


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS
VALPARAÍSO - CHILE



**PRONÓSTICO DEL CONSUMO ENERGÉTICO DE LARGO
PLAZO EN EE.UU MEDIANTE ANFIS (ADAPTIVE NEURO
FUZZY INFERENCE SYSTEM)**

FRANCISCO ANDRÉS PRADO MORENO

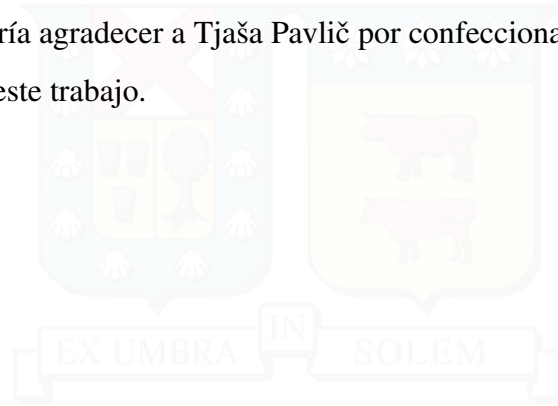
MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL INDUSTRIAL

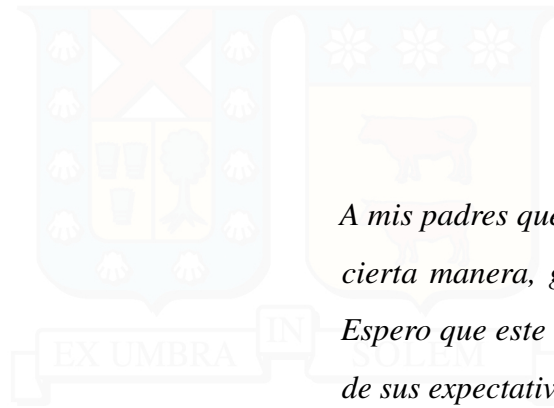
PROFESOR GUÍA : SR. WERNER KRISTJANPOLLER
PROFESOR CORREFERENTE : SR. RODOLFO SALAZAR.

OCTUBRE 2016

Me gustaría agradecer a la oficina EIA por la publicación de su base de datos en su web, en particular a Tyler Hodge del área de STEO (Short-Term Energy Outlook) por su colaboración de información relevante.

También me gustaría agradecer a Tjaša Pavlič por confeccionar algunas de las figuras que fueron usadas en este trabajo.





A mis padres que me han apoyado y, de cierta manera, guiado en este camino. Espero que este trabajo esté a la altura de sus expectativas.

A mi grupo de amigos de la Universidad por acompañarme en este camino, sin ellos no hubiera sido lo mismo. En especial a tres personas, a Margarita por siempre estar, en las buenas y en las malas. A Mario por enseñarme que la mediocridad no es el camino, A Luis por transmitirme el amor hacia hacer lo que a uno le gusta.

To Tjaša Pavlič, who was one of the most important pillars since last year, thank you for your support and being present, always. No matter how far, you've always been there.

RESUMEN EJECUTIVO

El siguiente trabajo consiste en la propuesta de un método de inteligencia computacional híbrido compuesto por un modelo AR (auto-regresivo) y ANFIS para el pronóstico de consumo energético de largo plazo agregado en Estados Unidos. Tras comparar el modelo propuesto con distintos métodos de pronóstico incluyendo modelo ARIMA, ANN y GARCH mediante la función de pérdida MAPE y un análisis MCS (Model Confidence Set), se concluye mediante la prueba t de Welch y MCS que el modelo propuesto genera, en promedio, significativamente menos error que los modelos de benchmark. De la misma manera, el modelo propuesto, según un test de MCS, se prueba con una habilidad significativamente superior de predicción por sobre los modelos benchmark.

Por último, se propone un pronóstico del consumo mensual para el horizonte desde Julio de 2016 hasta Diciembre de 2017 mediante el modelo final propuesto.

Palabras Clave. ANFIS, Pronóstico del Consumo Energético de Largo Plazo (E.E.U.U), Series de Tiempo, Inteligencia Computacional, Selección de Modelos, Habilidad Superior de Pronóstico, MAPE.

ABSTRACT

The following work consists in a proposal of a hybrid method composed by an AR model (Auto-regressive) and ANFIS to forecast the aggregated long-term energetic load in United States. After comparing the proposed model with several benchmark methods including ARIMA, ANN and GARCH by the loss function MAPE and an MCS analysis (Model Confidence Set), it is concluded by the Welch's t test and MCS that the proposed method generates, on average terms, significantly less error than the benchmark models. In the same sense, the proposed model, by a MCS test, it is proven with a significant superior predictive ability (SPA) over the benchmark models.

Lastly, a monthly energetic load forecast is proposed from July 2016 to December 2017 by the means of the proposed model.

Keywords. ANFIS, Long-Term Energetic Load Forecast, Time Series, Computational Intelligence, Model Selection, Superior Predictive Ability, MAPE.

Índice de Contenidos

| | |
|--|-----------|
| 1. Problema de Investigación | 1 |
| 1.1. Series de Tiempo | 1 |
| 1.2. Pronóstico del Consumo de Energía Eléctrica | 2 |
| 1.3. Pronóstico del Consumo Energético de Largo Plazo | 3 |
| 1.3.1. Antecedentes | 3 |
| 1.3.2. Justificación | 4 |
| 1.4. Inteligencia Computacional | 5 |
| 2. Objetivos | 6 |
| 2.1. Objetivo General | 6 |
| 2.2. Objetivos Específicos | 6 |
| 3. Marco Teórico | 7 |
| 3.1. Pronóstico del Consumo Energético en la Actualidad | 7 |
| 3.2. ¿Cómo se ha resuelto el Problema hasta ahora? | 13 |
| 4. Data | 14 |
| 5. Contexto Teórico | 16 |
| 5.1. Modelo ARIMA | 16 |
| 5.1.1. Modelos Integrados | 17 |
| 5.1.1.1. Prueba de Dickey-Fuller Aumentada | 17 |
| 5.2. Modelo GARCH | 18 |
| 5.3. Modelos ANN | 19 |
| 5.3.1. El perceptrón | 19 |
| 5.3.2. Modelos ANN Recurrentes (RNN) | 21 |
| 5.3.2.1. Capas Escondidas (Hidden Layers) | 22 |
| 5.3.2.2. Algoritmo de Entrenamiento | 22 |
| 5.3.2.3. Medida de Desempeño | 23 |
| 5.4. Modelo ANFIS | 24 |
| 5.4.1. Lógica Difusa (Fuzzy Logic) | 24 |
| 5.4.1.1. Operadores Lógicos Difusos (Fuzzy Operators) | 24 |
| 5.4.1.2. Reglas Difusas (if-then Rules) (Reglas Si-entonces) | 26 |
| 5.4.1.3. Conjuntos Difusos (Fuzzy Sets) | 26 |
| 5.4.1.4. Funciones de Membresía (Membership Functions) | 26 |

| | | |
|-----------|---|-----------|
| 5.4.2. | FIS (Fuzzy Inference System) (Sistema de Inferencia Difusa) | 28 |
| 5.4.2.1. | Mamdani | 28 |
| 5.4.2.2. | Sugeno | 29 |
| 5.4.3. | Entramamiento | 29 |
| 5.5. | Criterios de Selección de Modelos | 30 |
| 5.5.1. | Criterio AIC (Akaike Information Criterion) | 30 |
| 5.5.2. | Criterio BIC o SC (Schwarz Criterion) | 30 |
| 5.5.3. | Alcance y Eviews | 31 |
| 5.6. | Funciones de Pérdida | 31 |
| 5.6.1. | RMSE | 31 |
| 5.6.2. | MAPE | 32 |
| 5.7. | Prueba o Test de Significancia Estadística | 32 |
| 5.7.1. | Test t de Welch | 33 |
| 5.7.2. | Model Confidence Set | 33 |
| 6. | Metodología | 35 |
| 6.1. | Estructura | 35 |
| 6.1.1. | Pronóstico del Modelo Propuesto | 35 |
| 6.1.1.1. | Análisis Exploratorio de la Base de Datos | 35 |
| 6.1.1.2. | Pronóstico de los datos | 36 |
| 6.1.1.3. | Cálculo del Error | 36 |
| 6.1.2. | Benchmark | 36 |
| 6.1.2.1. | Pronósticos | 36 |
| 6.1.2.2. | Cálculo del Error | 36 |
| 6.1.3. | Prueba de Significancia | 37 |
| 7. | Procedimiento | 38 |
| 7.1. | Pronóstico del Modelo Propuesto | 38 |
| 7.1.1. | Análisis Exploratorio ARI(p,d) | 38 |
| 7.1.1.1. | Análisis I(d) | 38 |
| 7.1.1.2. | Análisis AR(p) | 39 |
| 7.1.2. | Pronóstico con ANFIS | 40 |
| 7.1.2.1. | Preprocesamiento | 40 |
| 7.1.2.2. | FIS Inicial | 40 |
| 7.1.2.3. | Error | 41 |
| 7.2. | Pronósticos de los Benchmarks | 41 |
| 7.2.1. | Benchmark AR(p) | 42 |
| 7.2.2. | Benchmark MA(q) | 42 |
| 7.2.3. | Benchmark ARMA(p,q) | 42 |
| 7.2.4. | Benchmark GARCH(r,s) | 42 |
| 7.2.5. | Benchmark ANN | 43 |
| 7.2.6. | Error | 43 |
| 7.3. | Pruebas Estadísticas | 44 |
| 7.3.1. | Test t de Welch | 44 |
| 7.3.2. | Análisis MCS | 45 |

| | |
|--|-----------|
| 8. Análisis de los Resultados | 46 |
| 8.1. Modelos Convencionales | 46 |
| 8.2. Modelo ANFIS | 46 |
| 8.2.1. Pronóstico de Julio 2016-2017 | 47 |
| 8.2.2. Modelo anfis_scr06_suge_hyb | 48 |
| 8.2.2.1. Análisis de sensibilidad MAPE | 49 |
| 9. Conclusiones | 50 |
| Bibliografía | 52 |
| A. Base de Datos | 57 |
| B. Resultados Modelo Propuesto | 65 |
| C. Pronóstico de Carga Mensual 2017 | 85 |
| D. Documentación - Modelo ANFIS | 86 |
| D.1. Código Modelo Anfis | 86 |
| D.2. Código para Pronóstico 2017 | 87 |

Índice de Tablas

| | |
|--|----|
| 5.1. Operadores de Lógica Booleana. Fuente: Elaboración Propia. | 25 |
| 5.2. Ejemplo de Operadores Difusos. Fuente: Elaboración Propia. | 25 |
| 7.1. Glosario de Abreviaturas para MAPE de ANFIS. | 41 |
| 7.2. Modelos GARCH(r,s) provenientes de los Modelos ARMA(p,q).. Fuente: Elaboración Propia. | 43 |
| 7.3. Glosario de Abreviaturas para MAPE de Benchmarks. | 44 |
| 8.1. Pronóstico de Consumo Energético Para Julio 2016-2017 mediante an- fis_scr05_suge_hyb. | 47 |
| 8.2. Pronóstico de Consumo Energético Para Julio 2016-2017 mediante modelo anfis_scr06_suge_hyb. | 48 |
| 8.3. Variación del MAPE al variar % de Datos para Entrenamiento para el modelo anfis_scr06_suge_hyb. Fuente: Elaboración Propia, MS Excel 2013. | 49 |
| A.1. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1973-1975. Fuen- te: Energy Information Administration (EIA). | 57 |
| A.2. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1976-1978. Fuen- te: Energy Information Administration (EIA). | 58 |
| A.3. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1979-1981. Fuen- te: Energy Information Administration (EIA). | 58 |
| A.4. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1982-1984. Fuen- te: Energy Information Administration (EIA). | 59 |
| A.5. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1985-1987. Fuen- te: Energy Information Administration (EIA). | 59 |
| A.6. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1988-1990. Fuen- te: Energy Information Administration (EIA). | 60 |
| A.7. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1991-1993. Fuen- te: Energy Information Administration (EIA). | 60 |
| A.8. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1994-1996. Fuen- te: Energy Information Administration (EIA). | 61 |
| A.9. Consumo Total Energía Primaria [Cuatrillones Btu] Años 1997-1999. Fuen- te: Energy Information Administration (EIA). | 61 |
| A.10. Consumo Total Energía Primaria [Cuatrillones Btu] Años 2000-2002. Fuen- te: Energy Information Administration (EIA). | 62 |

A.11. Consumo Total Energía Primaria [Cuatrillones Btu] Años 2003-2005. **Fuente:** Energy Information Administration (EIA). 62

A.12. Consumo Total Energía Primaria [Cuatrillones Btu] Años 2006-2008. **Fuente:** Energy Information Administration (EIA). 63

A.13. Consumo Total Energía Primaria [Cuatrillones Btu] Años 2009-2011. **Fuente:** Energy Information Administration (EIA). 63

A.14. Consumo Total Energía Primaria [Cuatrillones Btu] Años 2012-2014. **Fuente:** Energy Information Administration (EIA). 64

A.15. Consumo Total Energía Primaria [Cuatrillones Btu] Años 2015 y 2016. **Fuente:** Energy Information Administration (EIA). 64

B.1. Resultados de Criterio AIC y SC de Modelos AR(1-36) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 68

B.2. Resultados de MAPE para los pronósticos de ANFIS. **Fuente:** Elaboración Propia, MS Excel 2013. 69

B.3. Resultados de Criterio AIC y SC de Modelos MA(1-23) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 69

B.4. Parte 1: Resultados de Criterio AIC de Modelos ARMA(1-23,1-23) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 70

B.5. Parte 2: Resultados de Criterio AIC de Modelos ARMA(1-23,1-23) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 71

B.6. Parte 3: Resultados de Criterio AIC de Modelos ARMA(1-23,1-23) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 72

B.7. Parte 1: Resultados de Criterio SC de Modelos ARMA(1-23,1-23) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 73

B.8. Parte 2: Resultados de Criterio SC de Modelos ARMA(1-23,1-23) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 74

B.9. Parte 3: Resultados de Criterio SC de Modelos ARMA(1-23,1-23) de la serie z_t . **Fuente:** Elaboración Propia, Eviews 8. 75

B.10. Resultados AIC para modelo GARCH proveniente de AR(14). **Fuente:** Elaboración Propia, Eviews 8. 76

B.11. Resultados SC para modelo GARCH proveniente de AR(14). **Fuente:** Elaboración Propia, Eviews 8. 76

B.12. Resultados AIC para modelo GARCH proveniente de ARMA(12,12). **Fuente:** Elaboración Propia, Eviews 8. 76

B.13. Resultados SC para modelo GARCH proveniente de ARMA(12,12). **Fuente:** Elaboración Propia, Eviews 8. 76

B.14. Resultados AIC para modelo GARCH proveniente de ARMA(14,15). **Fuente:** Elaboración Propia, Eviews 8. 77

B.15. Resultados SC para modelo GARCH proveniente de ARMA(14,15). **Fuente:** Elaboración Propia, Eviews 8. 77

B.16. Resultados de MAPE para los pronósticos de Benchmarks. **Fuente:** Elaboración Propia, MS Excel 2013. 77

B.17. Parte 1: Resultados de p-valores prueba t de Welch. **Fuente:** Elaboración Propia, MS Excel 2013. 78

| | |
|--|----|
| B.18. Parte 2: Resultados de p-valores prueba t de Welch. Fuente: Elaboración Propia, MS Excel 2013. | 79 |
| B.19. Parte 3: Resultados de p-valores prueba t de Welch. Fuente: Elaboración Propia, MS Excel 2013. | 80 |
| B.20. Resultados de p-valores prueba MCS . Fuente: Elaboración Propia, Matlab 2016a, MS Excel 2013. | 81 |
| B.21. Resultados de p-valores prueba MCS para modelo <code>anfis_scr10_suge_back</code> . Fuente: Elaboración Propia, Matlab 2016a, MS Excel 2013. | 82 |
| B.22. Resultados de p-valores prueba MCS para modelo <code>anfis_scr06_suge_hyb</code> . Fuente: Elaboración Propia, Matlab 2016a, MS Excel 2013. | 83 |
| B.23. Resultados de p-valores prueba t de Welch para Análisis de Sensibilidad del modelo <code>anfis_scr06_suge_hyb</code> . Fuente: Elaboración Propia, MS Excel 2013. | 84 |
| C.1. Pronóstico de Consumo Energético Para Julio 2016-2017 mediante modelo <code>anfis_scr06_suge_hyb</code> | 85 |

Índice de Figuras

| | |
|--|----|
| 4.1. Serie de Tiempo mensual de Consumo Total de Energía Primaria 1973-2016. | 14 |
| 5.1. Esquema representativo del modelo de un perceptrón. | 20 |
| 5.2. Esquema representativo del modelo de una Time Delayed Neural Network. | 21 |
| 5.3. Esquema representativo del modelo de una Capa Escondida. | 22 |
| 5.4. Esquema representativo de la “Fuzzificación” de las <i>entradas</i> . | 27 |
| 5.5. Esquema representativo de los Conjuntos Difusos. | 28 |
| 7.1. Prueba de Raíz Unitaria con prueba Dickey-Fuller Aumentada para Variable Nivel. | 39 |
| B.1. Resultados de Prueba de Raíz Unitaria con prueba Dickey-Fuller Aumentada para Serie en su Nivel. | 66 |
| B.2. Resultados de Prueba de Raíz Unitaria con prueba Dickey-Fuller Aumentada para Primera Diferencia de la Serie. | 67 |

1 | Problema de Investigación

El saber qué es lo que acontecerá siempre ha sido siempre una de las interrogantes más grandes del ser humano. Esto ha permitido que el humano se pueda preparar para el futuro y así poder tener mayores probabilidades de éxito ante escenarios adversos.

1.1. Series de Tiempo

Una de las metodologías más utilizadas hoy en día para pronósticos son las llamadas "series de tiempo", las cuales datan de los años 70' ([Box and Jenkins, 1970](#)). La particularidad de este método es el que se busca pronosticar un valor futuro para una variable, solo sabiendo su valor en el pasado. Esto sin tomar en cuenta todos los factores que pueden afectar a la variable en cuestión, sino que sólo se genera una dependencia sobre el tiempo.

La econometría ha generado una gama muy amplia de modelos que permiten predecir el valor de una variable utilizando modelos regresivos con muchas variables. Sin embargo, esta misma ha creado modelos que trabajan con los datos como series de tiempo como los modelos, las 3 categorías más amplias entre las que se clasifican estos modelos son:

- Modelos Autoregresivos (AR)
- Modelos Integrados (I)
- Modelos de Medias Móviles (MA)

El análisis o los pronósticos obtenidos mediante los métodos anteriores por separado pueden ser buenos en etapas exploratorias con el fin de más o menos tener una noción del comportamiento de la variable que se quiere analizar. Sin embargo, existen métodos más precisos para pronósticos de series de tiempo, estos modelos integran o mezclan a los modelos por separado explicitados anteriormente, como los modelos ARMA, ARIMA (Rojas et al., 2008), por ejemplo.

1.2. Pronóstico del Consumo de Energía Eléctrica

En general, como los pronósticos buscan acercarse a la "verdad" que deparará el futuro, estos tienen mucha trascendencia en la economía y áreas relacionadas. En específico, el pronóstico del consumo energético ha permitido desde sus inicios una mejora en la planeación de las empresas o firmas que ofertan energía eléctrica. Esto es porque las firmas con estos pronósticos tienen un horizonte más o menos claro, lo cual les permite generar objetivos específicos y planes para alcanzar mejores resultados.

El saber que deparará el futuro permite a las firmas productoras de energía eléctrica contratar mano de obra, mantener operarios en horas extra, e incluso permite que estas vean la posibilidad de ampliar o disminuir su capacidad de producción (entre otras).

Así como existe el deseo de generar buenos pronósticos para el consumo energético, existen muchos artículos científicos que buscan dar pronósticos para el consumo energético. Con una reseña de métodos de inteligencia artificial para pronósticos de demanda energética (Raza and Khosravi, 2015), otra reseña de predicción de consumo energético (Zhao and Magoulès, 2012), arquitectura integrada híbrida para pronóstico de consumo energético (Maté et al., 2016) y pronóstico mensual de consumo energético por medio de redes neuronales y series de Fourier (González-Romera et al., 2008), entre otros.

1.3. Pronóstico del Consumo Energético de Largo Plazo

Se define **Consumo Energético (o Demanda Energética) de Largo Plazo** como la energía consumida de manera agregada (medida en Quadrillion Btu), es decir, de todo el país (Estados Unidos) de forma Mensual, Cuatrimestral, y Anual (Ventosa et al., 2005).

1.3.1. Antecedentes

Algunas décadas atrás, en Estados Unidos el sector de energía eléctrica estaba regulado. Los monopolios de servicios públicos utilizaban el pronóstico de consumo energético de corto plazo para asegurar su oferta de servicios, mientras que el pronóstico de largo plazo era utilizado como base para la planeación e inversiones de capacidad (Shahidehpour et al., 2002) (Weron, 2014). Luego, a comienzos de la década de los 90' las posiciones cambiaron, mediante la desregulación e introducción de nuevos mercados de servicios de electricidad competitivos (Weron, 2006), donde los consumidores en principio son libres de elegir a su proveedor (Weron, 2006). El panorama cambió de un sector regulado por el gobierno (anteriormente monopolios naturales), a uno muy competitivo, por lo que el pronóstico de la demanda de energía sería cada vez más crucial para sus operaciones.

A nivel estratégico se han vuelto cada vez más importantes los pronósticos del precio de la electricidad y su consumo. Estas variables permiten determinar las utilidades esperadas, volviéndose fundamentales en los mecanismos de toma de decisiones.

A la fecha existen estados en que siguen siendo monopolios naturales y estados donde se ha implantado la entrada de muchas empresas de retail de venta de energía eléctrica. En los estados donde existen monopolios naturales, los consumidores finales tienen al monopolista como ofertante de energía eléctrica, dado que el monopolista se comporta como productor y distribuidor (PJM Learning Center, 2016). Mientras que los estados donde existen mercados de energía retail, los consumidores no tratan con los productores de energía, sino con los distribuidores retail (EPSA, 2016b). Si bien ambos mercados

funcionan de distinta manera, ambos son regulados por el estado (EPSA, 2016a).

1.3.2. Justificación

Dada la regulación, los costos en que incurren los retailers por sobreprecio o subprecio en los contratos con los productores de energía junto con el poco poder de mercado en mercados competitivos del retail de energía eléctrica pueden llevar a pérdidas financieras significativas, incluso a la quiebra en algunos casos (Weron, 2006). En especial los mercados de servicios de electricidad, por su regulación, el aumento en los costos no puede ser traspasado a los consumidores. Es por esto que el pronóstico de la carga o consumo y los precios spot de la energía eléctrica se vuelve de vital importancia.

Un generador, empresa de servicios de electricidad, o consumidor industrial grande que sea capaz de pronosticar los precios de la energía en el mercado primario con un algún nivel de certeza puede ajustar su estrategia de oferta en el caso de las primeras o su estrategia de producción en el caso de la última con el objetivo de minimizar costos o maximizar beneficios respectivamente. Aún cuando los pronósticos de precios y carga o consumo son utilizados por varios departamentos dentro de una empresa de energía, es difícil poder cuantificar los beneficios de mejorar los pronósticos. Según Hong (2015), un ahorro estimado proveniente de la reducción del Error Porcentual Absoluto Medio (MAPE, en inglés) en un 1 % para una empresa de servicios de electricidad que posea 1 [GW] de consumo máximo es:

- **\$ 500,000 USD anuales por pronóstico del consumo energético de largo plazo.**
- \$300,000 USD anuales por pronóstico del consumo energético de corto plazo.
- \$600,000 USD anuales por pronóstico de consumo energético de corto plazo y pronóstico de precios de corto plazo.

