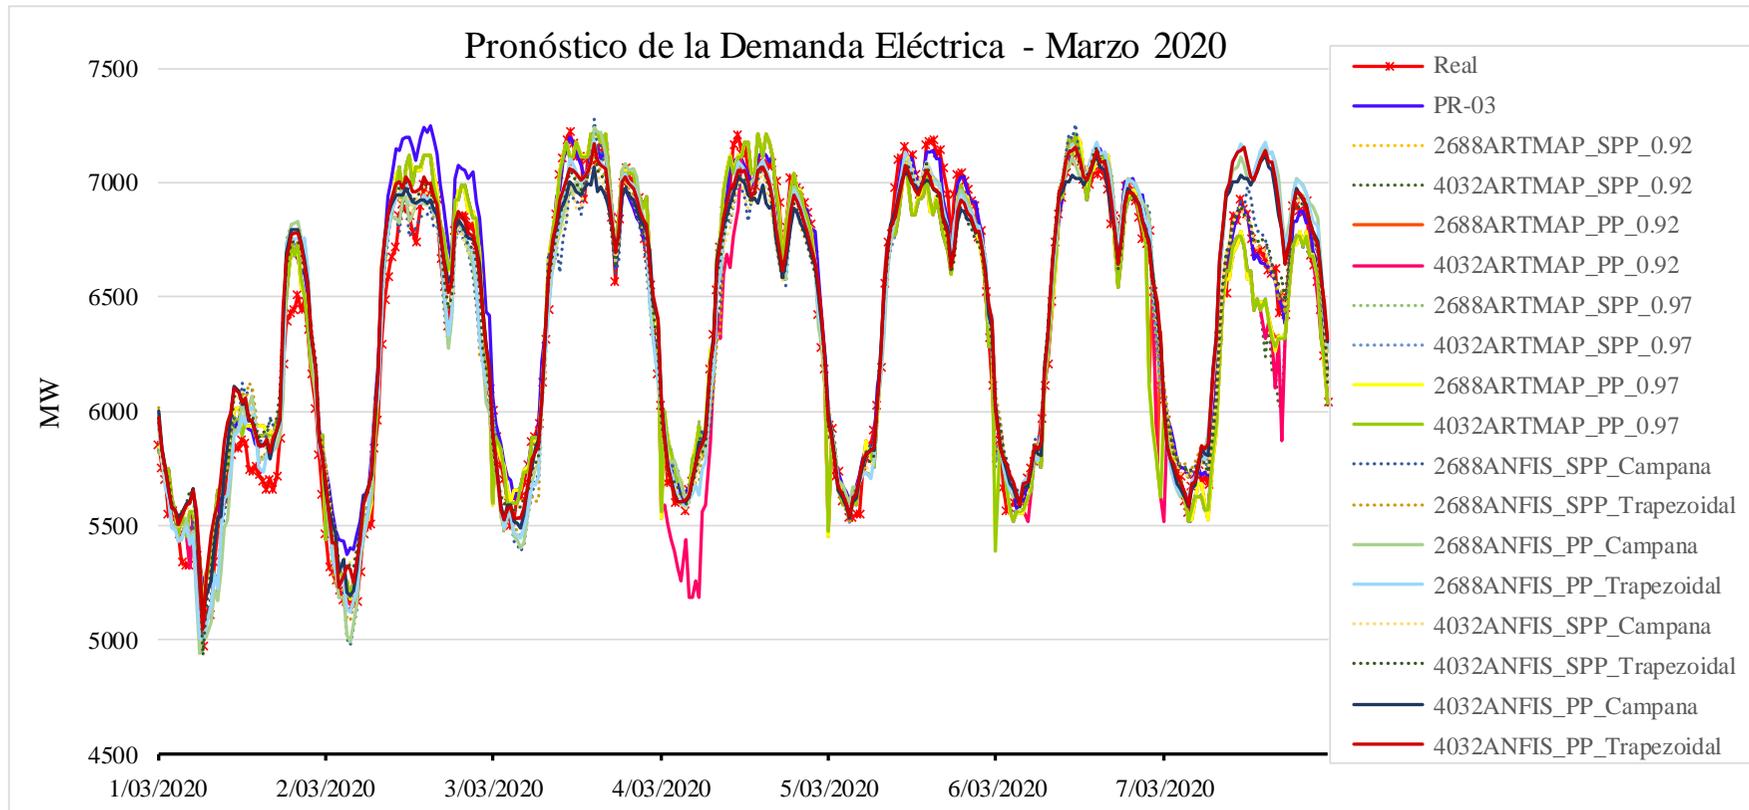


Fig. 5.22 Comparación del pronóstico de demanda aplicando diferentes metodologías-Marzo 2020.