Dado que el sólo disminuir en un 1 % el MAPE de un pronóstico puede desencadenar ahorros cercanos a medio millón de dólares para las empresas de capacidad mayor o igual

a 1 [GW] de potencia, se cree que es una oportunidad que puede ser explotada y por tanto la motivación o justificación económica del estudio.

1.4. Inteligencia Computacional

Los métodos de Inteligencia Computacional provienen de la Inteligencia Artificial, siendo una subcategoría de la última.

La ventaja y razón por la cual estos métodos son cada vez más ocupados en diversas áreas es su capacidad de aprender de los datos entregados, separando a la base de datos en dos, según [Raza and Khosravi \(2015\)](#):

- **Entrenamiento**

- **Prueba**

Al aprender de los datos de **entrenamiento**, los algoritmos, tras prueba y error, van generando una aproximación cada vez mejor a los valores reales de la parte de **prueba** de la base de datos.

Para esta investigación se utilizará el método de Inteligencia Computacional llamado **ANFIS**.

2 | Objetivos

2.1. Objetivo General

Determinar una configuración de sistema de inferencia ANFIS que permita disminuir el error de pronóstico por sobre el de los métodos actuales el consumo o carga eléctrica mensual en Estados Unidos. Utilizando una base de datos longitudinal de consumo o carga mensual como serie de tiempo.

2.2. Objetivos Específicos

- Determinar el tipo de sistema de inferencia óptimo para el problema de pronóstico de carga energética.
- Determinar el tipo de malla (grid) a utilizar para la lógica difusa (fuzzy logic).
- Determinar la relación óptima de base de datos de entrenamiento vs prueba.
- Determinar el algoritmo óptimo de re-configuración de los parámetros.
- Proponer un pronóstico para el consumo de energía eléctrica mensual para todo el año 2017.

3 | Marco Teórico

3.1. Pronóstico del Consumo Energético en la Actualidad

A la fecha existen muchas publicaciones que desarrollan el tema de pronosticar la demanda energética mediante el uso de algoritmos de inteligencia computacional. A continuación se detallan algunos artículos científicos que se aproximan a soluciones para los pronósticos de situaciones en particular, los cuales serán utilizados como referencia y/o guía para el presente trabajo.

La tesis de [Kialashaki \(2014\)](#) estudia el uso de Redes Neuronales Artificiales para pronosticar el consumo energético de Estados Unidos por sectores con data histórica desde 1987 a 2012.

[González-Romera et al. \(2008\)](#) estudia el comportamiento periódico del consumo energético mensual en España usando un enfoque novedoso híbrido, donde se aisló la tendencia de los datos, utilizando Series de Fourier para pronosticar el comportamiento periódico de la serie, mientras que Redes Neuronales Artificiales para pronosticar la tendencia, obteniendo un MAPE menor al 2 %, menor que al utilizar los métodos ARIMA y Redes Neuronales por separado.

[Hassan et al. \(2015\)](#) utiliza métodos de agregación de los resultados (media simple, media truncada, modelo Bayesiano para promediar) obtenidos por 100 distintas configuraciones de Redes Neuronales para el pronóstico de demanda energética con datos obtenidos

de bases de datos de consumo eléctrico de intervalos de 30 minutos de Australia y Nueva York, mostrándose un mejor desempeño al utilizar el método agregado de resultados por sobre los pronósticos de las configuraciones de Redes Neuronales individuales.

[Grolinger et al. \(2016\)](#) estudia el consumo energético en lugares de eventos utilizando dos métodos de inteligencia computacional: Redes Neuronales, y SVR (Regresión de Vectores de Soporte). Se utilizó como base, datos diarios, horarios y de 15 minutos, obteniéndose mayor precisión en el pronóstico consumo energético en los modelos con datos diarios que los horarios y de 15 minutos. Del estudio se desprende que la predicción del consumo "peak" diario fue significativamente más precisa que la predicción del consumo.

En tanto, [Salcedo-Sanz et al. \(2015\)](#) intenta estimar de la demanda energética mediante 14 variables macroeconómicas a lo largo de 30 años (desde el 2008 hacia atrás), generando distintas variaciones a los métodos Busqueda Armoniosa (HS) y Máquina de Aprendizaje Extremo (ELM), logrando una mejora de un 15 % en la estimación de la demanda energética, comparado con el método de Algoritmos Genéticos propuesto en la literatura.

El estudio de [Tran et al. \(2012\)](#) muestra una comparación entre los métodos SARIMA (Seasonal Auto Regressive Integrated Moving Average) y ANFIS (Adaptive Network Based Fuzzy Inference System) para el pronóstico hora a hora del consumo energético para la data de la ciudad Hanoi, en Vietnam. Obteniéndose como resultado que el modelo SARIMA produce mejores resultados.

[Cristian et al. \(2007\)](#) compara el dos distintos tipos de redes neuronales artificiales, "Feedforward" y "Elman" en el pronóstico de corto plazo de consumo de energía eléctrica para el área de Banat, Rumania. Tras probar distintas estructuras, se concluye que el mejor desempeño lo obtiene las redes neuronales artificiales "Feedforward" dado que las redes "Elman" tardan mucho tiempo en disminuir el error de "entrenamiento" para estructuras simples de inputs.

Yang et al. (2016) propone un modelo SVR (Support Vector Regression) para el pronóstico de consumo eléctrico en Sud Gales. Para pre-procesar la serie de tiempo, se genera una serie de tiempo óptima por el método de reconstrucción espacial por fase (PSR) lo que permite disminuir el tiempo de computación de la fase de entrenamiento. Se concluye que SVR promete mucho dada su capacidad para trabajar con muestras pequeñas, no linealidad y muestras de muchas variables. Sin embargo, para muestras grandes su tiempo de computación aumenta y los problemas se vuelven complejos.

Para evadir las limitaciones individuales de los modelos de pronósticos, Xiao et al. (2016) propone un modelo combinado, un algoritmo “luciérnaga” (FA) modificado para el pronóstico de consumo eléctrico cada 30 minutos para data de Nueva Sud Gale, el Estado de Victoria y el Estado de Queensland en Australia. Tras comparar los MAPE con otros 6 modelos individuales se obtiene una mejora de 0.7138 % a 7.3367 % a favor del modelo propuesto.

Pandey et al. (2010) propone un modelo híbrido mediante una descomposición “Wavelet” para el pronóstico de energía eléctrica de 24 y 168 horas hacia adelante, para una base de datos de Alberta, Canadá. Luego de aplicar la descomposición “Wavelet” se utilizan los métodos RBFNN (Radial Basis Function Neural Network), series de tiempo y FINN (Fuzzy Inference Neural Network). Se concluye que al aplicar la descomposición “Wavelet” para darlo como entrada a los demás métodos resultados y disminuye los tiempos de entrenamiento.

Yun et al. (2008) muestra un modelo integrado, compuesto por el modelo RBF (Radial Basis Function) y el modelo ANFIS (Adaptive Neural Fuzzy Inference System) para el pronóstico de consumo energético de una región de Australia. El modelo propone utilizar el modelo ANFIS para mejorar los resultados obtenidos por RBF. Los resultados indican que el método ANFIS permite integrar los precios de la electricidad, característica o variable que no posee o carece e modelo RBF.

La investigación de [Hong et al. \(2013\)](#) propone un modelo híbrido compuesto por SVR (Support Vector Regression) y CGA (Chaotic Genetic Algorithm) para el pronóstico del consumo de energía eléctrica en el noreste de China. El modelo SVR se aplica para el pronóstico de las componentes cíclicas, mientras que el CGA para mejorar el desempeño del pronóstico, dado que la aleatoriedad que este algoritmo provee evita caer y estancarse en mínimos locales. Los resultados indican que pronósticos más certeros que ARIMA y otras variaciones del modelo SVR con estacionalidad.

El paper de [Kavousi-Fard et al. \(2014\)](#) presenta un nuevo modelo SVR (Support Vector Regression) - MFA (Modified Firefly Algorithm) para el pronóstico de consumo energético de una data de Irán. El modelo propuesto muestra tener mejores resultados que los modelos ARMA, ANN y otras distintas variaciones de modelos SVR.

[Bashir and El-Hawary \(2009\)](#) proponen un modelo integrado de ANN (Artificial Neural Network) junto con un PSO (Particle Swarm Optimization) para el pronóstico horario del consumo energético en una área del Estado de Nueva York. Se utiliza el algoritmo PSO para obtener los pesos de los parámetros de la red de neuronas artificiales, la descomposición “Wavelet” del algoritmo PSO ayuda a encontrar los valores de los pesos de la red mejor que el algoritmo BP (Back Propagation). Los resultados muestran que el uso del algoritmo PSO genera mejores pronósticos que mediante el algoritmo BP.

[Amjady and Keynia \(2009\)](#) proponen un modelo híbrido para el pronóstico de consumo energético para una base de datos horaria de Norte América y Nueva York. El modelo consta de una transformación de “Wavelet” en la etapa preliminar; luego una combinación de EA (Evolutionary Algorithm) y NN (Neural Network) para predecir cada componente; por último, se aplica la transformación de “Wavelet Inversa” para obtener el pronóstico. Se concluye que el modelo propuesto es robusto y puede ser adaptado a cualquier sistema de Energía.

[Barak and Sadegh \(2016\)](#) pronostican el consumo de energía en Irán por medio de un

modelo híbrido ARIMA-ANFIS. 3 distintas estructuras y configuraciones son probadas para el pronóstico. Se concluye que el modelo híbrido mejora los resultado individuales de ARIMA y ANFIS.

El estudio de [Bahrami et al. \(2014\)](#) presenta un modelo híbrido para el pronóstico de consumo de energía eléctrica con bases de datos de Irán y Nueva York. El modelo consta de una transformación “Wavelet” para eliminar las componentes de altas frecuencias. Luego para aumentar la precisión de la generación de coeficientes de GM (Grey Model) se utiliza el algoritmo PSO (Particle Swarm Optimization). Tras correr las simulaciones se confirma el desempeño favorable del modelo propuesto con respecto a los otros métodos o modelos benchmark.

[Selakov et al. \(2014\)](#) proponen un modelo híbrido, compuesto de PSO (Particle Swarm Optimization) y SVM (Support Vector Machine) para el pronóstico del consumo de energía eléctrica en la ciudad de Burbank. La arquitectura del modelo consta de 3 etapas: pre-procesamiento, módulo SVM y luego el módulo PSO. Los resultados indican mejores pronósticos que los generados con métodos convencionales.

[Lee and Ko \(2011\)](#) presenta un modelo híbrido para el pronóstico de consumo energético de distintas bases de datos de Taipower Company en 2007. El modelo consiste en un esquema “lifting” que por medio de “Wavelet” Multi-revolution Analysis (MRA) descompone a la serie original en distintas series que poseen distintos niveles de “revolución” para luego utilizar modelos ARIMA para el pronóstico. Los resultados muestran que el modelo propuesto posee mejores pronósticos que BPN (Back Propagation Network) y ARIMA por separado.

En su paper [Hong \(2009\)](#) presenta un modelo SVR (Support Vector Regression) con un “Algoritmo Inmune” (IA) para pronosticar el consumo eléctrico de Taiwan. Donde IA entrega los parámetros al modelo SVR. Se obtiene por resultado que el modelo SVRIA propuesto obtiene mejor desempeño que los métodos SVMG, modelo de regresión y ANN

en el pronóstico de consumo eléctrico.

Nie et al. (2011) utiliza un modelo híbrido compuesto por ARIMA y SVMs (Support Vector Machines) para el pronóstico del consumo energético de corto plazo. Con la base de datos de Heilongjiang en China. Se concluye que ambos modelos se complementan positivamente, donde el modelo SVMs mejora las predicciones generadas por el método ARIMA.

En resumen, los métodos más utilizados en la actualidad son métodos de Inteligencia Computacional. En particular los más utilizados son: Algoritmos genéticos y/o alguna variación de ellos, Redes Neuronales Artificiales, Descomposición de Wavelet, SVR, y ARIMA (que no es un método de Inteligencia Computacional). Con respecto a los métodos o modelos anteriormente mencionados, los Algoritmos Genéticos (GA) son utilizados para optimización, en particular para este tipo de problemas de pronósticos son utilizados para optimizar los parámetros obtenidos por algún otro método de regresión o red con el fin de minimizar el error de predicción; las Redes Neuronales Artificiales (ANN) para generar datos de salida con el uso de datos de entrada mediante fases de entrenamiento y configuraciones de redes, permiten manejar mejor que otros métodos de predicción la no linealidad de los datos; la descomposición Wavelet permite descomponer una serie en distintas series que se mueven a distintas revoluciones, lo que permite a los demás métodos trabajar sobre series con menores variaciones para tener mejores predicciones; las regresiones SVR permiten manejar la no linealidad de los datos y muestras pequeñas mientras se generan las entradas a partir de las salidas, aunque generalmente no se utiliza como único método; por último el método o modelos ARIMA se utiliza para el pronóstico de series de tiempo, sus desventajas principales son el trabajo con data no lineal dado su método regresión, actualmente se utiliza como método de apoyo y/o ayuda para elegir las variables regresoras (en fases exploratorias) para otros métodos de regresión.

3.2. ¿Cómo se ha resuelto el Problema hasta ahora?

Dado que los datos fueron extraídos de las bases de datos de la EIA (Administración de Información Energética de Estados Unidos). El método que ellos han usado para pronosticar la demanda de energía eléctrica es el de Regresión Lineal Simple, tomando en algunos casos las variables con rezago, utilizando modelos AR(1) a AR(3) para buscar/encontrar autocorrelación (EIA, 2015). Dado que esta organización posee información de muchas otras índoles, esta estima o pronostica la demanda energética por sector y luego, en un proceso de agregación se obtienen los pronósticos de consumo energético agregado, mensual y anual.

4 | Data

Los datos para las pruebas y benchmarks que se realizarán fueron obtenidos de la web de la Administración de Información de Estados Unidos (EIA)¹. Los Base de datos corresponde a una **serie de tiempo** del Consumo Total de Energía Primaria de manera mensual en Cuatrillones² de Btu desde Enero de 1973 a Junio de 2016 (siendo un total de 522 datos). La data se encuentra anexada en el Anexo A. La serie de tiempo se puede apreciar en la Figura 4.1.

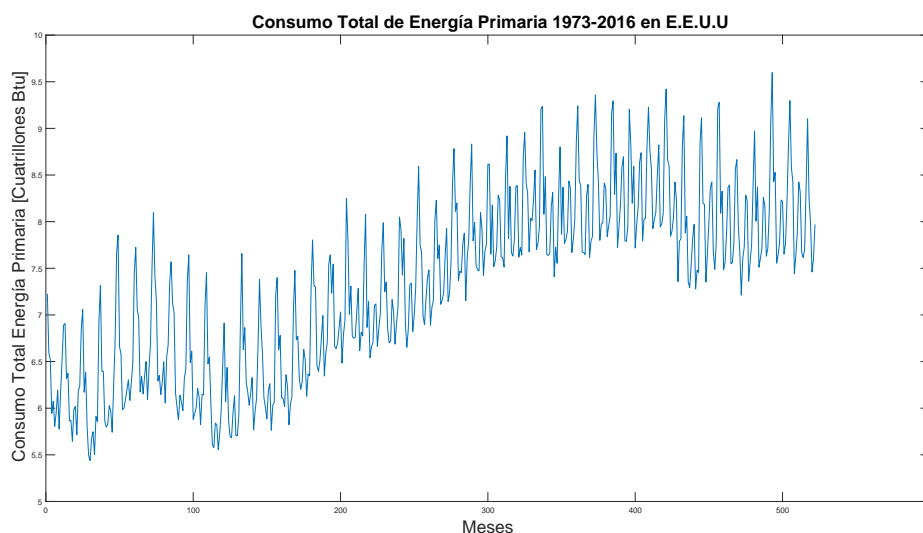


Figura 4.1: Serie de Tiempo mensual de Consumo Total de Energía Primaria 1973-2016.

Fuente: Elaboración Propia, Matlab 2016a.

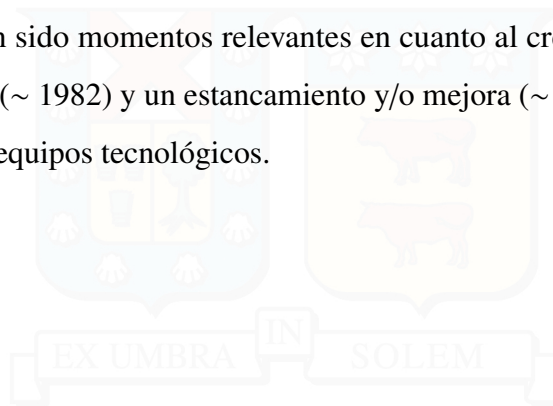
Tras visualizar la serie (ver Figura 4.1) es posible notar una clara línea de tendencia, la cual predomina entre fines de 1982 e inicios de 2002 aproximadamente. Asimismo, exista una clara estacionalidad cada 12 meses en forma de valles y crestas, no necesariamente en

¹<http://www.eia.gov/totalenergy/data/monthly/>

²10¹⁵

magnitud, pero en forma (comportamiento).

Si bien *ad priori* no es posible sacar conclusiones, es posible ver una tendencia de la serie a volver a la línea de tendencia. Explícito el punto anterior, es posible que los puntos donde cambia la tendencia (se hace más inclinada), fines de 1982 y aproximadamente inicios de 2002, hayan sido momentos relevantes en cuanto al crecimiento del consumo de nuevas tecnologías (~ 1982) y un estancamiento y/o mejora (~ 2002) de eficiencia con respecto al uso de los equipos tecnológicos.



5 | Contexto Teórico

5.1. Modelo ARIMA

El modelo ARIMA(p,d,q) (Autoregressive Integrated Moving Average) es una generalización del modelo ARMA (Autoregressive Moving Average) que fue propuesto por primera vez en la tesis de [Whittle \(1951\)](#) y popularizado por [Box and Jenkins \(1970\)](#). El modelo ARMA(p,q) es utilizado para el análisis y modelamiento de series de tiempo estacionarias, es decir, que la distribución de probabilidad no cambie en el largo plazo. Dicho lo anterior, tampoco debe variar su media y varianza si es que existen.

El modelo ARMA (5.3) consiste en la sumatoria de dos polinomios, el primero (AR(p)) que posee los rezagos de la variable (auto-regresores) hasta algún tiempo p en el pasado (5.1). El segundo polinomio (MA(q)) corresponde a las medias móviles que corresponde a ruidos blancos o “shocks” hasta algún tiempo q en el pasado (5.2). Si bien en [Box et al. \(2008\)](#) los modelos se expresan de manera distinta (sin término constante), se utilizará la nomenclatura de Eviews 8 (añade el término constante):

$$y_t = \alpha_0 + \sum_{i=1}^p \alpha_i \cdot y_{t-i} + \epsilon_t \quad (5.1)$$

$$y_t = \mu_0 + \sum_{j=1}^q \mu_j \cdot \epsilon_{t-j} + \epsilon_t \quad (5.2)$$

$$y_t = c + \sum_{i=1}^p \alpha_i \cdot y_{t-i} + \sum_{j=1}^q \mu_j \cdot \epsilon_{t-j} + \epsilon_t \quad (5.3)$$

Donde y_t corresponde al valor de la serie en el tiempo t , y_{t-i} al valor de la serie en un

tiempo $t - i$, α_0 corresponde a una constante, α_i a parámetros a estimar por el método de mínimos cuadrados ordinarios, mientras que ϵ_t corresponde al error (ruido blanco o “shock”) en el tiempo t . μ_0 y c corresponden a una constante, μ_j corresponde a los parámetros a estimar por mínimos cuadrados y ϵ_{t-j} al error (ruido blanco o “shock”) en el tiempo $t - j$.

5.1.1. Modelos Integrados

Algunas series pueden ser no estacionarias en su variable nivel, este es el caso del uso del modelo ARIMA, la I en ARIMA sugiere que el serie debe diferenciarse d veces para que la serie fuera estacionaria. Luego de hacer la serie estacionaria, se trabaja con el modelo ARMA. La manera de calcular la **primera diferencia** (5.4), la **segunda diferencia** (5.5) y la **d -ésima diferencia** (5.6).

$$\Delta y_t = y_t - y_{t-1} \quad (5.4)$$

$$\Delta^2 y_t = \Delta y_t - \Delta y_{t-1} \quad (5.5)$$

$$\vdots$$

$$\Delta^d y_t = (1 - L)^d y_t \quad (5.6)$$

Donde Δy_t corresponde a la primera diferencia de la serie, $\Delta^2 y_t$ a la segunda diferencia de la serie, y $\Delta^d y_t$ a la d -ésima de diferencia de la serie. Por otro lado, L corresponde al operador “lagg”, por lo que $Ly_t = y_{t-1}$, $L^2 y_t = y_{t-2}$, y así sucesivamente.

5.1.1.1. Prueba de Dickey-Fuller Aumentada

Para determinar si una serie es estacionaria o no en su nivel, es necesario realizar una prueba de raíz unitaria, las que de existir indicarían que la serie no es estacionaria. De esta manera, la cantidad de raíces unitarias será la cantidad de veces que será necesario diferenciar la serie para obtener una serie estacionaria.

La prueba o test propuesta por [Dickey and Fuller \(1979\)](#) permite determinar la presencia de raíces unitarias. El caso más básico de modelo para determinar la presencia de raíces

unitarias es con un modelo AR(1)³. Donde se comienza con el modelo:

$$y_t = \rho y_{t-1} + x_t' \delta + \epsilon_t \quad (5.7)$$

Donde y_t es el valor de la serie en el tiempo t , ρ parámetro, x_t' pueden ser variables exógenas opcionales, δ parámetros opcionales dependiendo de x_t' y ϵ_t se asume ruido blanco. Luego al modelo (5.7) se le resta a ambos lados y_{t-1} obteniéndose:

$$\Delta y_t = \alpha y_{t-1} + x_t' \delta + \epsilon_t \quad (5.8)$$

Donde la prueba de Dickey-Fuller aumentada consiste en probar la significancia del parámetro α . La prueba posee la hipótesis nula (5.9) e hipótesis alternativa (5.10):

$$H_0 : \alpha = 0 \quad (5.9)$$

$$H_a : \alpha < 0 \quad (5.10)$$

Que posee como estadístico que distribuye t-Student⁴ y se calcula como:

$$t_\alpha = \frac{\hat{\alpha}}{se(\hat{\alpha})} \quad (5.11)$$

Donde $\hat{\alpha}$ es el valor estimado de α , y $se(\hat{\alpha})$ corresponde al error estándar del coeficiente.

Al ser significativa la prueba, se rechazaría la hipótesis nula, por ende la serie no poseería raíz unitaria, por ende la serie sería estacionaria. De manera análoga, al no ser significativa la prueba llevaría a inferir que la serie no es estacionaria.

5.2. Modelo GARCH

El modelo GARCH (Generalized Autoregressive Conditional Heteroskedasticity) corresponde a la generalización propuesta por [Bollerslev \(1986\)](#) al modelo ARCH de [Engle \(1982\)](#) donde es posible hacer la analogía del modelo AR al modelo ARMA. Este modelo

³Para modelos de orden superior y/o con uso de medias móviles ver [Said and Dickey \(1984\)](#).

⁴Los valores críticos se encuentran disponibles en el paper de [Dickey and Fuller \(1979\)](#).

permite modelar de mejor manera que el modelo ARCH el fenómeno “Long Memory”⁵ como también una estructura de rezagos más flexible.

Este modelo sirve para modelar las series donde el error (ϵ_t), que antes se asumía ruido blanco, puede variar en el tiempo. Es decir, que la varianza del error esté en función del tiempo:

$$\epsilon_t \sim N(0, \sigma^2) \quad (5.12)$$

$$\sigma^2 = \sigma^2(t)$$

Donde el modelo GARCH(r,s) (5.14) agrega al modelo ARCH(s) (5.13), el último término.

$$\sigma^2 = \alpha_0 + \sum_{i=1}^s \alpha_i \epsilon_{t-i}^2 \quad (5.13)$$

$$\sigma^2 = \alpha_0 + \sum_{i=1}^s \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^r \beta_j \sigma_{t-j}^2 \quad (5.14)$$

Donde α_i, β_j son parámetros. Mientras que ϵ_{t-i}^2 y σ_{t-j}^2 son el error en un rezago i y la varianza del error en un rezago j .

5.3. Modelos ANN

Los modelos ANN (Artificial Neural Networks) o redes neuronales artificiales intentan homologar el comportamiento y el proceso de aprendizaje del ser humano.

5.3.1. El perceptrón

La teoría de estas redes se basa en su unidad más básica el *perceptrón* (ver Figura 5.1), que sería el equivalente a una red de una sola neurona. Según [Kacprzyk and Pedrycz \(2015\)](#), el **perceptrón** un modelo simple de una neurona que toma señales o patrones que son codificados como un vector de entradas (reales) $\vec{x} = (x_1, x_2, \dots, x_{n+1})$ asociado al vector

⁵Se dice que una serie de tiempo posee “Long Memory” si la dependencia estadística entre dos puntos u observaciones decrece a una tasa inferior que el decaimiento exponencial.

de **pesos** sinápticos $\vec{w} = (w_1, w_2, \dots, w_{n+1})$. Mientras que la salida *Out* está determinada por:

$$Out = f(red) = f(\vec{x} \cdot \vec{w}) = f\left(\sum_{j=1}^{n+1} x_j w_j\right) = f\left(\sum_{j=1}^n x_j w_j - \theta\right) \quad (5.15)$$

Donde f^6 es la función de activación. Por convención, si existiesen n entradas para el **perceptrón**, el valor de la entrada $n + 1$ será fijado en -1 y valor del peso asociado a $n + 1$ en θ . Al último se le llama valor “**excitation threshold**”.




Figura 5.1: Esquema representativo del modelo de un perceptrón.

Fuente: Elaboración Propia, Illustrator CC 2015.

Donde a) es el vector o capa de entrada, b) los respectivos pesos, c) el **perceptrón**, d) la función de activación y e) la respectiva salida.

Para este trabajo, como se trata del modelamiento de series de tiempo el tipo de Redes Neuronales, habiendo otras, serán las Redes Neuronales *Recurrentes*.

⁶Dada la gran cantidad de funciones de activación distintas, estas no se detallarán en este trabajo.

5.3.2. Modelos ANN Recurrentes (RNN)

Para algunos modelos, como las series de tiempo, no basta que el entrenamiento consista en el parear una *entrada* a una *salida*. Este tipo de modelos posee un contexto temporal, en otras palabras, la *salida* no solo está determinada por la *entrada* sino que también por el historial de sucesos hasta un momento. En particular, para este trabajo se utilizará el esquema representativo expuesto en la Figura 5.2.

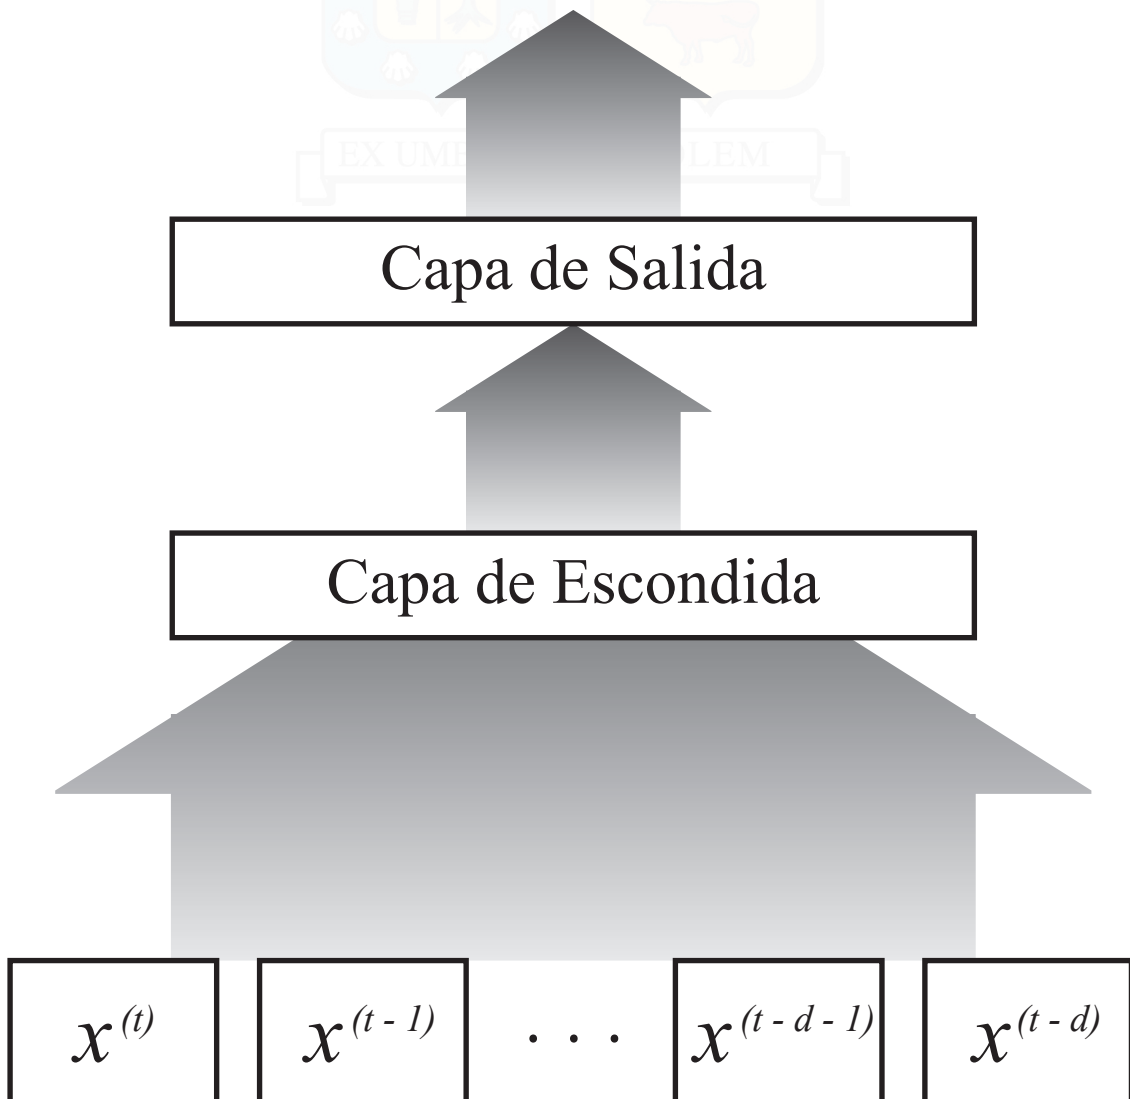


Figura 5.2: Esquema representativo del modelo de una Time Delayed Neural Network.

Fuente: Elaboración Propia, Illustrator CC 2015.

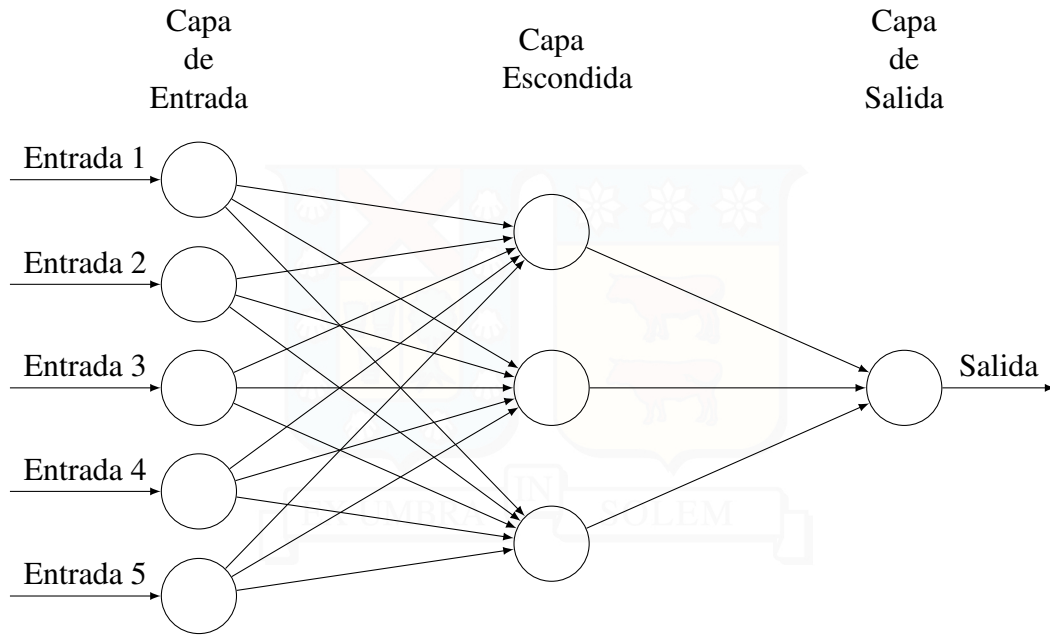


Figura 5.3: Esquema representativo del modelo de una Capa Escondida.

Fuente: Elaboración Propia, TikZ.

5.3.2.1. Capas Escondidas (Hidden Layers)

También conocidas como las capas de neuronas escondidas, estas capas escondidas consisten en capas donde se realizan distintos tipos de cálculos, y cómo se encuentran entre la *capa de entradas* y *salidas* (ver Figura 5.3) no es posible verlas como salida, por eso el término *escondidas*.

A mayor cantidad de de capas escondidas, el tiempo de computación de los problemas aumenta, pero permite explicar problemas más complejos (Kacprzyk and Pedrycz, 2015).

5.3.2.2. Algoritmo de Entrenamiento

Dada posibilidad de las capas escondidas encuentren relaciones no lineales en la Dentro de los muchos algoritmos de entrenamiento, se utilizará el algoritmo de Levenberg-Marquardt propuesto por Levenberg (1944) y actualizado por Marquardt (1963). Según Gavin (2016), la ecuación “amortiguada” matricial que utiliza Matlab es:

$$[J^T W J + \lambda \text{diag}(J^T W J)] \delta = J^T W (y - \hat{y}) \quad (5.16)$$

Donde J es el jacobiano (5.17⁷), W es una matriz diagonal de pesos opcionales que usualmente tiene como términos $W_{ii} = 1/\sigma_{y_i}^2$, λ es el factor no-negativo de “amortiguamiento”, δ el factor de actualización que mueve los parámetros en la dirección más inclinada hacia el mínimo (local o global), y el vector con los valores de la serie y \hat{y} el vector con los valores estimados de la serie.

$$J = \frac{\partial f(x_i, \beta)}{\partial \beta} \quad (5.17)$$

5.3.2.3. Medida de Desempeño

Existen muchas medidas de desempeño que permiten determinar qué tan bueno es un modelo. Para este trabajo y este modelo se utilizará RMSE, el cual se detallará en al Subsección 5.6.1.

⁷El jacobiano representa la sensibilidad local de la función $f(x_i, \beta)$ a la variación de los parámetros β

5.4. Modelo ANFIS

El modelo ANFIS (Adaptive Neuro Fuzzy Inference System) (Jang, 1993) consiste en la combinación de dos modelos de Inteligencia Computacional en un sistema de inferencia unificado. AN proviene de la parte de ANN que es la actualiza y reajusta los parámetros que son determinados en una primera instancia por un sistema FIS. Donde el último genera un sistema de inferencia a partir de la **Lógica Difusa** (Fuzzy Logic)⁸.

5.4.1. Lógica Difusa (Fuzzy Logic)

A diferencia de la lógica Booleana, donde solo existen dos resultados (1 o 0), la lógica difusa tiene más relación con la lógica multi-valor. Si bien la lógica difusa es distinta en muchos aspectos a la lógica multi-valor, tienen en común que pueden existir más de solo dos resultados, por eso la analogía.

En un sentido más amplio, la lógica difusa es casi sinónimo de la teoría de conjuntos difusos, donde estos conjuntos poseen límites difusos. Esto último, permite que un valor pueda pertenecer **en un cierto grado** a un cierto conjunto.

Una de las aplicaciones más relevantes de la lógica difusa es en la conformación de “if-then” o simplemente “reglas difusas”. Estas últimas permiten trabajar con **premisas difusas y conclusiones difusas**.

Una de las cosas más importantes de tener en cuenta es que la Lógica Difusa es un super-conjunto de la Lógica Booleana, por lo que los operadores lógicos deben **“mantenerse”**.

5.4.1.1. Operadores Lógicos Difusos (Fuzzy Operators)

La lógica Booleana nos dice lo siguiente (ver Tabla 5.1). Dado que ahora los valores de la lógica difusa pueden estar dentro del intervalo $[0, 1]$ (ver Figura 5.5), esta necesita operadores puedan trabajar aquellos valores. Dicho esto, los operadores Booleanos no permiten dichas operaciones. Como solución a esto es posible cambiar los operadores, pero los valores en los extremos deben mantenerse. Como ejemplo, podrían ser estos (ver Tabla 5.2), entre otras.

⁸Solo se tratarán los contenidos que tengan relevancia al paquete de Matlab “Fuzzy Logic Toolbox™”

Tabla 5.1: Operadores de Lógica Booleana.**Fuente:** Elaboración Propia.

| | | | | | |
|----------|---|--------------|----------|---|--------------|
| A | B | A y B | A | B | A o B |
| 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 1 | 0 | 0 | 1 | 1 |
| 1 | 0 | 0 | 1 | 0 | 1 |
| 1 | 1 | 1 | 1 | 1 | 1 |
| y | | | o | | |

| | |
|-----------|------|
| A | no A |
| 0 | 1 |
| 1 | 0 |
| no | |

Tabla 5.2: Ejemplo de Operadores Difusos.**Fuente:** Elaboración Propia.

| | | | | | |
|----------|---|----------|----------|---|----------|
| A | B | min(A,B) | A | B | max(A,B) |
| 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 1 | 0 | 0 | 1 | 1 |
| 1 | 0 | 0 | 1 | 0 | 1 |
| 1 | 1 | 1 | 1 | 1 | 1 |
| y | | | o | | |

| | |
|-----------|-----|
| A | 1-A |
| 0 | 1 |
| 1 | 0 |
| no | |

5.4.1.2. Reglas Difusas (if-then Rules) (Reglas Si-entonces)

Las reglas difusas son una colección de proposiciones lingüísticas que describen cómo el sistema de inferencia FIS debe funcionar, tomando en cuenta: cómo se debe clasificar una *entrada* y/o cómo se determinará una *salida*. La forma de escribir una regla difusa es la siguiente:

Si ($entrada_1$ **está dentro de la** *funcion de membresa₁*) **y/o** ($entrada_2$ **está dentro de la** *funcion de membresa₂*) **y/o** ... **entonces** ($salida_n$ **está dentro de la** *funcion de membresa_n*)

Por ejemplo:

Si (*la temperatura es alta*) **y** (*la humedad es alta*) **entonces** (*el cuarto está caliente*)

De esta manera, las reglas difusas permiten la “fuzzificación” de las *entradas*. Un esquema de este proceso se ejemplifica en la Figura 5.4.

5.4.1.3. Conjuntos Difusos (Fuzzy Sets)

Un conjunto difuso es un conjunto sin un límite concreto o bien definido. Este tipo de conjuntos puede contener elementos con solo un “grado de pertenencia” parcial. Mientras que en los conjuntos “concretos” (“crisp”), los elementos pertenecen al conjunto o no.

Generalmente se utiliza μ como el porcentaje de pertenencia en un conjuntos (ver Figura 5.5).

5.4.1.4. Funciones de Membresía (Membership Functions)

Una función de membresía (*MF*) es una curva que define cómo cada punto de un *Espacio de entrada* es mapeada a un valor de membresía (o grado de pertenencia) entre 0 y 1. El *Espacio de entrada* es, a veces, llamado “*Universe of Discourse*”. Si bien las funciones de membresía pueden ser representadas por funciones de probabilidad, estas se diferencian en dos aspectos principalmente:

1. El requerimiento mínimo para las funciones de probabilidad es la *aditividad* , es

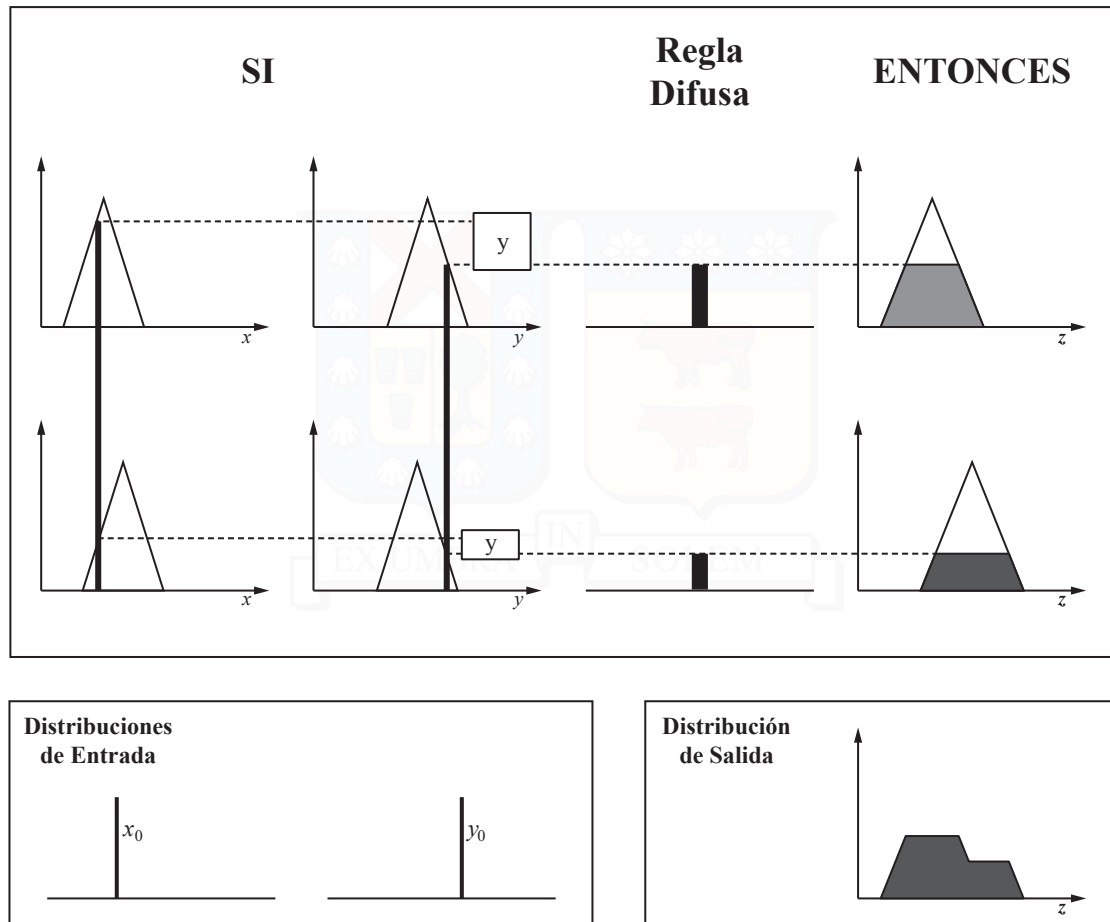


Figura 5.4: Esquema representativo de la “Fuzzificación” de las *entradas*.

Fuente: Elaboración Propia, Illustrator CC 2015.

decir, que la integral de la función de probabilidad sobre todo el dominio debe ser la unidad.

- Más importante, desde una perspectiva semántica, las proposiciones probabilísticas determinan que tan probable es que un evento suceda. De esta manera, un evento puede ocurrir o no. En contraste, con proposiciones difusas no es posible determinar si un evento ocurrió o no inequívocamente, en vez de lo anterior, modela hasta que punto un evento puede o no haber ocurrido.

Lo más importante de recordar, es que las funciones de membresía permiten la **clasificación** de las entradas, no calcular su probabilidad.

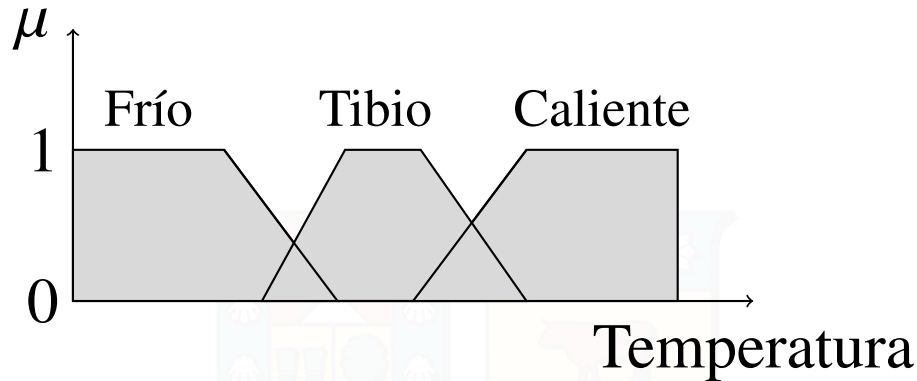


Figura 5.5: Esquema representativo de los Conjuntos Difusos.

Fuente: Elaboración Propia, TikZ.

5.4.2. FIS (Fuzzy Inference System) (Sistema de Inferencia Difusa)

Un sistema de inferencia difusa permite el mapeo de *entradas* a *salidas* mediante el uso de la lógica difusa y los elementos mencionados anteriormente. Los dos sistemas de inferencia difusa más utilizados son: Mamdani y Sugeno.

5.4.2.1. Mamdani

El sistema de inferencia propuesto por [Mamdani and Assilian \(1975\)](#) consta básicamente de 6 etapas:

1. Determinar un conjunto de reglas difusas.
2. “Fuzzificar” las *entradas* usando funciones de membresía.
3. Combinar las *entradas difusas* en concordancia con las reglas difusas para generar una regla difusa de salida.
4. Encontrar la conclusión de la regla difusa mediante la regla difusa de salida y la función de membresía de salida.
5. Combinar las conclusiones (agregar) para obtener una función de distribución de salida total.

6. “De-fuzzificar” la función de membresía de salida total⁹ (este paso se sigue solo si se necesita una *salida* explícita).