(Fuente: Elaboración propia)

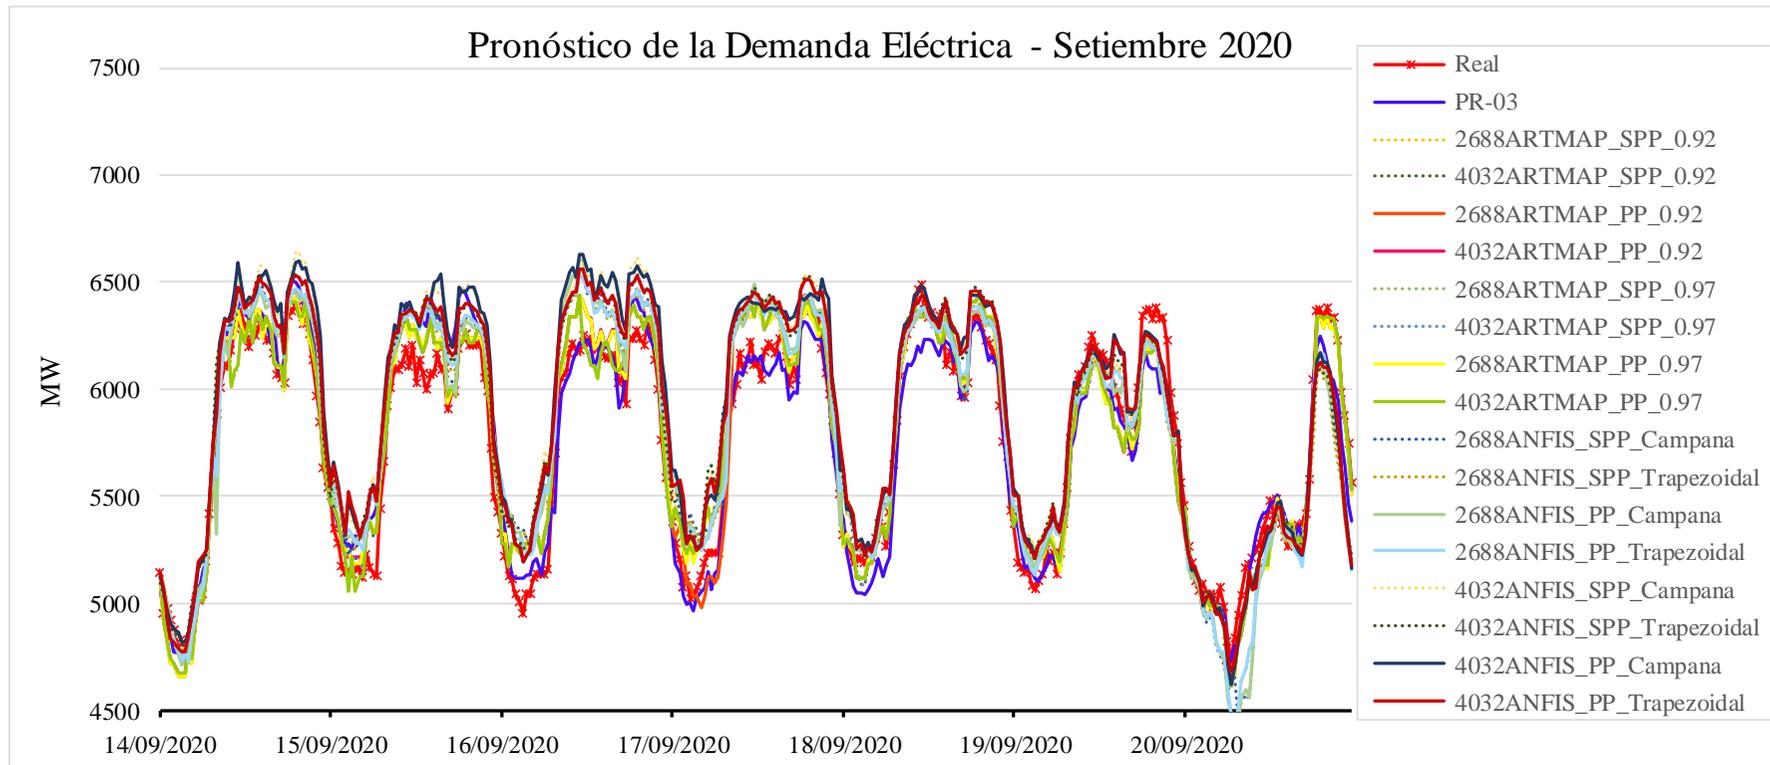


Fig. 5.23 Comparación del pronóstico de demanda aplicando diferentes metodologías-Setiembre 2020.

(Fuente: Elaboración propia)

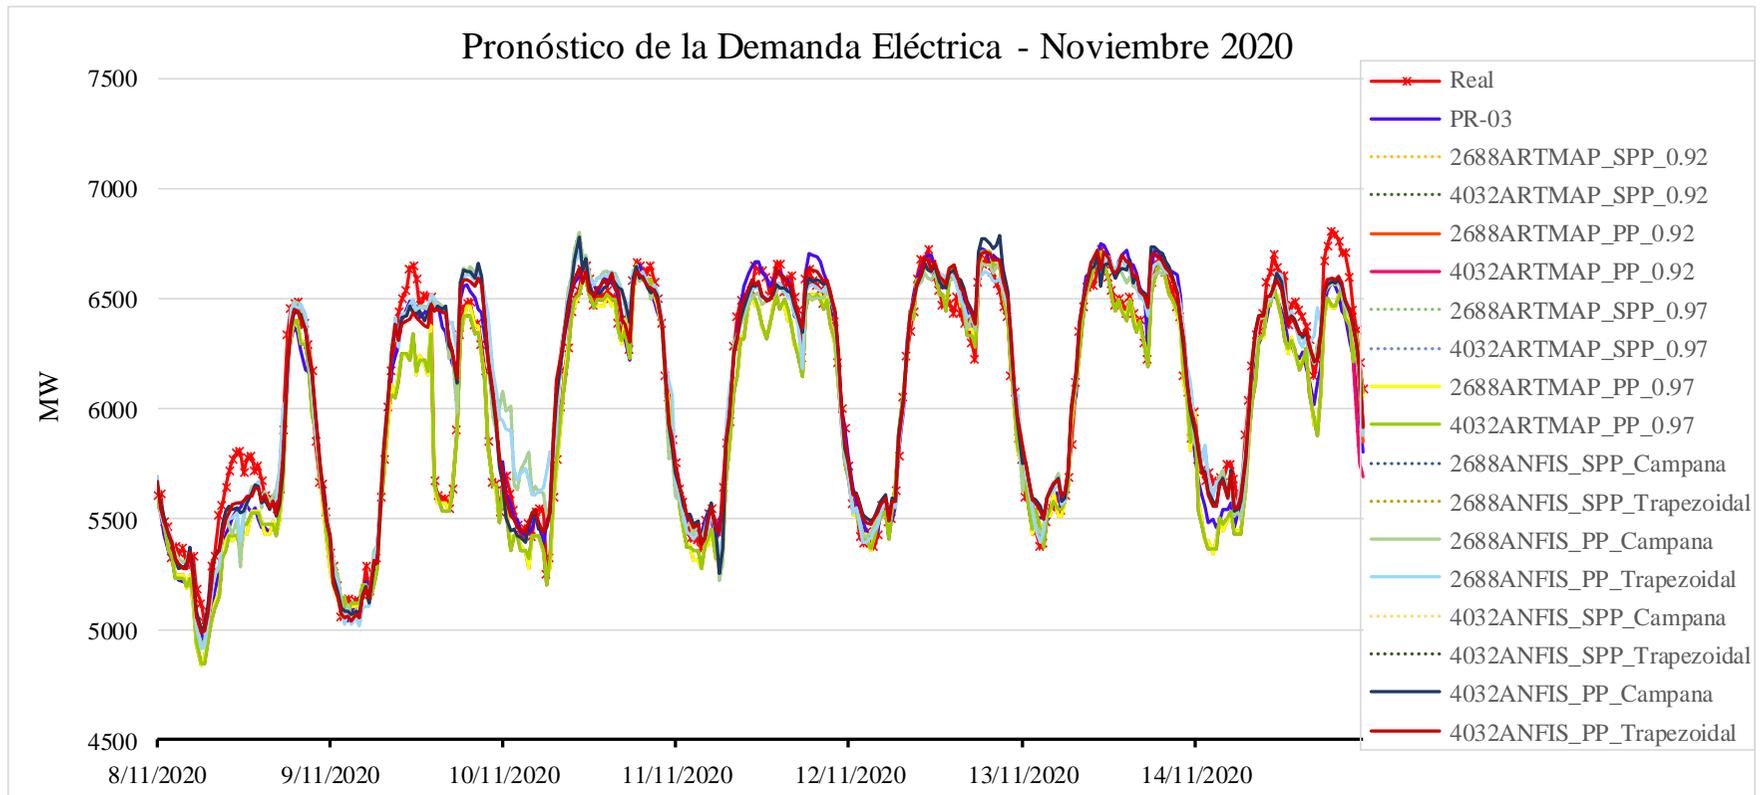


Fig. 5.24 Comparación del pronóstico de demanda aplicando diferentes metodologías-Noviembre 2020.