5.4.2.2. Sugeno

El sistema de inferencia propuesto por Sugeno (1985) es muy similar al expuesto en la Subsubsección 5.4.2.1. La diferencia recae en como se trabaja después de generar las reglas difusas (ver Subsección 5.4.1.2). En el sistema de inferencia Mamdani las funciones de membresía de salida pueden tomar cualquier distribución (dependiendo de las *salidas*). En contraste, las distribuciones de membresía de *salida* en el sistema Sugeno son ya bien lineales o constantes. De esta manera cada $salida_j = z_j$ (para un modelo bi-dimensional) queda determinada por:

Si $entrada_j = x_j$ operador $entrada_j = y_j$ entonces $salida_j = z_j$

Los pesos w_j están determinados por:

$$w_j = \text{operador}(MF_1(x_j), MF_2(y_j)) \quad (5.18)$$

De esta manera la *salida final* queda determinada por:

$$salida\ final = \frac{\sum_{j=1}^N w_j z_j}{\sum_{j=1}^N w_j} \quad (5.19)$$

Donde N es la cantidad de *entradas*.

5.4.3. Entrenamiento

La parte AN de ANFIS es la que, como se mencionó anteriormente, actualiza/optimiza los parámetros w_j en la fase de entrenamiento y chequeo. Los dos métodos de actualización/optimización de parámetros presentes en el paquete de Matlab (“Fuzzy Logic ToolboxTM”) son “Backpropagation” y “Hybrid¹⁰”.

⁹Si bien existen distintos métodos, uno de los más utilizados es el método del centro de masa.

¹⁰El algoritmo de optimización híbrido consiste en una mezcla entre “Backpropagation” (Descenso por Gradiente) y Mínimos Cuadrados Ordinarios Ordinarios.

5.5. Criterios de Selección de Modelos

Para el análisis de los Modelos ARIMA(p,d,q), GARCH(r,s) y en general, en la fase exploratoria será necesario utilizar algún criterio que permita determinar el desempeño de los modelos con el fin de elegir el(los) que tengan el(los) mejor(es) desempeños. Dentro de los más utilizados se encuentran el criterio AIC, BIC, C_p de Mallows, distintos coeficientes de Bayes, entre otros. Para esta investigación se utilizarán los criterio AIC y BIC (Schwarz Criterion) que son los dos métodos más usados en la selección de modelos (Fabozzi et al., 2014). Donde la diferencia fundamental de ambos índices es el cómo penalizan el número de parámetros estimados (Kadane and Lazar, 2004).

5.5.1. Criterio AIC (Akaike Information Criterion)

El criterio AIC fue propuesto por Akaike (1974) en su paper “A New Look at the Statistical Model Identification”. Este criterio busca minimizar el índice AIC, por tanto el modelo con menor AIC será el mejor. El índice AIC se calcula como:

$$AIC = -2\log(L) + 2k \quad (5.20)$$

Donde L es el máximo valor de la función de máxima verosimilitud de los estimadores (parámetros), y k el número de parámetros independientemente ajustados.

5.5.2. Criterio BIC o SC (Schwarz Criterion)

El criterio SC o más conocido como BIC fue propuesto por Schwarz (1978) en su paper “Estimating the Dimension of a Model”. Similar al criterio AIC, pero difiere en su cálculo, de la misma manera lo hace su interpretación y resultados para distintos tamaños de muestra. El indicador se calcula de la forma:

$$BIC = SC = -2\log(L) + k \cdot \log(n) \quad (5.21)$$

Donde L es el máximo valor de la función de máxima verosimilitud de los estimadores (parámetros), n el tamaño de muestra y k el número de parámetros independientemente ajustados.

5.5.3. Alcance y Eviews

Si bien los índices de los criterios AIC y BIC son, numéricamente (expuesto por los autores), los expuestos en las Subsecciones 5.5.1 5.5.2 respectivamente, Eviews 8¹¹ los calcula de la siguiente manera:

$$AIC = -2\log(L) + \frac{2k}{n} \quad (5.22)$$

$$BIC = SC = -2\log(L) + \frac{k \cdot \log(n)}{n} \quad (5.23)$$

5.6. Funciones de Pérdida

El fin de todo pronóstico es acercarse a la verdad, en este caso al dato que efectivamente se registro en un determinado tiempo t . Todo pronóstico, al ser una estimación del verdadero dato, genera una pérdida de información (dado que puede diferir de la verdad), es por eso el nombre de las funciones de pérdida, o **funciones de pérdida de información**. Estas funciones de pérdida buscan determinar el acumulado de información que se está perdiendo por el hecho de utilizar la predicción, pronóstico o estimador. En general, el objetivo es siempre intentar minimizar la pérdida de información, es decir, el que genere una menor pérdida de información será el mejor pronóstico. Dicho esto, para este trabajo se utilizarán algunos indicadores de error, los cuales permitirán comparar los métodos propuestos entre si y con respecto a los existentes. Estos indicadores serán el RMSE, MAPE, y sMAPE.

5.6.1. RMSE

Root Mean Squared Error, es un índice de error que se utiliza principalmente para determinar el error entre los valores observados y los valores que se obtienen a través de

¹¹EViews 8 User's Guide II. Pág. 15.

un pronóstico. Como se obtiene a través de la suma de observaciones como se muestra en (5.24), este indicador puede perder o alejarse del orden de magnitud de las mediciones, pudiendo llevar a errores de inferencia dada su dependencia de escala (Hyndman and Koehler, 2006). Se calcula mediante:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (5.24)$$

Donde y_t es el valor de la serie en el tiempo t , \hat{y}_t el valor estimado (pronóstico) de la serie en el tiempo t y n el tamaño de la muestra.

5.6.2. MAPE

Mean Absolute Percentage Error, es un indicador estadístico que permite medir la precisión de un pronóstico. En particular, este trabajo o investigación se centrará en el uso de esta función de pérdida, dada la justificación económica que significa disminuir este índice (ver Justificación 1.3.2). Se calcula como:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (5.25)$$

Donde y_t es el valor de la serie en el tiempo t , \hat{y}_t el valor estimado (pronóstico) de la serie en el tiempo t y n el tamaño de la muestra.

5.7. Prueba o Test de Significancia Estadística

En general, los resultados obtenidos a partir de los pronósticos pueden ser distintos unos de otros. Si bien a simple inspección y comparación pueden parecer distintos, estos pueden ser no significativamente distintos entre sí. Es por esto que es necesario aplicar alguna prueba o test de hipótesis que permita la **comparación estadística** de los errores, en particular de las funciones de pérdida entre los modelos de benchmark y el método propuesto.

Para este trabajo se utilizará el test generalizado de “t-Student” o el test t de Welch. Además de esta prueba, se realizará un análisis MCS (Model Confidence Set) con el fin de

determinar si el modelo propuesto posee una habilidad significativamente superior para pronosticar (SPA¹²).

5.7.1. Test t de Welch

El test t propuesto por Welch (1947) permite comparar las medias de dos poblaciones independientes con diferente varianza y tamaño de muestra. La hipótesis nula considera que la diferencia de las medias es nula (donde se utiliza una distribución de dos colas), es decir:

$$\Delta = \mu_1 - \mu_2 = 0 \quad (5.26)$$

Donde el estadístico t (5.27) sigue una distribución t-Student con ν (5.28) grados de libertad.

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{s_1^2}{N_1} + \frac{s_2^2}{N_2}}} \quad (5.27)$$

$$\nu \approx \frac{\left(\frac{s_1^2}{N_1} + \frac{s_2^2}{N_2}\right)^2}{\frac{s_1^4}{N_1^2 \nu_1} + \frac{s_2^4}{N_2^2 \nu_2}} \quad (5.28)$$

Donde \bar{X}_i es el promedio muestral, s_i la desviación estándar muestral, N_i el tamaño muestral y $\nu_i = N_i - 1$ corresponde a los grados de libertad asociados a la estimación de la varianza muestral i . El valor de ν se aproxima al valor entero más cercano.

5.7.2. Model Confidence Set

La prueba para determinar la habilidad superior de predicción (SPA) de un modelo diseñada por Hansen (2005) y actualizada por Hansen et al. (2011) será explicada brevemente a continuación.

La hipótesis nula (5.29) de esta prueba o test supone que el modelo un modelo en particular **no es inferior** a ninguna de las alternativas, es decir que el valor de la función de

¹²Superior Predictive Ability.

la pérdida de cada alternativa sea mayor que la del modelo propuesto.

$$H_0 = \boldsymbol{\mu} \leq \mathbf{0} \quad (5.29)$$

Donde $\boldsymbol{\mu} \in \mathbb{R}^m$ proviene de:

$$\boldsymbol{\mu} \equiv E(\mathbf{d}_t) \quad (5.30)$$

Donde $\mathbf{d}_t = (d_{1,t}, \dots, d_{m,t})'$ proviene de:

$$d_{k,t} \equiv L(\xi_t, \delta_{0,t-h}) - L(\xi_t, \delta_{k,t-h}), \quad k = 1, \dots, m. \quad (5.31)$$

Donde m es la cantidad de modelos alternativos, h la cantidad de periodos en adelante donde debe ser tomada una decisión, $\delta_{k,t-h}$ el conjunto de posibles reglas de decisión, ξ_t la variable de interés y L la función de pérdida asociada a ξ_t .

6 | Metodología

En el Capítulo 1 se estableció que el método de pronóstico que se ocupará para proponer predicciones para el consumo de energía eléctrica será ANFIS. Sin embargo, tras revisar el marco teórico, se determinó que la metodología a utilizar será la de un modelo híbrido, agregando propiedades de ARIMA en conjunto con ANFIS.

6.1. Estructura

Con respecto a la estructura de la metodología, esta será descompuesta en tres etapas o partes. La **primera parte** corresponderá al pronóstico con el método propuesto; la **segunda** será la generación de pronósticos de Benchmark para comparar y contrastar el modelo propuesto; por último, la **tercera parte** será realizar una prueba de significancia estadística sobre el error con el fin de determinar si el método propuesto entrega predicciones significativamente mejores.

6.1.1. Pronóstico del Modelo Propuesto

6.1.1.1. Análisis Exploratorio de la Base de Datos

En este análisis exploratorio de la base de datos se realizarán pruebas para determinar que coeficientes de $ARI(p, d)$ son los que entregan el menor AIC (Akaike Information Criterion) y/o SC (Schwarz Criterion) dependiendo de la naturaleza de los resultados. Una vez obtenidos los coeficientes o variables, estas pasarán a ser los datos o variables de entrada para el método ANFIS. El análisis exploratorio se realizará con ayuda del software *Eviews 8*. Con el fin de determinar si la serie de la base de datos corresponde a una serie

estacionaria se utilizará la prueba de Dickey-Fuller Aumentada.

6.1.1.2. Pronóstico de los datos

Una vez que se tenga los datos o variables de entrada pre procesados por los métodos $ARI(p, d)$ se procederá a realizar la búsqueda de la configuración óptima de ANFIS para los pronósticos sobre la serie de tiempo.

Todo lo correspondiente con los pronósticos y predicción de datos se realizará sobre el software *Matlab 2016a*. En particular, se utilizarán los últimos x^{13} datos pronosticados por el modelo dentro de la muestra para comparar con los benchmarks.

6.1.1.3. Cálculo del Error

Posteriormente, se calculará el **MAPE** para los distintos modelos propuestos por ANFIS en su variable **nivel** como índice de error. Este cálculo se llevará a cabo en el software *MS Excel 2013*.

6.1.2. Benchmark

6.1.2.1. Pronósticos

Con el fin de comparar los resultados obtenidos en la Subsubsección 6.1.1.2, se generarán otros 3 tipos de pronósticos (benchmarks) con los métodos ARIMA, GARCH y ANN. Donde los pronósticos con los dos primeros métodos ARIMA y GARCH¹⁴ serán obtenidos mediante el software *Eviews 8*, en cuanto el pronóstico mediante el método ANN se obtendrá con ayuda del software *MS Excel 2013*.

6.1.2.2. Cálculo del Error

Al igual que para los pronósticos con el método ANFIS, a los x^{15} pronósticos obtenidos con los métodos benchmark se calculará el MAPE para comparar con los pronósticos del

¹³Donde $x = 522 - p - d$ será la cantidad de datos que se determinará tras obtener el modelo $ARI(p, d)$.

¹⁴Para el modelo GARCH se utilizarán los parámetros óptimos (p, q) de modelo $ARMA(p, q)$ anterior.

¹⁵**Nota:** Si algún método o modelo pronosticara más de x datos, solo se tomará en cuenta para el benchmark los últimos x .

método propuesto. Para este cálculo se utilizará el software *Matlab 2016a*.

6.1.3. Prueba de Significancia

Si bien el método propuesto podría ser mejor o no que los métodos o modelos de benchmark en cuanto a los pronósticos ser más parecidos a los datos reales. Es necesario comprobar que el modelo propuesto es **significativamente** mejor o peor que los de benchmarking. Para esto se realizará el test t de Welch con el fin de determinar si los índices MAPE son significativamente distintos.

De manera adicional, se realizará un análisis MCS (Model Confidence Set) para indagar más en el desempeño de los modelos. Esta prueba o análisis busca determinar si el modelo propuesto posee una habilidad superior para pronosticar **significativamente** mejor que los demás modelos y/o métodos. Estas pruebas serán realizadas en el software *Matlab 2016a*.

7 | Procedimiento

7.1. Pronóstico del Modelo Propuesto

Cómo se habló en la Subsección 6.1.1, lo primero que se realizará será un análisis exploratorio de la serie de tiempo del consumo, desde ahora, y_t .

7.1.1. Análisis Exploratorio ARI(p,d)

Lo que se quiere lograr con este análisis exploratorio es determinar los rezagos de la serie de tiempo de tal manera que el modelo AR de tales rezagos sean los que entreguen el menor error, lo que se determinará con el índice AIC. Pero, dado que los coeficientes de los modelos AR se determinan mediante el método de Mínimos Cuadrados Ordinarios, primero es necesario determinar que la serie sea estacionaria, para evitar errores de inferencia (Granger and Newbold, 1974).

7.1.1.1. Análisis I(d)

Para determinar si la serie y_t es estacionaria en su nivel se realizará una prueba de Dickey-Fuller Aumentada (ADF test) en el software *Eviews 8*. Dado que la cantidad de rezagos quedará determinada por el modelo AR que posea menor AIC, por ahora solo colocarán 12 rezagos (rezagos), equivalente a un año, ver Figura 7.1.

Como se puede apreciar en la Figura B.1 el resultado de la prueba anterior arroja que el *valor-p* es mayor que 0.05, por lo tanto no se puede rechazar la hipótesis nula de que exista una raíz unitaria, por lo tanto la serie sería no estacionaria en su Nivel. Generalmente las series que no son estacionarias en su variable nivel si lo son en su primera diferencia, por

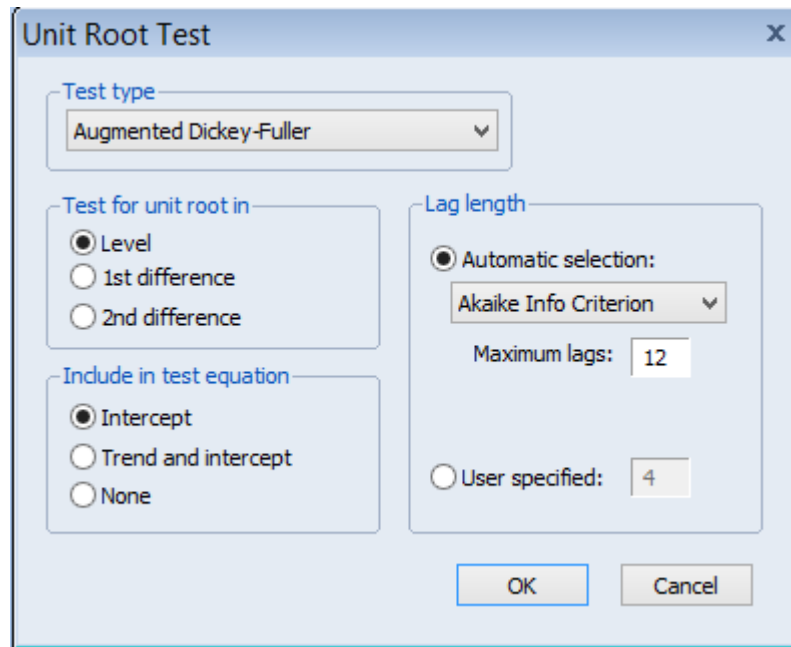


Figura 7.1: Prueba de Raíz Unitaria con prueba Dickey-Fuller Aumentada para Variable Nivel.
Fuente: Elaboración Propia, Eviews 8.

lo tanto se realizará la misma prueba pero para la primera diferencia de la serie, es decir:

$$\Delta y_t = y_t - y_{t-1} \quad (7.1)$$

Los resultados de la prueba Dickey-Fuller Aumentada para la variable en su primera diferencia (ver resultados en la Figura B.2) muestran un *valor-p* de 0, por lo que se rechaza la hipótesis nula, por tanto no existiría raíz unitaria, por ende la serie sería estacionaria en su primera diferencia. Es por esto que **desde ahora en adelante se utilizará la primera diferencia de la serie como la nueva serie**, desde ahora, z_t .

7.1.1.2. Análisis AR(p)

Al intentar determinar cuál es el modelo AR que mejor modela a la serie z_t se encuentra con la dificultad de que el criterio AIC sobre-ajusta el modelo señalando que a medida que se agregan rezagos el modelo mejora (ver Tabla B.1 con los resultados). Este comportamiento es una de las falencias de este criterio. Por tanto, se utilizará el criterio de Schwartz (SC) que tiene mejores resultados el criterio Akaike (AIC) que ajusta modelos con muchas variables

(Koehler and Murphree, 1988). Tras ocupar este criterio para los mismos modelos AR, se obtiene como resultado (ver Tabla B.1) que el modelo que tiene mejor desempeño según el criterio de Schwartz (SC) es el modelo AR(14). De esta manera, el modelo ARI(14,1) será entonces el modelo sobre el cual trabajará el modelo o método ANFIS.

7.1.2. Pronóstico con ANFIS

7.1.2.1. Preprocesamiento

Dada la sintaxis de de las funciones de ANFIS en Matlab y según el análisis exploratorio realizado en la Subsubsección 7.1.1.2, que indicaba un modelo AR(14), se separó la serie z_t ¹⁶ en *entrada* y *salida* según un modelo AR(14) como se muestra en el recuadro.

```

1 for t=16:522,
2     data2(t-15,:)=[ z(t-14) z(t-13) z(t-12) z(t-11) z(t-10) z(t-9)
3     z(t-8) z(t-7) z(t-6) z(t-5) z(t-4) z(t-3) z(t-2) z(t-1) ];
4     zout(t-15,:)=[ z(t) ];
5 end
6
7 train_data=datos(1:480,:);
8 check_data=datos(481:end,:);

```

Se dividió la data en entrenamiento y chequeo validación, para su tamaño se determinó aleatoriamente el tamaño de la data de entrenamiento sobre el 90 %, fijándose en 480 datos, quedando 41 datos para la validación o chequeo.

7.1.2.2. FIS Inicial

Los algoritmos híbrido y “backpropagation” son los que se utilizarán para la actualización/optimización de parámetros. Ambos algoritmos necesitan un valor de partida (inicial) para los pesos del sistema de inferencia. Es por esto que es necesario generar una FIS inicial a optimizar. El método para generar la FIS inicial será, en general, “Subtractive Clustering”

¹⁶La serie z_t contiene 521 datos, corresponden.

(Chiu, 1994) dadas sus ventajas de computación. Para proponer más de un solo modelo, se varió los valores de radio escalar desde 0,5 hasta 1 avanzando de 0,1.

7.1.2.3. Error

A cada modelo propuesto anteriormente se le calculó el MAPE, estos se pueden ver en la Tabla B.2. Dada la gran cantidad de términos se realizará una tabla glosario donde se sintetizarán los términos, ver Tabla 7.1.

Tabla 7.1: Glosario de Abreviaturas para MAPE de ANFIS.

| | |
|-------------------------------------|-------|
| ANFIS | anfis |
| Sustractive Clustering Radii | scr |
| Sugeno FIS | suge |
| Backpropagation Algorithm | back |
| Hybrid Algorithm | hyb |

Donde un pronóstico mediante ANFIS con un radio de agrupación (clustering) de 0,7 optimado mediante un algoritmo híbrido se abreviaría como:

anfis_scr07_suge_hyb

Se obtiene que el modelo con mínimo valor en su función de pérdida (MAPE) es el modelo **anfis_scr05_suge_hyb**. Por lo tanto el modelo $AR(14) - ANFIS$ con un radio escalar de 0.5 con parámetros optimizados mediante el algoritmo híbrido. Donde el MAPE para el modelo mencionado es 0,004773603.

7.2. Pronósticos de los Benchmarks

Como se dijo en la Subsubsección 6.1.2.1, para comparar el modelo propuesto se utilizarán algunos modelos como benchmark. Estos modelos serán individualmente los modelos $AR(p)$, $MA(q)$, $ARMA(p, q)$, $GARCH(r, s)$ y $AR(p) - ANN$.

Como ya se propuso anteriormente, para los benchmark se trabajará de igual manera, es decir, la serie sobre la cual trabajarán los pronósticos será z_t , en otras palabras, la primera diferencia de la serie original.

7.2.1. Benchmark AR(p)

Este modelo ya fue determinado en la Subsección 7.1.1, por lo tanto, no se repetirá el cálculo. El modelo con menor índice SC fue el modelo AR(14), por ende, será el modelo que se utilizará como benchmark AR(p).

7.2.2. Benchmark MA(q)

Para determinar el Modelo MA que mejor modela a la serie z_t , se utilizaron ambos criterios AIC y SC. Los resultados de las pruebas en *Eviews 8* se pueden ver en la Tabla B.3. Si bien, nuevamente el criterio AIC elige el modelo con la mayor cantidad de regresores (MA(23))¹⁷ no se descarta como opción dado que el criterio SC entrega una solución similar (MA(21)). Es por esto que ambos modelos MA(21) y MA(23) se utilizará como benchmark MA(q).

7.2.3. Benchmark ARMA(p,q)

Nuevamente el software *Eviews 8* fue utilizado para determinar cuál es el mejor modelo ARMA(p,q) según los criterios AIC y SC. Asimismo, dada la similitud del resultado de ambos criterios, se utilizarán ambos modelos como benchmark ARMA(p,q). Los resultados las pruebas con el criterio AIC (ver Tablas B.4 B.5 B.6) y el criterio SC (ver Tablas B.7 B.8 B.9) muestran que el mejor modelo según el criterio AIC es ARMA(14,15), mientras que el mejor modelo según el criterio SC es ARMA(12,12). Como se dijo anteriormente, ambos modelos se utilizarán como benchmark.

7.2.4. Benchmark GARCH(r,s)

Mediante el software *Eviews 8* y utilizando los parámetros óptimos (ver Subsección 7.2.1 7.2.3) para los modelos AR y ARMA se determinaron los siguientes modelos (ver Tabla 7.2), dada su similaridad, todos se utilizarán como benchmark.

¹⁷**Nota:** A diferencia del modelo AR, para este caso no se pudo obtener los valores AIC y SC para los modelos MA hasta MA(36). Sino que por limitaciones del software *Eviews 8*, solo se obtuvo hasta el modelo MA(23).

Tabla 7.2: Modelos GARCH(r,s) provenientes de los Modelos ARMA(p,q)..**Fuente:** Elaboración Propia.

| | | |
|-------------|---|------------------|
| AR(14) | { | AIC → GARCH(2,8) |
| | | SC → GARCH(2,3) |
| ARMA(12,12) | { | AIC → GARCH(2,5) |
| | | SC → GARCH(3,2) |
| ARMA(14,15) | { | AIC → GARCH(2,7) |
| | | SC → GARCH(2,4) |

Los resultados AIC y SC de lo expuesto en la Tabla 7.2, se pueden ver en los Anexos [B.10](#) [B.11](#) [B.12](#) [B.13](#) [B.14](#) [B.15](#).

7.2.5. Benchmark ANN

Para determinar los modelos benchmark por medio de Redes Neuronales se utilizó el paquete “Neural Network Toolbox™” de *Matlab2016a*, en particular la funcionalidad para trabajar con series de tiempo.

Como se mencionó anteriormente, de manera de generar un benchmark que pueda competir con el generado por el modelo ANFIS, al modelo por ANN también se le dará como entrada el modelo $AR(14)$. Los modelos se generaron por medio de la función NAR (Non-linear Autoregressive) y se sensibilizó para distintas configuraciones de ratios *entrenamiento/validación/prueba* y distinto número de neuronas escondidas (capas escondidas, ver Subsubsección [5.3.2.1](#)).

7.2.6. Error

A cada modelo determinado en las Subsecciones anteriores se le calculó el MAPE, estos se pueden ver en la Tabla [B.16](#). También, como para el caso de los pronósticos de ANFIS, se generará una tabla glosario con las abreviaturas que se utilizarán para tabular

Tabla 7.3: Glosario de Abreviaturas para MAPE de Benchmarks.

| | |
|--------------------------------------|-------------|
| AR(p) | ar_p |
| ARMA(p,q) | arma_p_q |
| MA(q) | ma_q |
| GARCH(r,s) | garch_r_s |
| ANN | ann |
| Neuronas Escondidas (capas) | hn |
| Entramiento_validación_prueba | ratio_a_b_c |

los valores de MAPE. Estas abreviaturas estarán expuestas en la Tabla 7.3.

Se obtiene que el modelo con mínimo valor en su función de pérdida (MAPE) es el modelo **ann_hn20_ratio_80_15_5**. Por lo tanto el modelo $AR(14)$ – ANN con 20 capas escondidas y un ratio 80:15:5 para los datos de entrenamiento, validación y prueba, respectivamente. Donde el MAPE del modelo mencionado es 0,015001552.

7.3. Pruebas Estadísticas

Con el fin de determinar si los valores obtenidos tienen relevancia estadística se realizarán las siguientes pruebas.

7.3.1. Test t de Welch

Los resultados de MAPE obtenidos anteriormente muestran que el valor de MAPE para el mejor modelo propuesto es menor que el de el mejor modelo benchmark. Si bien un MAPE es menor que el otro, lo es en promedio, pero puede que la diferencia entre ambos valores no sea significativa desde un punto de vista estadístico.

Con el fin de determinar la significancia estadística de la diferencia de los MAPE se realizó una prueba t de Welch cruzada (todos con todos), donde los p-valores de la prueba se muestran en la Tabla B.17 B.18 B.19.

De las tablas anteriormente mencionadas puede extraerse que la diferencia entre el MAPE del mejor modelo propuesto y el mejor modelo benchmark **es significativa**, por lo que se podría afirmar que el mejor modelo propuesto genera significativamente menos

error que el mejor modelo benchmark.

7.3.2. Análisis MCS

Si bien el mejor modelo propuesto puede generar menor error que el mejor modelo benchmark, puede que este no tenga una habilidad superior de predicción significativa, que es lo que busca un modelo de pronóstico.

Con el fin de determinar si el modelo propuesto también tiene o no una habilidad superior de predicción se realizó una prueba de Model Confidence Set, donde se tomó 1000 veces un conjunto (iteró 1000 veces) de 12 datos (correspondientes a un año) evaluándose conjunto a conjunto con un 5 % de significancia como parámetro de corte.

Tras analizar los resultados de la prueba MCS (ver Tabla B.20) se puede ver que el mejor modelo propuesto es el único que no es significativo (mediante ambos estadísticos), por lo tanto no se puede rechazar la hipótesis nula (ver Hipótesis (5.29)), por lo que el modelo propuesto no sería inferior a ninguna de las alternativas, por ende tendría una habilidad superior de predicción (SPA) significativa por sobre los demás modelos.

8 | Análisis de los Resultados

Hasta el momento solo se ha hablado de lo concerniente al modelo ANFIS propuesto, este Capítulo tratará de indagar en los resultados con el fin de obtener conclusiones y/o información relevante que se haya podido pasar por alto en los capítulos anteriores.

8.1. Modelos Convencionales

Mientras se obtuvieron los resultados de la función de pérdida para los modelos AR, MA, ARMA y GARCH se pudo encontrar ciertos aspectos relevantes. Sin ir más lejos al mirar las Tablas [B.17](#) [B.18](#) [B.19](#) con los p-valores de la prueba t de Welch es posible inferir que los valores de MAPE para los modelos GARCH provenientes de cada correspondiente modelo AR o ARMA no son significativamente distintos. Esto ocurre para los 6 modelos GARCH (ver Tabla [7.2](#)), donde los 6 p-valores son no significativos.

La razón por la cual la situación anterior puede ocurrir es que la serie z_t sea homoscedástica, por lo que al agregar los términos GARCH y ARCH el modelamiento no mejora, dado que los modelos G(ARCH) modelan de mejor manera series heteroscedásticas.

8.2. Modelo ANFIS

En promedio los valores de la función de pérdida MAPE para los pronósticos mediante el método ANFIS, son mayores para los pronósticos cuyos pesos fueron optimizados mediante el algoritmo “backpropagation” (ver Tabla [B.2](#)).

Con respecto a los pronósticos generados por ANFIS, estos por separado generan menos error o pérdida de información, en términos medios (MAPE), que cualquiera de los métodos

de pronósticos benchmark. Al corroborar las diferencias entre las funciones de pérdida por medio de la prueba t de Welch, se encuentra que el único MAPE que no es significativamente (al 5 % de significancia) distinto es el del modelo **anfis_scr10_suge_back** con el modelo **ann_hn20_ratio_80_15_5**. Con el fin de indagar en este caso particular, se realizó una prueba MCS, donde se muestra (ver Tabla B.21) que el modelo **anfis_scr10_suge_back** posee una habilidad superior de predicción significa por sobre cualquier método benchmark.

8.2.1. Pronóstico de Julio 2016-2017

Al intentar generar un pronóstico desde Julio de 2016 hasta Diciembre de 2017 mediante el modelo **anfis_scr05_suge_hyb**, el modelo arroja los siguientes resultados (ver Tabla 8.1). Para de la generación de los pronósticos se utilizó un algoritmo propuesto detallado en el Anexo D.2. Al pronosticar el 9^{no} dato, el modelo arroja un valor no permitido. Es más, los valores en general, para el Año 2017 parecen inverosímiles al contrastar con la data pasada.

Tabla 8.1: Pronóstico de Consumo Energético Para Julio 2016-2017 mediante **anfis_scr05_suge_hyb**.

| Año 2016 | | Año 2017 | |
|------------|-------------|------------|--------------|
| Enero | 9.102587 | Enero | 5.972010256 |
| Febrero | 8.247054 | Febrero | 3.310282008 |
| Marzo | 7.985055 | Marzo | -20.69112614 |
| Abril | 7.460904 | Abril | |
| Mayo | 7.598107 | Mayo | |
| Junio | 7.970408 | Junio | |
| Julio | 8.688934888 | Julio | |
| Agosto | 7.599147889 | Agosto | |
| Septiembre | 7.387201933 | Septiembre | |
| Octubre | 8.865085461 | Octubre | |
| Noviembre | 9.276049991 | Noviembre | |
| Diciembre | 10.0388507 | Diciembre | |

Si se considera la Tabla B.2 ordenada por los MAPE de manera creciente, el primer modelo que logra pronosticar el año 2017 completo más los 6 meses faltantes del 2016 es el modelo **anfis_scr06_suge_hyb**. Donde el pronóstico se puede ver en la Tabla 8.2. Donde se utilizó el mismo algoritmo detallado en el Anexo D.2.

Tabla 8.2: Pronóstico de Consumo Energético Para Julio 2016-2017 mediante modelo **anfis_scr06_suge_hyb**.

| Año 2016 | | Año 2017 | |
|------------|-------------|------------|-------------|
| Enero | 9.102587 | Enero | 8.119330245 |
| Febrero | 8.247054 | Febrero | 7.052715442 |
| Marzo | 7.985055 | Marzo | 8.230496164 |
| Abril | 7.460904 | Abril | 7.060141304 |
| Mayo | 7.598107 | Mayo | 8.142232138 |
| Junio | 7.970408 | Junio | 8.288807105 |
| Julio | 8.505602853 | Julio | 8.447880858 |
| Agosto | 7.831097651 | Agosto | 8.141368218 |
| Septiembre | 7.202683622 | Septiembre | 7.008142353 |
| Octubre | 7.97753461 | Octubre | 7.947173997 |
| Noviembre | 8.18557135 | Noviembre | 8.115568421 |
| Diciembre | 9.065923693 | Diciembre | 9.163887696 |

Lo anterior puede sugerir dos cosas, la primera es que existe algún tipo de sobreajuste en el modelo **anfis_scr05_suge_hyb**. La segunda es que, dado que es lo único que se varió en ambos modelos, el modelo es muy sensible a cambios en el radio escalar. La segunda opción tiende a ser lo que se podría inferir, dado el modelo **anfis_scr05_suge_hyb** si permite pronosticar valores fuera de la muestra. La opción de que el modelo es muy sensible al cambio en el radio escalar, se puede corroborar dado que al aumentar solo a 0,6¹⁸ este valor el modelo **anfis_scr06_suge_hyb** permite generar los 18 pronósticos fuera de la muestra hasta Diciembre de 2017. Cabe mencionar que todos los modelos con mayor radio escalar que 0,6 también permiten el pronóstico.

8.2.2. Modelo **anfis_scr06_suge_hyb**

Dado que el modelo **anfis_scr05_suge_hyb** no permite el correcto pronóstico de los valores de consumo de 2017, este método se descartará y por tanto se realizará una prueba MCS para determinar si el método posee una habilidad superiora de predicción significativamente mayor que la del resto de los modelos¹⁹.

¹⁸Cabe recalcar que el modelo **anfis_scr05_suge_back** tampoco permite generar el pronóstico de los 18 valores futuros.

¹⁹No se tomarán en cuenta los modelos ANFIS con radio escalar 0,5.

Como se puede observar en la Tabla B.22, el modelo **anfis_scr06_suge_hyb** tendría una habilidad superior de predicción significativa según uno de los estadísticos (método R), pero no sería el único mejor (método SQ) al 5 % de significancia, pero si lo sería al 7 %. Sin embargo, como lo que se busca es generar un modelo que genere mejores resultados que los métodos o modelos benchmark, este método será el que se utilizará y/o hablará de ahora en adelante.

8.2.2.1. Análisis de sensibilidad MAPE

Como anteriormente se mencionó, el número de datos de entrenamiento fue fijado en 480 datos para todos los modelos ANFIS. Con el fin de demostrar la variación del valor en la función de pérdida al variar este número se generará una tabla (ver Tabla 8.3) en donde se variará en porcentaje la base de entrenamiento para determinar cambios en la función de pérdida MAPE.

Tabla 8.3: Variación del MAPE al variar % de Datos para Entrenamiento para el modelo **anfis_scr06_suge_hyb**.

Fuente: Elaboración Propia, MS Excel 2013.

| anfis_scr06_suge_hyb | MAPE | % de Datos para Entrenamiento |
|-----------------------------|-------------|--------------------------------------|
| | 0.017992681 | 50 % (260 datos) |
| | 0.015663851 | 60 % (313 datos) |
| | 0.014719555 | 70 % (365 datos) |
| | 0.013470398 | 80 % (417 datos) |
| | 0.013138946 | 90 % (468 datos) |
| | 0.012286328 | 92.13 % (480 datos) |
| | 0.012188956 | 95 % (495 datos) |

Luego de ver la tabla 8.3 se procede a realizar una prueba *t* de Welch con el fin de dilucidar si las diferencias en los MAPE son significativas ante un cambio en el porcentaje de datos totales que se utilizan como entrenamiento de la FIS. Los resultados se pueden visualizar en la Tabla B.23, estos sugieren que solo existen diferencias significativas en los MAPE cuando se varía el porcentaje de datos de entrenamiento por de bajo de un 80 %. Con esto se concluye mientras la variación de el porcentaje de datos de entrenamiento no baje del 80 % no se obtendrán MAPES significativamente distintos.

9 | Conclusiones

Cualquier modelo generado por ANFIS produce, en promedio, menor error según la función de pérdida (MAPE) que cualquiera de los métodos benchmark. Más aún, el peor modelo generado por ANFIS (**anfis_scr10_suge_back**) desde el punto de vista de la función de pérdida MAPE, posee una habilidad significativamente superior que cualquiera de los métodos benchmark.

El modelo **anfis_scr06_suge_hyb** obtiene un valor significativamente menor en la función de pérdida que cualquiera de los modelos o métodos benchmark. De la misma manera, el modelo anteriormente mencionado posee una habilidad superior de predicción significativa que cualquiera de los modelos o métodos benchmark.

En promedio (MAPE) el algoritmo de optimización o actualización de los parámetros que genera mejores resultados es el algoritmo “Híbrido” que es una combinación de el método de los Mínimos Cuadrados Ordinarios y “Backpropagation”.

El radio escalar para la Clasificación Sustractiva afecta directamente al valor de de la función de pérdida MAPE. Asimismo, mientras menor sea el radio el modelo producido es más rígido ante variaciones provocando resultados incongruentes y/o inverosímiles contrastados con la realidad.

Como se dijo anteriormente en el Análisis de Sensibilidad 8.2.2.1, no existiría un ratio óptimo significativo entre la data de entrenamiento y de chequeo. Lo anterior de acuerdo a la diferencia no significativa en el valor de la función de pérdida MAPE.

Por último, se puede concluir que es favorable el uso del método o modelo ANFIS, dado que al cambiar **desde** el modelo ANN o AR (donde AR es el que actualmente se utiliza por la oficina EIA) hacia el modelo **anfis_scr05_suge_hyb** puede significar una disminución **en promedio** de 1,02 % a 1,5 % en el MAPE (ver Tablas [B.2 B.16](#)), respectivamente. Incluso para si se cambiase hacia el modelo **anfis_scr06_suge_hyb** se disminuiría **en promedio** de 0,27 % a 0,79 % el MAPE (ver Tablas [B.2 B.16](#)), respectivamente. Más aún, es aconsejable el uso del método ANFIS dado que con los resultados se puede generar un ahorro en costos en $(x\%/1\%) \cdot \$500,000 \text{ USD}$ dependiendo del método a utilizar, como fue expuesto en la Justificación [1.3.2](#) de este trabajo.

Bibliografía

- Akaike, H. (1974). A New Look at the Statistical Model Identification. *Automatic Control, IEEE Transactions on*, 19(6):716–723.
- Amjady, N. and Keynia, F. (2009). Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm. *Energy*, 34(1):46–57.
- Bahrani, S., Hooshmand, R.-A., and Parastegari, M. (2014). Short term electric load forecasting by wavelet transform and grey model improved by PSO (particle swarm optimization) algorithm. *Energy*, 72(2014):434–442.
- Barak, S. and Sadegh, S. S. (2016). Forecasting energy consumption using ensemble ARIMA–ANFIS hybrid algorithm. *International Journal of Electrical Power & Energy Systems*, 82:92–104.
- Bashir, Z. A. and El-Hawary, M. E. (2009). Applying wavelets to short-term load forecasting using PSO-based neural networks. *IEEE Transactions on Power Systems*, 24(1):20–27.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3):307–327.
- Box, G. and Jenkins, G. (1970). *Time Series Analysis: Forecasting and Control*. Holden-Day series in time series analysis. Holden-Day.
- Box, G. E. P., Jenkins, G. M., and Reinsel, G. C. (2008). *Time Series Analysis: Forecasting and Control*. John Wiley & Sons, Inc., 4th edition.
- Chiu, S. L. (1994). Fuzzy Model Identification Based on Cluster Estimation. *Journal of Intelligent and Fuzzy Systems*, 2(3):267–278.
- Cristian, V., Iosif, S., Ioan, F., and Gabriela, P. (2007). Short Term Electric Load Forecast with Artificial Neural Networks. *IFAC Proceedings Volumes*, 40(18):443–449.
- Dickey, D. A. and Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*, 74(366):427–431.
- EIA (2015). Short-Term Energy Outlook Model Documentation : Retail Electricity Sales Model. Technical report, U.S. Energy Information Administration.

- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4):987–1007.
- EPSA (2016a). How Is Electricity Sold At Retail?
- EPSA (2016b). What is a Wholesale Electricity Market? *Electric Power Supply Association*.
- Fabozzi, F. J., Focardi, S. M., Rachev, S. T., Arshanapalli, B. G., and David, R. (2014). *The Basics of Financial Econometrics: Tools, Concepts, and Asset Management Applications*.
- Gavin, H. P. (2016). *The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems*. PhD thesis, Duke University.
- González-Romera, E., Jaramillo-Morán, M., and Carmona-Fernández, D. (2008). Monthly electric energy demand forecasting with neural networks and Fourier series. *Energy Conversion and Management*, 49(11):3135–3142.
- Gooijer, J. G. D., Abraham, B., Gould, A., and Robinson, L. (1985). Methods for Determining the Order of an Autoregressive-Moving Average Process: A Survey. *International Statistical Review*, 53(3):301–329.
- Granger, C. W. J. and Newbold, P. (1974). Spurious Regressions in Econometrics. *Journal of Econometrics* 2, 2:111–120.
- Grolinger, K., L’Heureux, A., Capretz, M. A. M., and Seewald, L. (2016). Energy forecasting for event venues: Big data and prediction accuracy. *Energy and Buildings*, 112:222–233.
- Hannan, E. J. and Quinn, B. G. (1979). The Determination of the Order of an Autoregression. *Journal of the Royal Statistical Society. Series B (Methodological)*, 41(2):190–195.
- Hansen, P. R. (2005). A Test for Superior Predictive Ability. *Journal of Business & Economic Statistics*, 23(24):365–380.
- Hansen, P. R., Lunde, A., and Nason, J. M. (2011). The Model Confidence Set. *Econometrica*, 79(2):453–497.
- Hassan, S., Khosravi, A., and Jaafar, J. (2015). Examining performance of aggregation algorithms for neural network-based electricity demand forecasting. *International Journal of Electrical Power and Energy Systems*, 64:1098–1105.
- Hong, T. (2015). Crystal Ball Lessons in Predictive Analytics.
- Hong, W. C. (2009). Electric load forecasting by support vector model. *Applied Mathematical Modelling*, 33(5):2444–2454.
- Hong, W. C., Dong, Y., Zhang, W. Y., Chen, L. Y., and K. Panigrahi, B. (2013). Cyclic electric load forecasting by seasonal SVR with chaotic genetic algorithm. *International Journal of Electrical Power and Energy Systems*, 44(1):604–614.

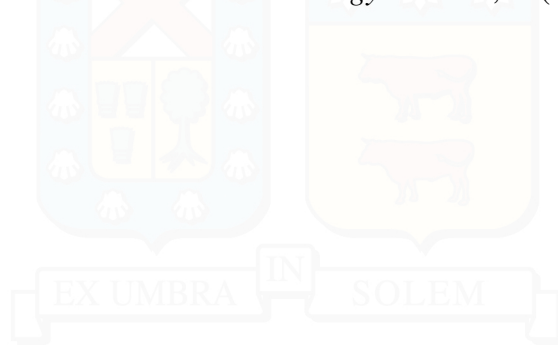
- Hyndman, R. J. and Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4):679–688.
- Jang, J. S. R. (1993). ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transactions on Systems, Man and Cybernetics*, 23(3):665–685.
- Kacprzyk, J. and Pedrycz, W. (2015). *Springer Handbook of Computational Intelligence*. Springer Dordrecht Heidelberg London New York.
- Kadane, J. B. and Lazar, N. A. (2004). Methods and Criteria for Model Selection. *Journal of the American Statistical Association*, Vol. 99(No. 465):279–290.
- Kavousi-Fard, A., Samet, H., and Marzbani, F. (2014). A new hybrid Modified Firefly Algorithm and Support Vector Regression model for accurate Short Term Load Forecasting. *Expert Systems with Applications*, 41(13):6047–6056.
- Kialashaki, A. (2014). *Evaluation and Forecast of Energy Consumption in Different Sectors of the United States Using Artificial Neural Networks*. PhD thesis, University of Wisconsin Milwaukee.
- Koehler, A. B. and Murphree, E. S. (1988). A Comparison of the Akaike and Schwarz Criteria for Selecting Model Order. *Applied Statistics*, 37(2):187–195.
- Lee, C. M. and Ko, C. N. (2011). Short-term load forecasting using lifting scheme and ARIMA models. *Expert Systems with Applications*, 38(5):5902–5911.
- Levenberg, K. (1944). A method for the solution of certain non-linear problems in least squares. *Quarterly of Applied Mathematics*, 2(2):164–168.
- Mamdani, E. and Assilian, S. (1975). An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. *International Journal of Man-Machine Studies*, 7(1):1–13.
- Marquardt, D. W. (1963). An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11(2):431–441.
- Maté, A., Peral, J., Ferrández, A., Gil, D., and Trujillo, J. (2016). A hybrid integrated architecture for energy consumption prediction. *Future Generation Computer Systems*.
- Nie, H., Liu, G., Liu, X., and Wang, Y. (2011). Hybrid of ARIMA and SVMs for short-term load forecasting. *Energy Procedia*, 16(PART C):1455–1460.
- Pandey, A. S., Singh, D., and Sinha, S. K. (2010). Intelligent hybrid wavelet models for short-term load forecasting. *IEEE Transactions on Power Systems*, 25(3):1266–1273.
- PJM Learning Center (2016). Market for Electricity.
- Raza, M. Q. and Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50:1352–1372.

- Rojas, I., Valenzuela, O., Rojas, F., Guillen, A., Herrera, L., Pomares, H., Marquez, L., and Pasadas, M. (2008). Soft-computing techniques and ARMA model for time series prediction. *Neurocomputing*, 71(4-6):519–537.
- Said, S. and Dickey, D. a. (1984). Testing for unit roots in autoregressive moving-average models of unknown order. *Biometrika*, 71(3):599–607.
- Salcedo-Sanz, S., Muñoz-Bulnes, J., Portilla-Figueras, J., and Del Ser, J. (2015). One-year-ahead energy demand estimation from macroeconomic variables using computational intelligence algorithms. *Energy Conversion and Management*, 99:62–71.
- Schwarz, G. (1978). Estimating the Dimension of a Model. *The Annals of Statistics*, 6(2):461–464.
- Selakov, A., Cvijetinović, D., Milović, L., Mellon, S., and Bekut, D. (2014). Hybrid PSO-SVM method for short-term load forecasting during periods with significant temperature variations in city of Burbank. *Applied Soft Computing Journal*, 16:80–88.
- Shahidehpour, M., Yamin, H., and Li, Z. (2002). *Market Operations in Electric Power Systems : Forecasting, Scheduling, and Risk Management*, volume 9. John Wiley & Sons, Inc.
- Sugeno, M. (1985). *Industrial Applications of Fuzzy Control*. Elsevier Science Inc., New York, NY, USA.
- Tran, V. G., Debusschere, V., and Bacha, S. (2012). One week hourly electricity load forecasting using Neuro-Fuzzy and Seasonal ARIMA models. *IFAC Proceedings Volumes*, 45(21):97–102.
- Ventosa, M., Baíllo, Á. ., Ramos, A., and Rivier, M. (2005). Electricity market modeling trends. *Energy Policy*, 33(7):897–913.
- Welch, B. L. (1947). The Generalization of 'Student's' Problem When Several Different Population Variances Are Involved. *Biometrika*, 34(2):28–35.
- Weron, R. (2006). *Modeling and forecasting electricity loads and prices : a statistical approach*. JohnWiley & Sons Ltd.
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4):1030–1081.
- Whittle, P. (1951). *Hypothesis Testing in Time Series Analysis*. Statistics Upsala. Almqvist & Wiksells.
- Xiao, L., Shao, W., Liang, T., and Wang, C. (2016). A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting. *Applied Energy*, 167:135–153.
- Yang, Y., Che, J., Li, Y., Zhao, Y., and Zhu, S. (2016). An incremental electric load forecasting model based on support vector regression. *Energy*, 113:796–808.