(Fuente: Elaboración propia)

CONCLUSIONES

1. En esta tesis se propuso la metodología basada en las redes neuronales de la teoría de la resonancia adaptativa para el pronóstico de la demanda eléctrica diaria aplicada al Sistema Eléctrico Interconectado Nacional que permitió garantizar resultados eficientes respecto a la métrica de comparación. Los mejores resultados promedios anuales en términos de error porcentual absoluto medio comparados entre la primera y segunda metodología fueron para la primera metodología, red neuronal ARTMAP *Fuzzy*, tanto para el año 2019 y 2020. Por tal motivo, la presente propone la primera metodología como la competente para resolver el problema del pronóstico de la demanda aplicado al Sistema Eléctrico Interconectado Nacional.
2. En esta tesis se propuso un algoritmo de aprendizaje continuo cuya característica presenta la plasticidad, estabilidad y rapidez utilizando *Machine Learning* para el procedimiento técnico 3 del Comité de Operación Económica del Sistema Interconectado Nacional que permitió garantizar resultados eficientes respecto a la métrica de comparación. Este algoritmo, parte de la primera metodología, garantizó una asociación de nuevos patrones en los datos trayendo como resultado desempeños significativos en términos de error porcentual absoluto medio comparados a lo efectuado por el operador del sistema, otorgándole de esta forma a ser tomada en consideración como parte del procedimiento.
3. En esta tesis se determinó una correcta asociación de la información utilizando los datos históricos de los Informes de Evaluación de la Operación Diaria del Sistema Eléctrico Interconectado Nacional, esta permitió garantizar eficientes resultados para la primera metodología medidos en base al error porcentual absoluto medio. Esta correcta asociación de la información se consiguió modificados los parámetros de la estructura interna de la red neuronal ARTMAP *Fuzzy*.
4. En esta tesis se propuso una metodología de pre-procesamiento de información utilizando los datos brutos extraídos de los Informes de Evaluación de la Operación Diaria del Sistema Eléctrico Interconectado Nacional desde el 2018 hasta 2020. Este pre-

procesamiento garantizó la mejora sustancial en el pronóstico de la demanda eléctrica para los días evaluados utilizando la segunda metodología ANFIS, superando significativamente a los evaluados con los datos extraídos directamente de los informes. Por otra parte, en la primera metodología para ARTMAP *Fuzzy* no se observó un cambio sustancial en los resultados, por el contrario se mantuvo; sin embargo cabe se resaltar que los resultados de la primera metodología se mantuvieron superiores a los obtenidos utilizando el pre-procesamiento en la segunda. Es de esta forma que la asociación de ANFIS para datos estandarizados contribuyó y garantizó un desempeño eficiente porque eliminó disparos en los resultados con datos sin pre-proceso, pero desafortunadamente no consiguió ser superior a la primera metodología.

RECOMENDACIONES

1. Debido al comportamiento analizado de las cargas eléctricas, puede utilizarse un modelo híbrido entre las dos metodologías propuestas. En base a la información de los IEOD es posible obtener las cargas dinámicas concernientes a los grandes usuarios libres, y consecuentemente obtener datos, casi parecidos, a los usuarios regulados o cargas vegetativas realizando una diferencia ente demanda total menos demanda de grandes usuarios libres. Las cargas más dinámicas, grandes usuarios libres, se pueden modelar mediante la primera metodología ARTMAP *Fuzzy*, y las vegetativas con ANFIS, pudiendo de esta forma obtener un posible mejor desempeño al presentado en esta tesis.
2. Las bondades de la red neuronal ARTMAP *Fuzzy* estuvieron limitadas a los datos de entrada, cargas eléctricas pasadas. Sin embargo, es posible adicionar en la entrada de la red datos como lo factores externos de tipo meteorológico, económicos, tiempo, y más; no obstante, los datos en estos factores externos son restringidos y difíciles de obtener. Por lo tanto, como recomendación quedaría procurar bases de datos de estos factores externos y evaluar el desempeño de la metodología propuesta.
3. Se recomienda utilizar la metodología del pre-procesamiento para probabilidades acumuladas menores a 80%. De forma consecuente, se podría evaluar estos datos estandarizados utilizando la segunda metodología para los días aleatorios establecidos buscando un mejor desempeño en la red neuronal ANFIS.
4. Con la finalidad de resolver el problema del pronóstico de demanda para días feriados se recomienda generar una base de datos con sus perfiles de carga normalizados en función de la energía total diaria y también ajustar la metodología de pre-procesamiento, a un corte menor de 80% *e.g.*, para un feriado cualquiera, realizar un pronóstico como si fuera un día común, sumar la energía obtenida. El pronóstico de este día vendría a ser el resultado de la multiplicar el perfil del feriado almacenado por la energía obtenida.
5. Se recomienda analizar otras técnicas de *Machine Learning* aplicado al Sistema Eléctrico Interconectado Nacional que permitan superar los desempeños obtenidos en esta tesis.

REFERENCIAS BIBLIOGRÁFICAS

- [1] COES, “PROCEDIMIENTO TÉCNICO DEL COMITÉ DE OPERACIÓN ECONÓMICA DEL SISTEMA PR – 03.” pp. 1–20, 2011.
- [2] A. Mosavi, M. Salimi, S. F. Ardabili, T. Rabczuk, S. Shamshirband, and A. R. Varkonyi-Koczy, “State of the art of machine learning models in energy systems, a systematic review,” *Energies*, vol. 12, no. 7, 2019, doi: 10.3390/en12071301.
- [3] H. Chen, C. A. Cañizares, and A. Singh, “ANN-based short-term load forecasting in electricity markets,” *Proc. IEEE Power Eng. Soc. Transm. Distrib. Conf.*, vol. 2, no. WINTER MEETING, pp. 411–415, 2001, doi: 10.1109/PESW.2001.916876.
- [4] B. L. Zhang and Z. Y. Dong, “An adaptive neural-wavelet model for short term load forecasting,” *Electr. Power Syst. Res.*, vol. 59, no. 2, pp. 121–129, 2001, doi: 10.1016/S0378-7796(01)00138-9.
- [5] M. L. M. Lopes, “Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica,” Universidade Estadual Paulista, 2005.
- [6] A. Escobar M and L. P. Pérez, “Application of support vector machines and ANFIS to the short-term load forecasting,” *2008 IEEE/PES Transm. Distrib. Conf. Expo. Lat. Am. T D-LA*, pp. 10–14, 2008, doi: 10.1109/TDC-LA.2008.4641839.
- [7] H. H. Çevik and M. Çunkaş, “Short-term load forecasting using fuzzy logic and ANFIS,” *Neural Comput. Appl.*, vol. 26, no. 6, pp. 1355–1367, 2015, doi: 10.1007/s00521-014-1809-4.
- [8] T. T. Gomes, “Rede ARTMAP Euclidiana utilizada na solução do problema de previsão de Cargas Elétricas,” Universidade Estadual Paulista Faculdade de Engenharia de Ilha Solteira, 2017.
- [9] W. Li, X. Yang, H. Li, and L. Su, “Hybrid forecasting approach based on GRNN neural network and SVR machine for electricity demand forecasting,” *Energies*, vol.

- 10, no. 1, 2017, doi: 10.3390/en10010044.
- [10] R. Sevlian and R. Rajagopal, "A scaling law for short term load forecasting on varying levels of aggregation," *Int. J. Electr. Power Energy Syst.*, vol. 98, no. January, pp. 350–361, 2018, doi: 10.1016/j.ijepes.2017.10.032.
- [11] P. Singh and P. Dwivedi, "Integration of new evolutionary approach with artificial neural network for solving short term load forecast problem," *Appl. Energy*, vol. 217, no. October 2017, pp. 537–549, 2018, doi: 10.1016/j.apenergy.2018.02.131.
- [12] M. F. Alves, "Previsão de cargas não residenciais mistas por redes neurais ARTMAP Fuzzy," Universidade Estadual Paulista, 2019.
- [13] Y. Peng *et al.*, "Short-term Load Forecasting at Different Aggregation Levels with Predictability Analysis," *2019 IEEE PES Innov. Smart Grid Technol. Asia, ISGT 2019*, pp. 3385–3390, 2019, doi: 10.1109/ISGT-Asia.2019.8881343.
- [14] Y. Liang, D. Niu, and W. C. Hong, "Short term load forecasting based on feature extraction and improved general regression neural network model," *Energy*, vol. 166, pp. 653–663, 2019, doi: 10.1016/j.energy.2018.10.119.
- [15] J. Kim, J. Moon, E. Hwang, and P. Kang, "Recurrent inception convolution neural network for multi short-term load forecasting," *Energy Build.*, vol. 194, no. 2019, pp. 328–341, 2019, doi: 10.1016/j.enbuild.2019.04.034.
- [16] K. Xie, H. Yi, G. Hu, L. Li, and Z. Fan, "Short-term power load forecasting based on Elman neural network with particle swarm optimization," *Neurocomputing*, vol. 416, pp. 136–142, 2020, doi: 10.1016/j.neucom.2019.02.063.
- [17] P. M. R. Bento, J. A. N. Pombo, M. R. A. Calado, and S. J. P. S. Mariano, "Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting," *Neurocomputing*, vol. 358, pp. 53–71, 2019, doi: 10.1016/j.neucom.2019.05.030.
- [18] M. R. Müller, G. Gaio, E. M. Carreno, A. D. P. Lotufo, and L. A. Teixeira, "Electrical load forecasting in disaggregated levels using Fuzzy ARTMAP artificial neural network and noise removal by singular spectrum analysis," *SN Appl. Sci.*, vol. 2, no. 7, pp. 1–10, 2020, doi: 10.1007/s42452-020-2988-5.