Yun, Z., Quan, Z., Caixin, S., Shaolan, L., Yuming, L., and Yang, S. (2008). RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment. *IEEE Transactions on Power Systems*, 23(3):853–858.

Zadeh, L. (1965). Fuzzy Sets. *Information and Control*, 8:338–353.

Zhao, H.-x. and Magoulès, F. (2012). A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6):3586–3592.



A | Base de Datos

Tabla A.1: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1973-1975.

Fuente: Energy Information Administration (EIA).

| Año 1973 | | Año 1974 | | Año 1975 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 7.226265 | Enero | 6.906707 | Enero | 7.059014 |
| Febrero | 6.594709 | Febrero | 6.316938 | Febrero | 6.171542 |
| Marzo | 6.524198 | Marzo | 6.373851 | Marzo | 6.386257 |
| Abril | 5.944336 | Abril | 5.863745 | Abril | 5.800645 |
| Mayo | 6.074551 | Mayo | 5.867145 | Mayo | 5.494457 |
| Junio | 5.805318 | Junio | 5.644753 | Junio | 5.438115 |
| Julio | 5.954498 | Julio | 5.988038 | Julio | 5.671861 |
| Agosto | 6.194365 | Agosto | 6.018263 | Agosto | 5.747213 |
| Septiembre | 5.776048 | Septiembre | 5.713814 | Septiembre | 5.501291 |
| Octubre | 6.177455 | Octubre | 6.18496 | Octubre | 5.91174 |
| Noviembre | 6.521876 | Noviembre | 6.238457 | Noviembre | 5.853242 |
| Diciembre | 6.889701 | Diciembre | 6.84556 | Diciembre | 6.929591 |

Tabla A.2: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1976-1978.
Fuente: Energy Information Administration (EIA).

| Año 1976 | | Año 1977 | | Año 1978 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 7.315131 | Enero | 7.855623 | Enero | 7.724961 |
| Febrero | 6.396086 | Febrero | 6.657899 | Febrero | 7.055634 |
| Marzo | 6.39482 | Marzo | 6.57761 | Marzo | 6.969369 |
| Abril | 5.858227 | Abril | 5.983088 | Abril | 6.173557 |
| Mayo | 5.796389 | Mayo | 6.000884 | Mayo | 6.341706 |
| Junio | 5.827441 | Junio | 6.089198 | Junio | 6.152956 |
| Julio | 6.027641 | Julio | 6.199376 | Julio | 6.343727 |
| Agosto | 5.973736 | Agosto | 6.30407 | Agosto | 6.499555 |
| Septiembre | 5.742648 | Septiembre | 6.083524 | Septiembre | 6.091208 |
| Octubre | 6.24777 | Octubre | 6.276021 | Octubre | 6.428593 |
| Noviembre | 6.732906 | Noviembre | 6.488691 | Noviembre | 6.689161 |
| Diciembre | 7.661524 | Diciembre | 7.445772 | Diciembre | 7.479492 |

Tabla A.3: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1979-1981.
Fuente: Energy Information Administration (EIA).

| Año 1979 | | Año 1980 | | Año 1981 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 8.09605 | Enero | 7.569338 | Enero | 7.643376 |
| Febrero | 7.413492 | Febrero | 7.127106 | Febrero | 6.488579 |
| Marzo | 7.155015 | Marzo | 7.025383 | Marzo | 6.610567 |
| Abril | 6.291051 | Abril | 6.162598 | Abril | 5.879369 |
| Mayo | 6.351355 | Mayo | 6.011371 | Mayo | 5.943749 |
| Junio | 6.146792 | Junio | 5.875872 | Junio | 5.999608 |
| Julio | 6.280572 | Julio | 6.138724 | Julio | 6.212381 |
| Agosto | 6.496817 | Agosto | 6.066541 | Agosto | 6.116564 |
| Septiembre | 6.056294 | Septiembre | 5.974226 | Septiembre | 5.824826 |
| Octubre | 6.546994 | Octubre | 6.32064 | Octubre | 6.147633 |
| Noviembre | 6.682793 | Noviembre | 6.424042 | Noviembre | 6.142499 |
| Diciembre | 7.341604 | Diciembre | 7.367613 | Diciembre | 7.092463 |

Tabla A.4: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1982-1984.
Fuente: Energy Information Administration (EIA).

| Año 1982 | | Año 1983 | | Año 1984 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 7.452645 | Enero | 6.912467 | Enero | 7.659216 |
| Febrero | 6.475473 | Febrero | 6.069952 | Febrero | 6.628326 |
| Marzo | 6.548462 | Marzo | 6.436333 | Marzo | 6.863942 |
| Abril | 6.044908 | Abril | 5.873836 | Abril | 6.275386 |
| Mayo | 5.607074 | Mayo | 5.697525 | Mayo | 6.17619 |
| Junio | 5.577011 | Junio | 5.682518 | Junio | 6.03141 |
| Julio | 5.840514 | Julio | 5.946682 | Julio | 6.160819 |
| Agosto | 5.822744 | Agosto | 6.133137 | Agosto | 6.328067 |
| Septiembre | 5.553562 | Septiembre | 5.704341 | Septiembre | 5.766025 |
| Octubre | 5.730544 | Octubre | 5.70557 | Octubre | 5.965862 |
| Noviembre | 5.98305 | Noviembre | 5.940081 | Noviembre | 6.104652 |
| Diciembre | 6.463441 | Diciembre | 6.868125 | Diciembre | 6.67181 |

Tabla A.5: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1985-1987.
Fuente: Energy Information Administration (EIA).

| Año 1985 | | Año 1986 | | Año 1987 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 7.382202 | Enero | 7.399658 | Enero | 7.47645 |
| Febrero | 6.884675 | Febrero | 6.624247 | Febrero | 6.732162 |
| Marzo | 6.582706 | Marzo | 6.78017 | Marzo | 6.770707 |
| Abril | 6.110942 | Abril | 6.113781 | Abril | 6.317775 |
| Mayo | 6.01009 | Mayo | 6.103287 | Mayo | 6.203087 |
| Junio | 5.885315 | Junio | 6.019767 | Junio | 6.283858 |
| Julio | 6.191778 | Julio | 6.358024 | Julio | 6.630484 |
| Agosto | 6.2622 | Agosto | 6.227713 | Agosto | 6.518294 |
| Septiembre | 5.763682 | Septiembre | 5.822464 | Septiembre | 6.127542 |
| Octubre | 6.031312 | Octubre | 6.043899 | Octubre | 6.366409 |
| Noviembre | 6.06341 | Noviembre | 6.122967 | Noviembre | 6.346123 |
| Diciembre | 7.224067 | Diciembre | 7.031035 | Diciembre | 7.281541 |

Tabla A.6: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1988-1990.
Fuente: Energy Information Administration (EIA).

| Año 1988 | | Año 1989 | | Año 1990 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 7.804136 | Enero | 7.643431 | Enero | 7.812958 |
| Febrero | 7.311849 | Febrero | 7.233512 | Febrero | 7.007053 |
| Marzo | 7.300926 | Marzo | 7.545718 | Marzo | 7.309415 |
| Abril | 6.453888 | Abril | 6.664237 | Abril | 6.771444 |
| Mayo | 6.394683 | Mayo | 6.63915 | Mayo | 6.750373 |
| Junio | 6.511855 | Junio | 6.697367 | Junio | 6.759787 |
| Julio | 6.750241 | Julio | 6.85966 | Julio | 7.036435 |
| Agosto | 6.992534 | Agosto | 7.031494 | Agosto | 7.283519 |
| Septiembre | 6.344903 | Septiembre | 6.48453 | Septiembre | 6.618025 |
| Octubre | 6.591078 | Octubre | 6.794011 | Octubre | 6.812378 |
| Noviembre | 6.70819 | Noviembre | 6.943551 | Noviembre | 6.776411 |
| Diciembre | 7.544911 | Diciembre | 8.24871 | Diciembre | 7.546608 |

Tabla A.7: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1991-1993.
Fuente: Energy Information Administration (EIA).

| Año 1991 | | Año 1992 | | Año 1993 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 8.078663 | Enero | 7.988958 | Enero | 7.915534 |
| Febrero | 6.866744 | Febrero | 7.247711 | Febrero | 7.427581 |
| Marzo | 7.144072 | Marzo | 7.35359 | Marzo | 7.820025 |
| Abril | 6.540738 | Abril | 6.846012 | Abril | 6.910829 |
| Mayo | 6.659218 | Mayo | 6.702407 | Mayo | 6.654008 |
| Junio | 6.702525 | Junio | 6.719338 | Junio | 6.850787 |
| Julio | 7.102862 | Julio | 7.164266 | Julio | 7.316669 |
| Agosto | 7.117694 | Agosto | 7.033403 | Agosto | 7.341029 |
| Septiembre | 6.662206 | Septiembre | 6.686875 | Septiembre | 6.822401 |
| Octubre | 6.862795 | Octubre | 6.90685 | Octubre | 6.991571 |
| Noviembre | 7.011095 | Noviembre | 7.083527 | Noviembre | 7.289087 |
| Diciembre | 7.688564 | Diciembre | 8.049182 | Diciembre | 8.025835 |

Tabla A.8: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1994-1996.
Fuente: Energy Information Administration (EIA).

| Año 1994 | | Año 1995 | | Año 1996 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 8.593476 | Enero | 8.229314 | Enero | 8.783559 |
| Febrero | 7.749869 | Febrero | 7.603164 | Febrero | 8.111053 |
| Marzo | 7.672324 | Marzo | 7.749396 | Marzo | 8.199231 |
| Abril | 6.987193 | Abril | 7.113916 | Abril | 7.368835 |
| Mayo | 6.894539 | Mayo | 7.158831 | Mayo | 7.469621 |
| Junio | 7.170488 | Junio | 7.239355 | Junio | 7.452667 |
| Julio | 7.399171 | Julio | 7.633846 | Julio | 7.76482 |
| Agosto | 7.481423 | Agosto | 7.92587 | Agosto | 7.876603 |
| Septiembre | 6.890023 | Septiembre | 7.144139 | Septiembre | 7.153554 |
| Octubre | 7.079167 | Octubre | 7.233039 | Octubre | 7.624521 |
| Noviembre | 7.156575 | Noviembre | 7.580674 | Noviembre | 7.80297 |
| Diciembre | 8.013002 | Diciembre | 8.418986 | Diciembre | 8.41296 |

Tabla A.9: Consumo Total Energía Primaria [Cuatrillones Btu] Años 1997-1999.
Fuente: Energy Information Administration (EIA).

| Año 1997 | | Año 1998 | | Año 1999 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 8.83165 | Enero | 8.616182 | Enero | 8.919385 |
| Febrero | 7.794508 | Febrero | 7.652795 | Febrero | 7.816392 |
| Marzo | 7.992524 | Marzo | 8.177666 | Marzo | 8.377727 |
| Abril | 7.530876 | Abril | 7.518049 | Abril | 7.664196 |
| Mayo | 7.484287 | Mayo | 7.582563 | Mayo | 7.630737 |
| Junio | 7.473265 | Junio | 7.722534 | Junio | 7.812547 |
| Julio | 8.098807 | Julio | 8.284175 | Julio | 8.377734 |
| Agosto | 7.917525 | Agosto | 8.233685 | Agosto | 8.385746 |
| Septiembre | 7.41999 | Septiembre | 7.622231 | Septiembre | 7.6189 |
| Octubre | 7.684554 | Octubre | 7.616704 | Octubre | 7.722685 |
| Noviembre | 7.757317 | Noviembre | 7.513953 | Noviembre | 7.641839 |
| Diciembre | 8.614929 | Diciembre | 8.477055 | Diciembre | 8.680369 |

Tabla A.10: Consumo Total Energía Primaria [Cuatrillones Btu] Años 2000-2002.
Fuente: Energy Information Administration (EIA).

| Año 2000 | | Año 2001 | | Año 2002 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 8.955632 | Enero | 9.235901 | Enero | 8.800577 |
| Febrero | 8.411858 | Febrero | 8.079533 | Febrero | 7.865222 |
| Marzo | 8.303318 | Marzo | 8.482185 | Marzo | 8.369224 |
| Abril | 7.678513 | Abril | 7.647442 | Abril | 7.766781 |
| Mayo | 8.035094 | Mayo | 7.637828 | Mayo | 7.809105 |
| Junio | 8.012126 | Junio | 7.661306 | Junio | 7.898537 |
| Julio | 8.239735 | Julio | 8.153517 | Julio | 8.434788 |
| Agosto | 8.552401 | Agosto | 8.312763 | Agosto | 8.354453 |
| Septiembre | 7.701884 | Septiembre | 7.409713 | Septiembre | 7.669478 |
| Octubre | 7.770306 | Octubre | 7.726865 | Octubre | 7.811093 |
| Noviembre | 7.94916 | Noviembre | 7.553569 | Noviembre | 8.022439 |
| Diciembre | 9.206323 | Diciembre | 8.268844 | Diciembre | 8.841545 |

Tabla A.11: Consumo Total Energía Primaria [Cuatrillones Btu] Años 2003-2005.
Fuente: Energy Information Administration (EIA).

| Año 2003 | | Año 2004 | | Año 2005 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 9.241581 | Enero | 9.358096 | Enero | 9.295249 |
| Febrero | 8.438327 | Febrero | 8.740857 | Febrero | 8.290833 |
| Marzo | 8.389673 | Marzo | 8.437906 | Marzo | 8.733914 |
| Abril | 7.674455 | Abril | 7.800129 | Abril | 7.72174 |
| Mayo | 7.669797 | Mayo | 7.973814 | Mayo | 7.946109 |
| Junio | 7.648226 | Junio | 7.989111 | Junio | 8.179526 |
| Julio | 8.278235 | Julio | 8.413122 | Julio | 8.589137 |
| Agosto | 8.398374 | Agosto | 8.361797 | Agosto | 8.695789 |
| Septiembre | 7.61305 | Septiembre | 7.837803 | Septiembre | 7.794476 |
| Octubre | 7.789539 | Octubre | 7.956027 | Octubre | 7.788574 |
| Noviembre | 7.842548 | Noviembre | 8.057524 | Noviembre | 7.946574 |
| Diciembre | 8.933423 | Diciembre | 9.163174 | Diciembre | 9.205287 |

Tabla A.12: Consumo Total Energía Primaria [Cuatrillones Btu] Años 2006-2008.
Fuente: Energy Information Administration (EIA).

| Año 2006 | | Año 2007 | | Año 2008 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 8.822672 | Enero | 9.227761 | Enero | 9.422188 |
| Febrero | 8.197706 | Febrero | 8.759502 | Febrero | 8.660753 |
| Marzo | 8.592603 | Marzo | 8.564723 | Marzo | 8.596788 |
| Abril | 7.717395 | Abril | 7.926249 | Abril | 7.84368 |
| Mayo | 7.964245 | Mayo | 8.024056 | Mayo | 7.902721 |
| Junio | 8.153078 | Junio | 8.100448 | Junio | 8.048369 |
| Julio | 8.639901 | Julio | 8.493671 | Julio | 8.423632 |
| Agosto | 8.738791 | Agosto | 8.823103 | Agosto | 8.22325 |
| Septiembre | 7.792833 | Septiembre | 7.943626 | Septiembre | 7.357687 |
| Octubre | 8.027348 | Octubre | 7.974808 | Octubre | 7.790407 |
| Noviembre | 8.035988 | Noviembre | 8.084977 | Noviembre | 7.81551 |
| Diciembre | 8.801189 | Diciembre | 9.092318 | Diciembre | 8.804099 |

Tabla A.13: Consumo Total Energía Primaria [Cuatrillones Btu] Años 2009-2011.
Fuente: Energy Information Administration (EIA).

| Año 2009 | | Año 2010 | | Año 2011 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 9.135985 | Enero | 9.113757 | Enero | 9.278798 |
| Febrero | 7.880314 | Febrero | 8.197209 | Febrero | 8.091048 |
| Marzo | 8.056575 | Marzo | 8.185145 | Marzo | 8.326008 |
| Abril | 7.347912 | Abril | 7.352547 | Abril | 7.484839 |
| Mayo | 7.294207 | Mayo | 7.658428 | Mayo | 7.565172 |
| Junio | 7.543904 | Junio | 7.989391 | Junio | 7.878193 |
| Julio | 7.822647 | Julio | 8.363511 | Julio | 8.368996 |
| Agosto | 7.970487 | Agosto | 8.425126 | Agosto | 8.392325 |
| Septiembre | 7.278712 | Septiembre | 7.674965 | Septiembre | 7.548158 |
| Octubre | 7.480777 | Octubre | 7.488647 | Octubre | 7.56253 |
| Noviembre | 7.455998 | Noviembre | 7.779384 | Noviembre | 7.774188 |
| Diciembre | 8.847871 | Diciembre | 9.212851 | Diciembre | 8.566018 |

Tabla A.14: Consumo Total Energía Primaria [Cuatrillones Btu] Años 2012-2014.
Fuente: Energy Information Administration (EIA).

| Año 2012 | | Año 2013 | | Año 2014 | |
|------------|----------|------------|----------|------------|----------|
| Enero | 8.664932 | Enero | 8.972187 | Enero | 9.597777 |
| Febrero | 7.956481 | Febrero | 8.005634 | Febrero | 8.430775 |
| Marzo | 7.670145 | Marzo | 8.371768 | Marzo | 8.527425 |
| Abril | 7.213046 | Abril | 7.512915 | Abril | 7.554751 |
| Mayo | 7.604016 | Mayo | 7.610173 | Mayo | 7.646199 |
| Junio | 7.725586 | Junio | 7.714978 | Junio | 7.779401 |
| Julio | 8.28435 | Julio | 8.261963 | Julio | 8.231966 |
| Agosto | 8.223604 | Agosto | 8.159664 | Agosto | 8.213944 |
| Septiembre | 7.360495 | Septiembre | 7.629992 | Septiembre | 7.653697 |
| Octubre | 7.563286 | Octubre | 7.71267 | Octubre | 7.762227 |
| Noviembre | 7.758409 | Noviembre | 8.124531 | Noviembre | 8.203287 |
| Diciembre | 8.383047 | Diciembre | 9.068709 | Diciembre | 8.804756 |

Tabla A.15: Consumo Total Energía Primaria [Cuatrillones Btu] Años 2015 y 2016.
Fuente: Energy Information Administration (EIA).

| Año 2015 | | Año 2016 | |
|------------|----------|----------|----------|
| Enero | 9.29803 | Enero | 9.102587 |
| Febrero | 8.583333 | Febrero | 8.247054 |
| Marzo | 8.425082 | Marzo | 7.985055 |
| Abril | 7.443757 | Abril | 7.460904 |
| Mayo | 7.630114 | Mayo | 7.598107 |
| Junio | 7.876313 | Junio | 7.970408 |
| Julio | 8.425786 | | |
| Agosto | 8.317208 | | |
| Septiembre | 7.670919 | | |
| Octubre | 7.615439 | | |
| Noviembre | 7.703572 | | |
| Diciembre | 8.36803 | | |

B | Resultados Modelo Propuesto



Augmented Dickey-Fuller Unit Root Test on CONSUMO

| | | | | |
|--|-------------|-----------------------|-------------|-----------|
| Null Hypothesis: CONSUMO has a unit root | | | | |
| Exogenous: Constant | | | | |
| Lag Length: 12 (Automatic - based on AIC, maxlag=12) | | | | |
| | | | t-Statistic | Prob.* |
| Augmented Dickey-Fuller test statistic | | | -1.056863 | 0.7339 |
| Test critical values: | 1% level | | -3.442970 | |
| | 5% level | | -2.866999 | |
| | 10% level | | -2.569739 | |
| *MacKinnon (1996) one-sided p-values. | | | | |
| Augmented Dickey-Fuller Test Equation | | | | |
| Dependent Variable: D(CONSUMO) | | | | |
| Method: Least Squares | | | | |
| Date: 10/14/16 Time: 20:48 | | | | |
| Sample (adjusted): 1974M02 2016M06 | | | | |
| Included observations: 509 after adjustments | | | | |
| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
| CONSUMO(-1) | -0.011936 | 0.011293 | -1.056863 | 0.2911 |
| D(CONSUMO(-1)) | -0.364964 | 0.039984 | -9.127718 | 0.0000 |
| D(CONSUMO(-2)) | -0.372849 | 0.041018 | -9.089826 | 0.0000 |
| D(CONSUMO(-3)) | -0.363737 | 0.041117 | -8.846328 | 0.0000 |
| D(CONSUMO(-4)) | -0.420607 | 0.040782 | -10.31349 | 0.0000 |
| D(CONSUMO(-5)) | -0.329852 | 0.041552 | -7.938230 | 0.0000 |
| D(CONSUMO(-6)) | -0.386148 | 0.041611 | -9.279877 | 0.0000 |
| D(CONSUMO(-7)) | -0.318914 | 0.041274 | -7.726748 | 0.0000 |
| D(CONSUMO(-8)) | -0.376248 | 0.040944 | -9.189266 | 0.0000 |
| D(CONSUMO(-9)) | -0.380213 | 0.040026 | -9.499172 | 0.0000 |
| D(CONSUMO(-10)) | -0.369039 | 0.040259 | -9.166588 | 0.0000 |
| D(CONSUMO(-11)) | -0.304634 | 0.040109 | -7.595158 | 0.0000 |
| D(CONSUMO(-12)) | 0.501292 | 0.038900 | 12.88682 | 0.0000 |
| C | 0.103546 | 0.083436 | 1.241035 | 0.2152 |
| R-squared | 0.839935 | Mean dependent var | | 0.002090 |
| Adjusted R-squared | 0.835731 | S.D. dependent var | | 0.504365 |
| S.E. of regression | 0.204420 | Akaike info criterion | | -0.310162 |
| Sum squared resid | 20.68479 | Schwarz criterion | | -0.193749 |
| Log likelihood | 92.93632 | Hannan-Quinn criter. | | -0.264517 |
| F-statistic | 199.8066 | Durbin-Watson stat | | 2.113966 |
| Prob(F-statistic) | 0.000000 | | | |

Figura B.1: Resultados de Prueba de Raíz Unitaria con prueba Dickey-Fuller Aumentada para Serie en su Nivel.

Fuente: Elaboración Propia, Eviews 8.