- [19] Z. Tavassoli-Hojati, S. F. Ghaderi, H. Iranmanesh, P. Hilber, and E. Shayesteh, "A self-partitioning local neuro fuzzy model for short-term load forecasting in smart grids," *Energy*, vol. 199, p. 117514, 2020, doi: 10.1016/j.energy.2020.117514.
- [20] M. El-Hendawi and Z. Wang, "An ensemble method of full wavelet packet transform and neural network for short term electrical load forecasting," *Electr. Power Syst. Res.*, vol. 182, no. February, p. 106265, 2020, doi: 10.1016/j.epsr.2020.106265.
- [21] J. H. Chow, F. F. Wu, and J. A. Momoh, "Applied Mathematics for Restructured Electric Power Systems," in *Applied Mathematics for Restructured Electric Power Systems*, vol. 1, no. 9, Boston: Kluwer Academic Publishers, 2006, pp. 1–9.
- [22] H. Hahn, S. Meyer-Nieberg, and S. Pickl, "Electric load forecasting methods: Tools for decision making," *Eur. J. Oper. Res.*, vol. 199, no. 3, pp. 902–907, 2009, doi: 10.1016/j.ejor.2009.01.062.
- [23] A. K. Singh, Ibraheem, S. Khatoon, M. Muazzam, and D. K. Chaturvedi, "Load forecasting techniques and methodologies: A review," in *2012 2nd International Conference on Power, Control and Embedded Systems*, 2012, pp. 1–10, doi: 10.1109/ICPCES.2012.6508132.
- [24] P. Murto and Neural, "Neural Network Models for Short-Term Load Forecasting," Helsinki University of Technology, 1998.
- [25] S. Nimbargi, S. Mhaisne, S. Nangare, and M. Sinha, "Review on AMI technology for Smart Meter," *2016 IEEE Int. Conf. Adv. Electron. Commun. Comput. Technol. ICAECCT 2016*, pp. 21–27, 2017, doi: 10.1109/ICAECCT.2016.7942549.
- [26] D. Alahakoon and X. Yu, "Smart Electricity Meter Data Intelligence for Future Energy Systems: A Survey," *IEEE Trans. Ind. Informatics*, vol. 12, no. 1, pp. 425–436, Feb. 2016, doi: 10.1109/TII.2015.2414355.
- [27] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecast.*, vol. 22, no. 4, pp. 679–688, Oct. 2006, doi: 10.1016/j.ijforecast.2006.03.001.
- [28] K. P. Murphy, *Machine Learning A Probabilistic Perspective*. Cambridge, Massachusetts, 2012.

- [29] S. D. and X. Du, *Data Mining and Machine Learning in Cybersecurity*. Broken Sound Parkway NW: Taylor and Francis Group, LLC, 2012.
- [30] S. Haykin, *Neural networks and learning machines*, 3rd ed. Upper Saddle River, New Jersey: Pearson Education, Inc, 2009.
- [31] W. L. SW Jacob, CA Francone, *Structure and Function in Man*, 4th ed. 1978.
- [32] R. C. Eberhart and R. W. Dobbins, “Early neural network development history: the age of Camelot,” *IEEE Eng. Med. Biol. Mag.*, vol. 9, no. 3, pp. 15–18, Sep. 1990, doi: 10.1109/51.59207.
- [33] F. B. Fitch, “Warren S. McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. Bulletin of mathematical biophysics, vol. 5 (1943), pp. 115–133.,” *J. Symb. Log.*, vol. 9, no. 2, pp. 49–50, Jun. 1944, doi: 10.2307/2268029.
- [34] S. SANDRI and C. CORREA, “Lógica Nebulosa,” *Inst. Tecnológico da Aeronáutica - ITA. V Esc. Redes Neurais.*, pp. 73–90, 1999.
- [35] G. A. Carpenter and S. Grossberg, “The ART of Adaptive Pattern Recognition by a Self-Organizing Neural Network,” *Computer (Long. Beach. Calif.)*, vol. 21, no. 3, pp. 77–88, 1988, doi: 10.1109/2.33.
- [36] G. A. Carpenter, S. Grossberg, and J. H. Reynolds, “ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network,” *IEEE Conf. Neural Networks Ocean Eng.*, pp. 341–342, 1991, doi: 10.1109/icnn.1991.163370.
- [37] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen, “Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps,” *IEEE Trans. Neural Networks*, vol. 3, no. 5, pp. 698–713, 1992, doi: 10.1109/72.159059.
- [38] G. A. Carpenter, S. Grossberg, and D. B. Rosen, “Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system,” *Neural Networks*, vol. 4, no. 6, pp. 759–771, 1991, doi: 10.1016/0893-6080(91)90056-B.
- [39] J.-S. R. Jang, “ANFIS: adaptive-network-based fuzzy inference system,” *IEEE Trans. Syst. Man. Cybern.*, vol. 23, no. 3, pp. 665–685, 1993, doi: 10.1109/21.256541.

- [40] M. Negnevitsky, *Artificial Intelligence 3e e-book A Guide to Intelligent Systems*, vol. 73, no. 1–2. 2011.
- [41] P. J. WERBOS, “Beyond regression: New tools for prediction and analysis in the behavioral sciences,” Harvard University, Cambridge, Massachusetts, 1974.
- [42] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, and M. J. Damborg, “Electric load forecasting using an artificial neural network,” *IEEE Trans. Power Syst.*, vol. 6, no. 2, pp. 442–449, May 1991, doi: 10.1109/59.76685.

ANEXO A

ÍNDICE DE ILUSTRACIONES

Fig. 1.1 Correlación utilizando distribuciones marginales entre el MAPE y la variación de Energía Absoluta Diaria – 2017, 2018, 2019 y 2020.	3
Fig. 1.2 Demanda SEIN 2020 consecuencia del confinamiento COVID-19.	4
Fig. 3.1 Machine learning: Proceso de aprendizaje de las máquinas	22
Fig. 3.2 Diagrama de bloque del aprendizaje supervisado.	23
Fig. 3.3 Diagrama de bloque del aprendizaje supervisado.	23
Fig. 3.4 Diagrama de bloque del aprendizaje por Refuerzo.	24
Fig. 3.5 Representación simplificada de una neurona biológica.	26
Fig. 3.6 Neurona no lineal.	27
Fig. 3.7 Funciones de activación.	29
Fig. 3.8 Red no recurrente de una sola capa.	30
Fig. 3.9 Red recurrente con neuronas ocultas.	31
Fig. 3.10 Función triangular característica de un conjunto difuso Temperatura.	34
Fig. 3.11 Función de pertinencia Triangular	35
Fig. 3.12 Función de pertinencia Gaussiana.	35
Fig. 3.13 Función de pertinencia Trapezoidal	36
Fig. 3.14 Función de pertinencia Campana	37
Fig. 3.15 Arquitectura ARTMAP Fuzzy	39
Fig. 3.16 Efecto del parámetro de vigilancia en el entrenamiento de la red neuronal ART.	41
Fig. 3.17 Estrutura da ANFIS.	44
Fig. 4.1 MAPE diario comparando la demanda ejecutada y pronosticada PR-03 para 2019.	53
Fig. 4.2 MAPE diario comparando la demanda ejecutada y pronosticada PR-03 para 2020.	53

Fig. 4.3 Diagramas de cargas semanales SEIN perteneciente al 2018.....	56
Fig. 4.4 Diagramas de cargas semanales SEIN perteneciente al 2019.....	57
Fig. 4.5 Diagramas de cargas semanales SEIN perteneciente al 2020.....	57
Fig. 4.6 MAPE respecto al desvío energético diario.....	58
Fig. 4.7 Distribución acumulada de los datos del desvío energético diario.....	59
Fig. 4.8 Diagramas pre-procesadas de cargas semanales SEIN perteneciente al 2018.....	60
Fig. 4.9 Diagramas pre-procesadas de cargas semanales SEIN perteneciente al 2019.....	60
Fig. 4.10 Diagramas pre-procesadas de cargas semanales SEIN perteneciente al 2020.....	61
Fig. 4.11 Sistema de pronóstico ARTMAP Fuzzy.....	62
Fig. 4.12 Sistema de pronóstico ANFIS.....	64
Fig. 5.1 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 2688 datos sin pre-procesamiento – 2019.....	67
Fig. 5.2 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 4032 datos sin pre-procesamiento – 2019.....	69
Fig. 5.3 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 2688 datos sin pre-procesamiento – 2020.....	71
Fig. 5.4 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 4032 datos sin pre-procesamiento – 2020.....	73
Fig. 5.5 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 2688 datos con pre-procesamiento – 2019.....	75
Fig. 5.6 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 4032 datos con pre-procesamiento – 2019.....	76
Fig. 5.7 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 2688 datos con pre-procesamiento – 2020.....	78
Fig. 5.8 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ARTMAP Fuzzy para 4032 datos con pre-procesamiento – 2020.....	79
Fig. 5.9 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos sin pre-procesamiento – 2019.....	81
Fig. 5.10 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos sin pre-procesamiento – 2019.....	83
Fig. 5.11 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos sin pre-procesamiento – 2020.....	85

Fig. 5.12 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos sin pre-procesamiento – 2020.....	87
Fig. 5.13 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos con pre-procesamiento – 2019.....	89
Fig. 5.14 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos con pre-procesamiento – 2019.....	90
Fig. 5.15 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 2688 datos con pre-procesamiento – 2020.....	92
Fig. 5.16 Diagrama comparativo en términos de MAPE COES PR-03 vs metodología ANFIS para 4032 datos con pre-procesamiento – 2020.....	94
Fig. 5.17 Comparación del pronóstico de demanda aplicando diferentes metodologías- Febrero 2019.....	96
Fig. 5.18 Comparación del pronóstico de demanda aplicando diferentes metodologías- Mayo 2019.....	97
Fig. 5.19 Comparación del pronóstico de demanda aplicando diferentes metodologías- Agosto 2019.....	98
Fig. 5.20 Comparación del pronóstico de demanda aplicando diferentes metodologías- Octubre 2019.....	99
Fig. 5.21 Comparación del pronóstico de demanda aplicando diferentes metodologías- Enero 2020.....	100
Fig. 5.22 Comparación del pronóstico de demanda aplicando diferentes metodologías- Marzo 2020.....	101
Fig. 5.23 Comparación del pronóstico de demanda aplicando diferentes metodologías- Setiembre 2020.....	102
Fig. 5.24 Comparación del pronóstico de demanda aplicando diferentes metodologías- Noviembre 2020.....	103