Augmented Dickey-Fuller Unit Root Test on D(CONSUMO)

| Null Hypothesis: D(CONSUMO) has a unit root | | | | |
|--|-------------|-----------------------|-------------|-----------|
| Exogenous: Constant | | | | |
| Lag Length: 12 (Automatic - based on AIC, maxlag=12) | | | | |
| | | | t-Statistic | Prob.* |
| Augmented Dickey-Fuller test statistic | | | -8.797972 | 0.0000 |
| Test critical values: | | | | |
| 1% level | | | -3.442995 | |
| 5% level | | | -2.867010 | |
| 10% level | | | -2.569745 | |
| *MacKinnon (1996) one-sided p-values. | | | | |
| Augmented Dickey-Fuller Test Equation | | | | |
| Dependent Variable: D(CONSUMO,2) | | | | |
| Method: Least Squares | | | | |
| Date: 10/14/16 Time: 21:28 | | | | |
| Sample (adjusted): 1974M03 2016M06 | | | | |
| Included observations: 508 after adjustments | | | | |
| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
| D(CONSUMO(-1)) | -4.056054 | 0.461021 | -8.797972 | 0.0000 |
| D(CONSUMO(-1),2) | 2.624088 | 0.443159 | 5.921319 | 0.0000 |
| D(CONSUMO(-2),2) | 2.274279 | 0.407130 | 5.586120 | 0.0000 |
| D(CONSUMO(-3),2) | 1.942536 | 0.369407 | 5.258519 | 0.0000 |
| D(CONSUMO(-4),2) | 1.556006 | 0.331598 | 4.692449 | 0.0000 |
| D(CONSUMO(-5),2) | 1.261108 | 0.293340 | 4.299132 | 0.0000 |
| D(CONSUMO(-6),2) | 0.904868 | 0.255977 | 3.534962 | 0.0004 |
| D(CONSUMO(-7),2) | 0.625705 | 0.217283 | 2.879675 | 0.0042 |
| D(CONSUMO(-8),2) | 0.281262 | 0.180111 | 1.561605 | 0.1190 |
| D(CONSUMO(-9),2) | -0.055855 | 0.142081 | -0.393117 | 0.6944 |
| D(CONSUMO(-10),2) | -0.387751 | 0.106317 | -3.647121 | 0.0003 |
| D(CONSUMO(-11),2) | -0.652387 | 0.072555 | -8.991663 | 0.0000 |
| D(CONSUMO(-12),2) | -0.111373 | 0.044756 | -2.488451 | 0.0132 |
| C | 0.014557 | 0.009167 | 1.587946 | 0.1129 |
| R-squared | 0.925238 | Mean dependent var | | 0.001894 |
| Adjusted R-squared | 0.923271 | S.D. dependent var | | 0.734662 |
| S.E. of regression | 0.203502 | Akaike info criterion | | -0.319111 |
| Sum squared resid | 20.45803 | Schwarz criterion | | -0.202523 |
| Log likelihood | 95.05409 | Hannan-Quinn criter. | | -0.273393 |
| F-statistic | 470.2792 | Durbin-Watson stat | | 2.045873 |
| Prob(F-statistic) | 0.000000 | | | |

Figura B.2: Resultados de Prueba de Raíz Unitaria con prueba Dickey-Fuller Aumentada para Primera Diferencia de la Serie.

Fuente: Elaboración Propia, Eviews 8.

Tabla B.1: Resultados de Criterio AIC y SC de Modelos AR(1-36) de la serie z_t .**Fuente:** Elaboración Propia, Eviews 8.

| Modelo | AIC | SC |
|---------------|-----------------|-----------------|
| AR(1) | 1.454317 | 1.462498 |
| AR(2) | 1.451442 | 1.467827 |
| AR(3) | 1.350696 | 1.37531 |
| AR(4) | 1.163812 | 1.196679 |
| AR(5) | 1.141138 | 1.182283 |
| AR(6) | 1.099911 | 1.149358 |
| AR(7) | 1.089327 | 1.147101 |
| AR(8) | 0.934929 | 1.001054 |
| AR(9) | 0.800769 | 0.87527 |
| AR(10) | 0.521164 | 0.604068 |
| AR(11) | -0.01362 | 0.077714 |
| AR(12) | -0.30973 | -0.20994 |
| AR(13) | -0.31796 | -0.2097 |
| AR(14) | -0.3584 | -0.24164 |
| AR(15) | -0.35329 | -0.228 |
| AR(16) | -0.34868 | -0.21483 |
| AR(17) | -0.35167 | -0.20924 |
| AR(18) | -0.35062 | -0.19959 |
| AR(19) | -0.3477 | -0.18803 |
| AR(20) | -0.3418 | -0.17348 |
| AR(21) | -0.33634 | -0.15932 |
| AR(22) | -0.36317 | -0.17744 |
| AR(23) | -0.4228 | -0.22833 |
| AR(24) | -0.44163 | -0.2384 |
| AR(25) | -0.43875 | -0.22673 |
| AR(26) | -0.43665 | -0.21581 |
| AR(27) | -0.43316 | -0.20347 |
| AR(28) | -0.43886 | -0.20029 |
| AR(29) | -0.43397 | -0.1865 |
| AR(30) | -0.42852 | -0.17211 |
| AR(31) | -0.43461 | -0.16925 |
| AR(32) | -0.42833 | -0.15398 |
| AR(33) | -0.42203 | -0.13867 |
| AR(34) | -0.42688 | -0.13447 |
| AR(35) | -0.48914 | -0.18767 |
| AR(36) | -0.51718 | -0.2066 |

Tabla B.2: Resultados de MAPE para los pronósticos de ANFIS.**Fuente:** Elaboración Propia, MS Excel 2013.

| Abreviatura | MAPE |
|-----------------------------|--------------------|
| anfis_scr05_suge_hyb | 0.004773603 |
| anfis_scr05_suge_back | 0.008284709 |
| anfis_scr06_suge_hyb | 0.012286328 |
| anfis_scr06_suge_back | 0.013021973 |
| anfis_scr07_suge_hyb | 0.012735196 |
| anfis_scr07_suge_back | 0.013017106 |
| anfis_scr08_suge_hyb | 0.012804777 |
| anfis_scr08_suge_back | 0.013116708 |
| anfis_scr09_suge_hyb | 0.012946183 |
| anfis_scr09_suge_back | 0.013189228 |
| anfis_scr10_suge_hyb | 0.013438553 |
| anfis_scr10_suge_back | 0.013687994 |

Tabla B.3: Resultados de Criterio AIC y SC de Modelos MA(1-23) de la serie z_t .**Fuente:** Elaboración Propia, Eviews 8.

| Modelo | AIC | SC |
|---------------|-------------------|-------------------|
| MA(1) | 1.45813694 | 1.47447379 |
| MA(2) | 1.24410009 | 1.26860536 |
| MA(3) | 1.14656342 | 1.17923712 |
| MA(4) | 1.13987357 | 1.1807157 |
| MA(5) | 0.97969435 | 1.02870491 |
| MA(6) | 0.96706203 | 1.02424101 |
| MA(7) | 0.96845116 | 1.03379857 |
| MA(8) | 0.96227154 | 1.03578738 |
| MA(9) | 0.82479456 | 0.90647882 |
| MA(10) | 0.79423364 | 0.88408633 |
| MA(11) | 0.80645455 | 0.90447566 |
| MA(12) | 0.564382 | 0.67057154 |
| MA(13) | 0.54730678 | 0.66166475 |
| MA(14) | 0.47600581 | 0.59853221 |
| MA(15) | 0.44414785 | 0.57484267 |
| MA(16) | 0.43757227 | 0.57643551 |
| MA(17) | 0.42205722 | 0.56908889 |
| MA(18) | 0.42305108 | 0.57825118 |
| MA(19) | 0.38260962 | 0.54597815 |
| MA(20) | 0.35749377 | 0.52903072 |
| MA(21) | 0.32809829 | 0.50780366 |
| MA(22) | 0.32864376 | 0.51651756 |
| MA(23) | 0.31755168 | 0.51359391 |

Tabla B.4: Parte I: Resultados de Criterio AIC de Modelos ARMA(1-23,1-23) de la serie z_t .

Fuente: Elaboración Propia, Eviews 8.

| | MA(1) | MA(2) | MA(3) | MA(4) | MA(5) | MA(6) | MA(7) | MA(8) | MA(9) | MA(10) |
|--------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| AR(1) | 1.23454 | 1.21097 | 1.14900 | 1.06785 | 0.96249 | 0.96540 | 0.96880 | 0.89712 | 0.77349 | 0.77670 |
| AR(2) | 1.18491 | 1.20454 | 0.96812 | 1.03543 | 0.96661 | 0.97036 | 0.68656 | 0.90103 | 0.77759 | 0.48496 |
| AR(3) | 1.11388 | 1.11700 | 0.83829 | 1.05211 | 0.77222 | 0.78325 | 0.85143 | 0.56877 | 0.49688 | 0.47326 |
| AR(4) | 1.08293 | 1.08663 | 0.63402 | 0.63617 | 0.59916 | 0.45335 | 0.37357 | 0.55203 | 0.15359 | 0.14102 |
| AR(5) | 1.08659 | 0.96208 | 0.63738 | 0.62107 | 0.38753 | 0.34448 | 0.35364 | 0.31184 | 0.13708 | 0.14058 |
| AR(6) | 1.06676 | 0.92902 | 0.64115 | 0.55946 | 0.35026 | 0.35733 | 0.35231 | -0.17662 | 0.15569 | -0.22273 |
| AR(7) | 1.06365 | 0.93039 | 0.64583 | 0.80632 | 0.35641 | 0.36291 | 0.20289 | 0.22048 | -0.23274 | -0.29876 |
| AR(8) | 0.62609 | 0.29742 | 0.14479 | 0.27703 | 0.14557 | -0.22275 | -0.27761 | -0.27816 | -0.29082 | -0.33132 |
| AR(9) | 0.54254 | 0.51406 | 0.22695 | 0.04186 | 0.02661 | -0.27801 | -0.31521 | -0.34326 | -0.33888 | -0.44315 |
| AR(10) | 0.36009 | 0.04599 | 0.04053 | -0.07777 | -0.08929 | -0.27448 | -0.27692 | -0.48784 | -0.47843 | -0.48143 |
| AR(11) | -0.22739 | -0.24773 | -0.29926 | -0.34325 | -0.34098 | -0.40413 | -0.40262 | -0.40554 | -0.56045 | -0.57390 |
| AR(12) | -0.33895 | -0.34630 | -0.35382 | -0.35041 | -0.34965 | -0.40129 | -0.41173 | -0.43176 | -0.57570 | -0.57748 |
| AR(13) | -0.33856 | -0.34877 | -0.34811 | -0.35904 | -0.37175 | -0.40892 | -0.40826 | -0.57838 | -0.60949 | -0.62822 |
| AR(14) | -0.35509 | -0.35144 | -0.43111 | -0.40472 | -0.42517 | -0.42041 | -0.43113 | -0.59669 | -0.62579 | -0.63131 |
| AR(15) | -0.34913 | -0.41911 | -0.42705 | -0.42245 | -0.41895 | -0.43517 | -0.45265 | -0.62572 | -0.63092 | -0.62887 |
| AR(16) | -0.34625 | -0.42547 | -0.42237 | -0.42179 | -0.48553 | -0.43757 | -0.48596 | -0.62529 | -0.64492 | -0.65203 |
| AR(17) | -0.35348 | -0.42032 | -0.41718 | -0.48679 | -0.48537 | -0.49754 | -0.49896 | -0.61971 | -0.65497 | -0.63960 |
| AR(18) | -0.34851 | -0.41754 | -0.41491 | -0.48993 | -0.48963 | -0.53721 | -0.55200 | -0.61547 | -0.65148 | -0.64862 |
| AR(19) | -0.34312 | -0.41390 | -0.44287 | -0.48857 | -0.49042 | -0.54520 | -0.54705 | -0.62395 | -0.64459 | -0.64581 |
| AR(20) | -0.35445 | -0.42238 | -0.42026 | -0.48592 | -0.48634 | -0.55192 | -0.54796 | -0.65249 | -0.64681 | -0.63798 |
| AR(21) | -0.35814 | -0.39280 | -0.43426 | -0.43485 | -0.46444 | -0.54592 | -0.55317 | -0.64765 | -0.52598 | -0.66206 |
| AR(22) | -0.38466 | -0.40325 | -0.44308 | -0.48643 | -0.51335 | -0.55349 | -0.55609 | -0.64255 | -0.53889 | -0.59005 |
| AR(23) | -0.44995 | -0.44594 | -0.44362 | -0.51808 | -0.51764 | -0.56214 | -0.56088 | -0.61921 | -0.65449 | -0.65483 |

Tabla B.5: Parte 2: Resultados de Criterio AIC de Modelos ARMA(1-23,1-23) de la serie z_t .

Fuente: Elaboración Propia, Eviews 8.

| | MA(11) | MA(12) | MA(13) | MA(14) | MA(15) | MA(16) | MA(17) | MA(18) | MA(19) | MA(20) |
|--------|----------|----------|----------|----------|-----------------|----------|----------|----------|----------|----------|
| AR(1) | 0.78263 | 0.54852 | 0.46669 | 0.45418 | 0.44449 | 0.42480 | 0.42098 | 0.42452 | 0.38089 | 0.33012 |
| AR(2) | 0.48479 | 0.54497 | 0.44404 | 0.46287 | 0.26386 | 0.42083 | 0.39029 | 0.42646 | 0.28475 | 0.33515 |
| AR(3) | 0.46215 | 0.51950 | 0.44057 | 0.35852 | 0.16839 | 0.17840 | 0.40130 | 0.12804 | 0.32889 | 0.31181 |
| AR(4) | 0.13626 | 0.29134 | 0.07973 | 0.08213 | 0.15866 | 0.15419 | 0.01422 | -0.11198 | -0.11350 | -0.11028 |
| AR(5) | 0.09352 | 0.07721 | 0.08000 | 0.07374 | 0.15044 | 0.15152 | -0.11246 | -0.12139 | -0.10434 | -0.09864 |
| AR(6) | -0.30503 | -0.31820 | 0.09442 | -0.32239 | 0.15080 | 0.02542 | -0.11812 | -0.11650 | -0.11264 | -0.15307 |
| AR(7) | -0.02001 | -0.04696 | -0.04575 | -0.13971 | 0.01241 | -0.10603 | -0.10937 | 0.20942 | -0.25996 | -0.43390 |
| AR(8) | -0.26339 | -0.36906 | -0.33854 | -0.52704 | -0.53540 | -0.45373 | -0.40044 | -0.41750 | -0.54717 | -0.46618 |
| AR(9) | -0.16665 | -0.50350 | -0.54276 | -0.38501 | -0.57304 | -0.41501 | -0.58040 | -0.56207 | -0.58696 | -0.58535 |
| AR(10) | -0.65423 | -0.65234 | -0.65377 | -0.64823 | -0.65873 | -0.66994 | -0.66823 | -0.59293 | -0.59276 | -0.67345 |
| AR(11) | -0.57513 | -0.65163 | -0.72576 | -0.72319 | -0.73012 | -0.72707 | -0.73250 | -0.72899 | -0.72939 | -0.72394 |
| AR(12) | -0.61541 | -0.74117 | -0.73587 | -0.73522 | -0.74148 | -0.73892 | -0.74335 | -0.74052 | -0.74213 | -0.73821 |
| AR(13) | -0.62431 | -0.73505 | -0.73115 | -0.73078 | -0.73766 | -0.74943 | -0.74477 | -0.73559 | -0.73617 | -0.73487 |
| AR(14) | -0.71753 | -0.73558 | -0.73388 | -0.75138 | -0.77364 | -0.75340 | -0.73932 | -0.73387 | -0.72677 | -0.72701 |
| AR(15) | -0.63047 | -0.74093 | -0.75212 | -0.74683 | -0.74291 | -0.72258 | -0.72983 | -0.72620 | -0.71463 | -0.73995 |
| AR(16) | -0.64937 | -0.73216 | -0.74442 | -0.74504 | -0.74051 | -0.77243 | -0.71938 | -0.72097 | -0.70928 | -0.70948 |
| AR(17) | -0.64568 | -0.67694 | -0.72125 | -0.72365 | -0.71853 | -0.71996 | -0.71404 | -0.70992 | -0.71144 | -0.70332 |
| AR(18) | -0.63780 | -0.67158 | -0.72670 | -0.71785 | -0.71375 | -0.71062 | -0.71100 | -0.70440 | -0.62461 | -0.69911 |
| AR(19) | -0.72709 | -0.66791 | -0.72792 | -0.63731 | -0.71928 | -0.71585 | -0.69461 | -0.69076 | -0.68791 | -0.65399 |
| AR(20) | -0.64345 | -0.72315 | -0.61894 | -0.63015 | -0.70817 | -0.73485 | -0.69849 | -0.68264 | -0.67244 | -0.71786 |
| AR(21) | -0.63958 | -0.71493 | -0.67372 | -0.65670 | -0.70483 | -0.71354 | -0.71344 | -0.68905 | -0.68854 | -0.64109 |
| AR(22) | -0.69967 | -0.70159 | -0.70817 | -0.69856 | -0.70866 | -0.68303 | -0.68110 | -0.69608 | -0.69821 | -0.67672 |
| AR(23) | -0.62041 | -0.70604 | -0.71413 | -0.68152 | -0.64671 | -0.63841 | -0.70043 | -0.66275 | -0.66422 | -0.60547 |

Tabla B.6: Parte 3: Resultados de Criterio AIC de Modelos ARMA(1-23,1-23) de la serie z_t .
Fuente: Elaboración Propia, Eviews 8.

| | MA(21) | MA(22) | MA(23) |
|--------|----------|----------|----------|
| AR(1) | 0.32234 | 0.29601 | 0.31668 |
| AR(2) | 0.32597 | 0.03212 | 0.03703 |
| AR(3) | 0.04652 | 0.34839 | 0.38487 |
| AR(4) | -0.18035 | -0.18639 | 0.02990 |
| AR(5) | -0.18752 | -0.17659 | -0.21134 |
| AR(6) | -0.43951 | -0.18160 | -0.46019 |
| AR(7) | -0.24763 | -0.47225 | -0.45762 |
| AR(8) | -0.45302 | -0.44880 | -0.44252 |
| AR(9) | -0.44234 | -0.58590 | -0.40232 |
| AR(10) | -0.67205 | -0.60153 | -0.68648 |
| AR(11) | -0.72582 | -0.71487 | -0.71111 |
| AR(12) | -0.73850 | -0.74216 | -0.74038 |
| AR(13) | -0.74601 | -0.72939 | -0.74235 |
| AR(14) | -0.73656 | -0.73257 | -0.73804 |
| AR(15) | -0.74071 | -0.73201 | -0.73731 |
| AR(16) | -0.72205 | -0.72959 | -0.72392 |
| AR(17) | -0.70935 | -0.72545 | -0.71271 |
| AR(18) | -0.66173 | -0.60520 | -0.65523 |
| AR(19) | -0.71618 | -0.71791 | -0.71046 |
| AR(20) | -0.74129 | -0.70502 | -0.70505 |
| AR(21) | -0.70428 | -0.70636 | -0.59662 |
| AR(22) | -0.66645 | -0.58412 | -0.60952 |
| AR(23) | -0.63491 | -0.63228 | -0.62593 |

Tabla B.7: Parte 1: Resultados de Criterio SC de Modelos ARMA(1-23,1-23) de la serie z_t .

Fuente: Elaboración Propia, Eviews 8.

| | MA(1) | MA(2) | MA(3) | MA(4) | MA(5) | MA(6) | MA(7) | MA(8) | MA(9) | MA(10) |
|--------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| AR(1) | 1.25909 | 1.24369 | 1.18990 | 1.11693 | 1.01975 | 1.03084 | 1.04242 | 0.97892 | 0.86348 | 0.87487 |
| AR(2) | 1.21768 | 1.24550 | 1.01728 | 1.09278 | 1.03215 | 1.04410 | 0.76849 | 0.99115 | 0.87590 | 0.59146 |
| AR(3) | 1.15490 | 1.16623 | 0.89573 | 1.11775 | 0.84607 | 0.86530 | 0.94168 | 0.66722 | 0.60354 | 0.58813 |
| AR(4) | 1.13223 | 1.14415 | 0.69976 | 0.71012 | 0.68133 | 0.54374 | 0.47217 | 0.65885 | 0.26862 | 0.26427 |
| AR(5) | 1.14419 | 1.02791 | 0.71144 | 0.70336 | 0.47804 | 0.44322 | 0.46062 | 0.42705 | 0.26051 | 0.27224 |
| AR(6) | 1.13269 | 1.00319 | 0.72356 | 0.65012 | 0.44915 | 0.46446 | 0.46768 | -0.05301 | 0.28755 | -0.08263 |
| AR(7) | 1.13793 | 1.01293 | 0.73662 | 0.90536 | 0.46371 | 0.47845 | 0.32669 | 0.35254 | -0.09244 | -0.15020 |
| AR(8) | 0.70874 | 0.38834 | 0.24397 | 0.38449 | 0.26129 | -0.09877 | -0.14536 | -0.13764 | -0.14204 | -0.17427 |
| AR(9) | 0.63359 | 0.61339 | 0.33456 | 0.15775 | 0.15078 | -0.14556 | -0.17449 | -0.19425 | -0.18160 | -0.27759 |
| AR(10) | 0.45958 | 0.15377 | 0.15660 | 0.04659 | 0.04336 | -0.13354 | -0.12769 | -0.33033 | -0.31262 | -0.30733 |
| AR(11) | -0.11945 | -0.13149 | -0.17472 | -0.21040 | -0.19984 | -0.25468 | -0.24487 | -0.23948 | -0.38609 | -0.39124 |
| AR(12) | -0.22253 | -0.22157 | -0.22078 | -0.20906 | -0.19998 | -0.24330 | -0.24543 | -0.25714 | -0.39276 | -0.38623 |
| AR(13) | -0.21365 | -0.21553 | -0.20654 | -0.20914 | -0.21352 | -0.24237 | -0.23337 | -0.39517 | -0.41796 | -0.42835 |
| AR(14) | -0.22164 | -0.20966 | -0.28099 | -0.24625 | -0.25837 | -0.24526 | -0.24765 | -0.40486 | -0.42562 | -0.42280 |
| AR(15) | -0.20713 | -0.26876 | -0.26835 | -0.25540 | -0.24354 | -0.25141 | -0.26053 | -0.42525 | -0.42210 | -0.41170 |
| AR(16) | -0.19567 | -0.26653 | -0.25506 | -0.24611 | -0.30149 | -0.24517 | -0.28519 | -0.41615 | -0.42742 | -0.42616 |
| AR(17) | -0.19430 | -0.25276 | -0.24123 | -0.30247 | -0.29268 | -0.29647 | -0.28951 | -0.40187 | -0.42876 | -0.40501 |
| AR(18) | -0.18069 | -0.24133 | -0.23031 | -0.29694 | -0.28825 | -0.32743 | -0.33384 | -0.38892 | -0.41654 | -0.40528 |
| AR(19) | -0.16664 | -0.22902 | -0.24958 | -0.28689 | -0.28033 | -0.32670 | -0.32015 | -0.38865 | -0.40089 | -0.39370 |
| AR(20) | -0.16929 | -0.22880 | -0.21827 | -0.27551 | -0.26751 | -0.32468 | -0.31230 | -0.40841 | -0.39431 | -0.37707 |
| AR(21) | -0.16426 | -0.19049 | -0.22353 | -0.21569 | -0.23686 | -0.30990 | -0.30872 | -0.39477 | -0.26468 | -0.39233 |
| AR(22) | -0.18205 | -0.19220 | -0.22359 | -0.25849 | -0.27697 | -0.30867 | -0.30283 | -0.38084 | -0.26874 | -0.31147 |
| AR(23) | -0.23858 | -0.22611 | -0.21534 | -0.28134 | -0.27245 | -0.30849 | -0.29877 | -0.34865 | -0.37548 | -0.36736 |

Tabla B.8: Parte 2: Resultados de Criterio SC de Modelos ARMA(1-23,1-23) de la serie z_t .