ÍNDICE DE TABLAS

Tabla N° 3.1 Dos fases del algoritmo de aprendizaje ANFIS.	46
Tabla N° 4.1 Datos históricos seleccionados para el pronóstico de demanda.....	50
Tabla N° 4.2 Días aleatorios para el pronóstico de demanda aplicado en el análisis de la primera metodología.....	54
Tabla N° 4.3 Días aleatorios para el pronóstico de demanda aplicado en el análisis de la segunda metodología.	54
Tabla N° 5.1 Configuración de los parámetros para la metodología usando ARTMAP Fuzzy	65
Tabla N° 5.2 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 2688 datos sin pre-procesamiento - 2019.	66
Tabla N° 5.3 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 4032 datos sin pre-procesamiento - 2019	68
Tabla N° 5.4 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 2688 datos sin pre-procesamiento - 2020	70
Tabla N° 5.5 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 4032 datos sin pre-procesamiento - 2020	72
Tabla N° 5.6 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 2688 datos con pre-procesamiento - 2019.	73
Tabla N° 5.7 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 4032 datos con pre-procesamiento - 2019.	75
Tabla N° 5.8 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 2688 datos con pre-procesamiento - 2020.	77
Tabla N° 5.9 MAPE diario del pronóstico de la demanda eléctrica utilizando ARTMAP Fuzzy para 4032 datos con pre-procesamiento - 2020.	78
Tabla N° 5.10 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos sin pre-procesamiento - 2019.	80

Tabla N° 5.11 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos sin pre-procesamiento - 2019.	82
Tabla N° 5.12 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos sin pre-procesamiento – 2020.	84
Tabla N° 5.13 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos sin pre-procesamiento – 2020.	86
Tabla N° 5.14 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos con pre-procesamiento - 2019.	88
Tabla N° 5.15 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos con pre-procesamiento – 2019.	89
Tabla N° 5.16 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 2688 datos con pre-procesamiento – 2020.	91
Tabla N° 5.17 MAPE diario del pronóstico de la demanda eléctrica utilizando ANFIS para 4032 datos con pre-procesamiento – 2020.	93

GLOSARIO DE TÉRMINOS

ANFIS	Sistema de Inferencia Neuro Difuso Adaptativo
ANN	Redes Neuronales Artificiales
ARIMA	Media Móvil Integrada Autorregresiva
ARIMAX	Media Móvil Autorregresiva Integrada
ARMA	Media Móvil Autorregresiva
ARMAX	Media Móvil Autorregresiva con Variables Exógenas
ART	Teoría de la Resonancia Adaptativa
CNN	Redes Neuronales Convolucionales
COES	Comité de Operación Económica del Sistema Interconectado Nacional
EEMD	Descomposición en Modo Empírico por Conjuntos
EMD	Descomposición en Modo Empírico
ENN	Red Neuronal de Elman
ESA	Espectro Singular de Análisis
FOA	Algoritmo de Optimización de la Mosca de la Fruta
FTL	Movimiento de las Ovejas de un Rebaño
GMAE	Error Absoluto de la Media Geométrica
GMRAE	Error Absoluto de la Media Geométrica Relativa
GRNN	La Red Neuronal de Regresión General
IEOD	Informe de Evaluación de la Operación Diaria
IoT	Internet de las Cosas
LAN	Red de Área Local
LLFN	Neuro-Fuzzy Local de Autopartición

MAE	Error Absoluto Medio
MAPE	Error Porcentual Medio Absoluto
MAPE	Error Porcentual Absoluto Medio
MASE	Error de Escala Absoluto Medio
MdRAE	Error Absoluto de Media Relativa
ML	Machine Learning
MLP	Redes Neuronales Perceptron Multicapas
MMQ	Mínimos Cuadrados
mRMR	Relevancia Máxima de Redundancia Mínima
MSE	Error Cuadrático Medio
OSINERGMIN	Organismo Supervisor de la Inversión En Energía y Minería
PR-03	Procedimiento Técnico 03
PSO	Optimización de Enjambre de Partículas
PSVR	Máquina de Regresión Vectorial de Soporte Optimizada por el algoritmo de Optimización del Enjambre de Partículas
RBF	Redes Neuronales con Función de Base Radial
RICNN	Red Neuronal Convolutiva de Inicio Recurrente
RNN	Redes Neuronales Recurrentes
SARIMA	Modelo de Media Móvil Integrado Autorregresivo Estacional
SEIN	Sistema Eléctrico Interconectado Nacional
sMAPE	Error Simétrico Porcentual Absoluto Medio
SVM	Máquinas de Vectores de Soporte
WAN	Red de Área Amplia