Fuente: Elaboración Propia, Eviews 8.

| | MA(11) | MA(12) | MA(13) | MA(14) | MA(15) | MA(16) | MA(17) | MA(18) | MA(19) | MA(20) |
|--------|----------|-----------------|----------|----------|----------|----------|----------|----------|----------|----------|
| AR(1) | 0.88898 | 0.66304 | 0.58940 | 0.58506 | 0.58356 | 0.57205 | 0.57641 | 0.58813 | 0.55268 | 0.51009 |
| AR(2) | 0.59949 | 0.66786 | 0.57512 | 0.60214 | 0.41133 | 0.57648 | 0.55414 | 0.59851 | 0.46498 | 0.52358 |
| AR(3) | 0.58522 | 0.65077 | 0.58005 | 0.50620 | 0.32428 | 0.34249 | 0.57360 | 0.30854 | 0.51760 | 0.50872 |
| AR(4) | 0.26773 | 0.43102 | 0.22763 | 0.23825 | 0.32300 | 0.32674 | 0.19498 | 0.07701 | 0.08370 | 0.09513 |
| AR(5) | 0.23341 | 0.22533 | 0.23635 | 0.23831 | 0.32324 | 0.33255 | 0.07681 | 0.07610 | 0.10138 | 0.11531 |
| AR(6) | -0.15669 | -0.16162 | 0.25924 | -0.14933 | 0.33211 | 0.21497 | 0.07967 | 0.08952 | 0.10162 | 0.06944 |
| AR(7) | 0.13681 | 0.11811 | 0.12757 | 0.04186 | 0.20224 | 0.09205 | 0.09696 | 0.42401 | -0.03712 | -0.20281 |
| AR(8) | -0.09808 | -0.19548 | -0.15670 | -0.33693 | -0.33702 | -0.24709 | -0.18553 | -0.19433 | -0.31574 | -0.22648 |
| AR(9) | 0.00718 | -0.32139 | -0.35237 | -0.18634 | -0.36610 | -0.19978 | -0.35689 | -0.33029 | -0.34689 | -0.33701 |
| AR(10) | -0.47184 | -0.46166 | -0.45480 | -0.44097 | -0.44318 | -0.44610 | -0.43610 | -0.35251 | -0.34405 | -0.41645 |
| AR(11) | -0.38417 | -0.45236 | -0.51819 | -0.50732 | -0.50594 | -0.49459 | -0.49172 | -0.47990 | -0.47200 | -0.45825 |
| AR(12) | -0.41584 | -0.53328 | -0.51967 | -0.51071 | -0.50865 | -0.49778 | -0.49390 | -0.48274 | -0.47604 | -0.46381 |
| AR(13) | -0.41612 | -0.51853 | -0.50631 | -0.49761 | -0.49616 | -0.49960 | -0.48661 | -0.46911 | -0.46136 | -0.45173 |
| AR(14) | -0.50068 | -0.51039 | -0.50035 | -0.50951 | -0.52343 | -0.49485 | -0.47244 | -0.45865 | -0.44321 | -0.43510 |
| AR(15) | -0.40495 | -0.50705 | -0.50988 | -0.49625 | -0.48397 | -0.45529 | -0.45419 | -0.44221 | -0.42228 | -0.43925 |
| AR(16) | -0.41514 | -0.48956 | -0.49346 | -0.48571 | -0.47282 | -0.49637 | -0.43495 | -0.42818 | -0.40812 | -0.39995 |
| AR(17) | -0.40271 | -0.42560 | -0.46153 | -0.45555 | -0.44205 | -0.43510 | -0.42081 | -0.40831 | -0.40145 | -0.38495 |
| AR(18) | -0.38608 | -0.41146 | -0.45819 | -0.44095 | -0.42846 | -0.41694 | -0.40893 | -0.39394 | -0.30575 | -0.37187 |
| AR(19) | -0.46658 | -0.39900 | -0.45061 | -0.35159 | -0.42515 | -0.41332 | -0.38367 | -0.37142 | -0.36017 | -0.31785 |
| AR(20) | -0.37412 | -0.44541 | -0.33278 | -0.33558 | -0.40518 | -0.42344 | -0.37867 | -0.35440 | -0.33579 | -0.37279 |
| AR(21) | -0.36141 | -0.42834 | -0.37869 | -0.35324 | -0.39295 | -0.39323 | -0.38470 | -0.35188 | -0.34294 | -0.28706 |
| AR(22) | -0.41264 | -0.40612 | -0.40425 | -0.38620 | -0.38786 | -0.35379 | -0.34342 | -0.34995 | -0.34364 | -0.31371 |
| AR(23) | -0.32449 | -0.40166 | -0.40129 | -0.36023 | -0.31696 | -0.30021 | -0.35378 | -0.30764 | -0.30066 | -0.23345 |

Tabla B.9: Parte 3: Resultados de Criterio SC de Modelos ARMA(1-23,1-23) de la serie z_t .
Fuente: Elaboración Propia, Eviews 8.

| | MA(21) | MA(22) | MA(23) |
|--------|----------|----------|----------|
| AR(1) | 0.51049 | 0.49234 | 0.52119 |
| AR(2) | 0.52259 | 0.23693 | 0.25003 |
| AR(3) | 0.25163 | 0.56171 | 0.60639 |
| AR(4) | 0.03328 | 0.03546 | 0.25997 |
| AR(5) | 0.03466 | 0.05382 | 0.02729 |
| AR(6) | -0.20876 | 0.05739 | -0.21296 |
| AR(7) | -0.00829 | -0.22465 | -0.20177 |
| AR(8) | -0.20505 | -0.19257 | -0.17802 |
| AR(9) | -0.18572 | -0.32100 | -0.12914 |
| AR(10) | -0.40676 | -0.32795 | -0.40461 |
| AR(11) | -0.45182 | -0.43258 | -0.42051 |
| AR(12) | -0.45578 | -0.45113 | -0.44104 |
| AR(13) | -0.45454 | -0.42959 | -0.43423 |
| AR(14) | -0.43631 | -0.42399 | -0.42111 |
| AR(15) | -0.43166 | -0.41460 | -0.41155 |
| AR(16) | -0.40416 | -0.40334 | -0.38930 |
| AR(17) | -0.38260 | -0.39032 | -0.36921 |
| AR(18) | -0.32610 | -0.26117 | -0.30281 |
| AR(19) | -0.37164 | -0.36496 | -0.34911 |
| AR(20) | -0.38780 | -0.34311 | -0.33473 |
| AR(21) | -0.34182 | -0.33548 | -0.21731 |
| AR(22) | -0.29500 | -0.20423 | -0.22119 |
| AR(23) | -0.25443 | -0.24335 | -0.22854 |

Tabla B.10: Resultados AIC para modelo GARCH proveniente de AR(14).
Fuente: Elaboración Propia, Eviews 8.

| AIC.AR(14) | GARCH(1) | GARCH(2) | GARCH(3) | GARCH(4) | GARCH(5) | GARCH(6) | GARCH(7) | GARCH(8) | GARCH(9) |
|------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------------|-------------|
| ARCH(1) | -0.35814218 | -0.3678502 | -0.37268784 | -0.3614452 | -0.41397449 | -0.41504029 | -0.41261934 | -0.42228694 | -0.39970715 |
| ARCH(2) | -0.38743725 | -0.3856866 | -0.44029603 | -0.42498394 | -0.45422819 | -0.44533686 | -0.46361695 | -0.4741091 | -0.46119509 |
| ARCH(3) | -0.38501936 | -0.39763512 | -0.40071245 | -0.39809826 | -0.45410676 | -0.43766786 | -0.44294092 | -0.44476866 | -0.42326137 |
| ARCH(4) | -0.39851365 | -0.39525139 | -0.38648136 | -0.38329959 | -0.37845903 | -0.38461811 | -0.37016934 | -0.36927639 | -0.36485837 |
| ARCH(5) | -0.38947442 | -0.38646755 | -0.36758432 | -0.37496744 | -0.36800864 | -0.37789408 | -0.37781106 | -0.35874639 | -0.35692993 |
| ARCH(6) | -0.38727753 | -0.3864163 | -0.37509856 | -0.37272245 | -0.38141982 | -0.38347378 | -0.37872803 | -0.3718384 | -0.35880255 |
| ARCH(7) | -0.39667318 | -0.38458637 | -0.38477129 | -0.38299948 | -0.38010603 | -0.38145645 | -0.37331531 | -0.37016744 | -0.36966269 |
| ARCH(8) | -0.38207313 | -0.3857066 | -0.38690988 | -0.38429559 | -0.38187906 | -0.37940156 | -0.37207829 | -0.36944928 | -0.36426701 |
| ARCH(9) | -0.38978485 | -0.39961464 | -0.38470296 | -0.38397139 | -0.37916368 | -0.37997213 | -0.37359923 | -0.37013296 | -0.36436051 |

Tabla B.11: Resultados SC para modelo GARCH proveniente de AR(14).
Fuente: Elaboración Propia, Eviews 8.

| SC.AR(14) | GARCH(1) | GARCH(2) | GARCH(3) | GARCH(4) | GARCH(5) | GARCH(6) | GARCH(7) | GARCH(8) | GARCH(9) |
|-----------|-------------|-------------|-------------------|-------------|-------------|-------------|-------------|-------------|-------------|
| ARCH(1) | -0.20801752 | -0.20938529 | -0.20588267 | -0.18629977 | -0.23048881 | -0.22321434 | -0.21245313 | -0.21378048 | -0.18286043 |
| ARCH(2) | -0.22897234 | -0.21888143 | -0.2651506 | -0.24149826 | -0.26240225 | -0.24517066 | -0.25511049 | -0.25726238 | -0.23600811 |
| ARCH(3) | -0.21821419 | -0.2224897 | -0.21722676 | -0.20627232 | -0.25394056 | -0.2291614 | -0.2260942 | -0.21958168 | -0.18973414 |
| ARCH(4) | -0.22336822 | -0.21176571 | -0.19465542 | -0.18313339 | -0.16995257 | -0.16777139 | -0.14498237 | -0.13574916 | -0.12299087 |
| ARCH(5) | -0.20598874 | -0.19464161 | -0.16741812 | -0.16646098 | -0.15116193 | -0.1527071 | -0.14428383 | -0.11687889 | -0.10672218 |
| ARCH(6) | -0.19545159 | -0.1862501 | -0.16659211 | -0.15587574 | -0.15623284 | -0.14994654 | -0.13686054 | -0.12163065 | -0.10025454 |
| ARCH(7) | -0.19650698 | -0.17607991 | -0.16792458 | -0.1578125 | -0.1465788 | -0.13958896 | -0.12310756 | -0.11161943 | -0.10277442 |
| ARCH(8) | -0.17356667 | -0.16885988 | -0.16172291 | -0.15076836 | -0.14001157 | -0.1291938 | -0.11353028 | -0.10256101 | -0.08903857 |
| ARCH(9) | -0.17293813 | -0.17442767 | -0.15117572 | -0.1421039 | -0.12895593 | -0.12142412 | -0.10671097 | -0.09490444 | -0.08079173 |

Tabla B.12: Resultados AIC para modelo GARCH proveniente de ARMA(12,12).
Fuente: Elaboración Propia, Eviews 8.

| AIC.ARMA(12,12) | GARCH(1) | GARCH(2) | GARCH(3) | GARCH(4) | GARCH(5) | GARCH(6) | GARCH(7) | GARCH(8) | GARCH(9) |
|-----------------|-------------|-------------|-------------|-------------|-------------------|-------------|-------------|-------------|-------------|
| ARCH(1) | -0.73985136 | -0.70701473 | -0.69045096 | -0.68892679 | -0.66464226 | -0.64914952 | -0.64272254 | -0.6321852 | -0.74915576 |
| ARCH(2) | -0.70985842 | -0.67744575 | -0.73448033 | -0.75681661 | -0.7796102 | -0.75486131 | -0.71497216 | -0.63386662 | -0.69141654 |
| ARCH(3) | -0.6631214 | -0.76486167 | -0.66283804 | -0.72051991 | -0.67706019 | -0.69907824 | -0.75383799 | -0.69053219 | -0.74765953 |
| ARCH(4) | -0.60809848 | -0.62933216 | -0.60076613 | -0.59646227 | -0.62448715 | -0.61766024 | -0.6076716 | -0.59487171 | -0.61371114 |
| ARCH(5) | -0.46948141 | -0.46726337 | -0.48645204 | -0.49223783 | -0.46379425 | -0.5117602 | -0.52744592 | -0.47507334 | -0.49205522 |
| ARCH(6) | -0.48585973 | -0.46473729 | -0.46235384 | -0.47353579 | -0.49608153 | -0.49055917 | -0.49618181 | -0.46748281 | -0.48041044 |
| ARCH(7) | -0.57371881 | -0.51742688 | -0.5188417 | -0.52693328 | -0.50067295 | -0.48115411 | -0.49953714 | -0.48996002 | -0.50205613 |
| ARCH(8) | -0.53063802 | -0.51753088 | -0.50320226 | -0.52509998 | -0.50052169 | -0.58986034 | -0.52210693 | -0.50149916 | -0.48056428 |
| ARCH(9) | -0.50324819 | -0.52269687 | -0.51221921 | -0.51034607 | -0.5074181 | -0.50258103 | -0.49628353 | -0.50575699 | -0.47606354 |

Tabla B.13: Resultados SC para modelo GARCH proveniente de ARMA(12,12).
Fuente: Elaboración Propia, Eviews 8.

| SC.ARMA(12,12) | GARCH(1) | GARCH(2) | GARCH(3) | GARCH(4) | GARCH(5) | GARCH(6) | GARCH(7) | GARCH(8) | GARCH(9) |
|----------------|-------------|--------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| ARCH(1) | -0.50702515 | -0.4658733 | -0.4409943 | -0.43115491 | -0.39855516 | -0.37474719 | -0.36000499 | -0.34115243 | -0.44980777 |
| ARCH(2) | -0.46871698 | -0.42798909 | -0.47670845 | -0.4907295 | -0.50520787 | -0.47214376 | -0.42393939 | -0.33451863 | -0.38375333 |
| ARCH(3) | -0.41366474 | -0.50708978 | -0.39675094 | -0.44611759 | -0.39434264 | -0.40804547 | -0.45449 | -0.38286897 | -0.43168109 |
| ARCH(4) | -0.3503266 | -0.36324506 | -0.3263638 | -0.31374472 | -0.33345438 | -0.31831225 | -0.30000838 | -0.27889327 | -0.28941748 |
| ARCH(5) | -0.2033943 | -0.19286104 | -0.20373449 | -0.20120506 | -0.16444626 | -0.20409698 | -0.21146749 | -0.15077968 | -0.15944634 |
| ARCH(6) | -0.2114574 | -0.18201974 | -0.17132107 | -0.1741878 | -0.18841831 | -0.17458073 | -0.17188815 | -0.13487393 | -0.13948634 |
| ARCH(7) | -0.29100126 | -0.22639411 | -0.21949371 | -0.21927006 | -0.18469452 | -0.15686045 | -0.16692826 | -0.14903591 | -0.15281681 |
| ARCH(8) | -0.23960525 | -0.21818288 | -0.19553904 | -0.20912154 | -0.17622803 | -0.25725146 | -0.18118283 | -0.15225984 | -0.12300974 |
| ARCH(9) | -0.20390019 | -0.21503365 | -0.19624077 | -0.18605241 | -0.17480922 | -0.16165692 | -0.1470442 | -0.14820244 | -0.11019377 |

Tabla B.14: Resultados AIC para modelo GARCH proveniente de ARMA(14,15).

Fuente: Elaboración Propia, Eviews 8.

| AIC.ARMA(14,15) | GARCH(1) | GARCH(2) | GARCH(3) | GARCH(4) | GARCH(5) | GARCH(6) | GARCH(7) | GARCH(8) | GARCH(9) |
|-----------------|-------------|-------------|-------------|-------------|-------------|-------------|--------------------|-------------|-------------|
| ARCH(1) | -0.71697425 | -0.725719 | -0.73957924 | -0.73471116 | -0.75492369 | -0.80076878 | -0.81049583 | -0.66800072 | -0.75286018 |
| ARCH(2) | -0.72455391 | -0.73892004 | -0.72458886 | -0.82470101 | -0.69451885 | -0.82375796 | -0.83493543 | -0.73179585 | -0.74187163 |
| ARCH(3) | -0.74767727 | -0.65317535 | -0.65379121 | -0.72489864 | -0.66839608 | -0.80267064 | -0.72861506 | -0.7576784 | -0.69686657 |
| ARCH(4) | -0.66660388 | -0.64897125 | -0.48901221 | -0.59052769 | -0.58771936 | -0.58947018 | -0.58791644 | -0.6296506 | -0.62630459 |
| ARCH(5) | -0.47892386 | -0.48025929 | -0.45376245 | -0.46923142 | -0.4840429 | -0.48796841 | -0.56965908 | -0.64227379 | -0.47472414 |
| ARCH(6) | -0.42550909 | -0.44291493 | -0.43502926 | -0.45390736 | -0.47837874 | -0.55066112 | -0.60464108 | -0.57102986 | -0.51289656 |
| ARCH(7) | -0.51775916 | -0.46224823 | -0.48473412 | -0.50071856 | -0.48873835 | -0.48699021 | -0.51543819 | -0.51283553 | -0.50150684 |
| ARCH(8) | -0.45483 | -0.48733512 | -0.50206602 | -0.51629483 | -0.5070008 | -0.55891104 | -0.54890491 | -0.49051038 | -0.48035278 |
| ARCH(9) | -0.44956573 | -0.47826426 | -0.50421637 | -0.5003812 | -0.5737575 | -0.56247304 | -0.49315944 | -0.48619792 | -0.47934588 |

Tabla B.15: Resultados SC para modelo GARCH proveniente de ARMA(14,15).

Fuente: Elaboración Propia, Eviews 8.

| SC.ARMA(14,15) | GARCH(1) | GARCH(2) | GARCH(3) | GARCH(4) | GARCH(5) | GARCH(6) | GARCH(7) | GARCH(8) | GARCH(9) |
|----------------|-------------|-------------|-------------|--------------------|-------------|-------------|-------------|-------------|-------------|
| ARCH(1) | -0.44174573 | -0.44215021 | -0.4476702 | -0.43446186 | -0.44633413 | -0.48383896 | -0.48522575 | -0.33439039 | -0.41090958 |
| ARCH(2) | -0.44098513 | -0.447011 | -0.42433955 | -0.51611145 | -0.37758903 | -0.49848788 | -0.5013251 | -0.38984525 | -0.39158077 |
| ARCH(3) | -0.45576823 | -0.35292605 | -0.34520164 | -0.40796883 | -0.343126 | -0.4690603 | -0.38666446 | -0.40738754 | -0.33823546 |
| ARCH(4) | -0.36635457 | -0.34038169 | -0.17208239 | -0.26525761 | -0.25410903 | -0.24751958 | -0.23762559 | -0.27101949 | -0.25933322 |
| ARCH(5) | -0.1703343 | -0.16332947 | -0.12849237 | -0.13562108 | -0.1420923 | -0.13767756 | -0.21102797 | -0.27530242 | -0.09941251 |
| ARCH(6) | -0.10857927 | -0.11764485 | -0.10141892 | -0.11195676 | -0.12808789 | -0.19203001 | -0.23766971 | -0.19571823 | -0.12924468 |
| ARCH(7) | -0.19248908 | -0.1286379 | -0.14278353 | -0.15042771 | -0.13010724 | -0.12001884 | -0.14012656 | -0.12918364 | -0.1095147 |
| ARCH(8) | -0.12121967 | -0.14538452 | -0.15177517 | -0.15766372 | -0.14002943 | -0.18359941 | -0.16525303 | -0.09851824 | -0.08002038 |
| ARCH(9) | -0.10761514 | -0.12797341 | -0.14558526 | -0.13340983 | -0.19844588 | -0.17882115 | -0.1011673 | -0.08586552 | -0.07067322 |

Tabla B.16: Resultados de MAPE para los pronósticos de Benchmarks.

Fuente: Elaboración Propia, MS Excel 2013.

| Abreviatura | MAPE |
|-------------------------------|--------------------|
| ar_14 | 0.020229092 |
| ma_21 | 0.029652025 |
| ma_23 | 0.028901739 |
| arma_12_12 | 0.016527873 |
| arma_14_15 | 0.015520338 |
| garch_2_3 | 0.020148628 |
| garch_2_4 | 0.016816669 |
| garch_2_5 | 0.017000458 |
| garch_2_7 | 0.016782802 |
| garch_2_8 | 0.020177157 |
| garch_3_2 | 0.01699926 |
| ann_hn10_ratio_75_20_5 | 0.018664598 |
| ann_hn15_ratio_75_20_5 | 0.015519185 |
| ann_hn20_ratio_75_20_5 | 0.015778516 |
| ann_hn10_ratio_80_15_5 | 0.015628143 |
| ann_hn15_ratio_80_15_5 | 0.015485511 |
| ann_hn20_ratio_80_15_5 | 0.015001552 |

Tabla B.17: Parte 1: Resultados de p-valores prueba *t* de Welch.
Fuente: Elaboración Propia, MS Excel 2013.

| garch_2_8 | garch_3_2 | ann_hn10_75_20_5 | ann_hn15_75_20_5 | ann_hn20_75_20_5 | ann_hn10_80_15_5 | ann_hn15_80_15_5 | ann_hn20_80_15_5 |
|-------------|-------------|------------------|------------------|------------------|------------------|------------------|------------------|
| 8.4171E-37 | 5.61637E-28 | 1.32232E-33 | 3.1853E-23 | 6.73143E-24 | 1.69569E-23 | 3.5889E-23 | 1.39883E-21 |
| 1.56987E-40 | 5.09607E-32 | 3.87387E-39 | 9.50341E-26 | 1.97649E-26 | 5.24408E-26 | 9.09098E-26 | 1.88165E-23 |
| 1.14038E-17 | 2.64944E-09 | 2.1619E-14 | 1.68992E-05 | 4.83413E-06 | 1.01284E-05 | 1.91465E-05 | 0.000235813 |
| 9.9469E-15 | 5.99494E-07 | 1.71526E-11 | 0.000978606 | 0.000341831 | 0.000636331 | 0.001095036 | 0.007869665 |
| 1.00838E-15 | 9.60801E-08 | 1.82519E-12 | 0.000248849 | 8.09969E-05 | 0.000157183 | 0.000279867 | 0.002421614 |
| 1.11082E-14 | 6.34746E-07 | 1.90006E-11 | 0.001000266 | 0.000350982 | 0.000651604 | 0.001118881 | 0.007962628 |
| 1.51461E-15 | 1.37477E-07 | 2.73279E-12 | 0.000333307 | 0.000109673 | 0.000211478 | 0.00037458 | 0.003142582 |
| 3.34487E-14 | 1.40551E-06 | 5.46864E-11 | 0.001711111 | 0.000623704 | 0.001132215 | 0.001908286 | 0.012377229 |
| 7.35978E-15 | 4.45395E-07 | 1.26597E-11 | 0.000754973 | 0.000261708 | 0.000489337 | 0.000845275 | 0.006218373 |
| 6.243E-14 | 2.24469E-06 | 9.96436E-11 | 0.002378302 | 0.000885589 | 0.001587587 | 0.002647733 | 0.016293311 |
| 7.35528E-13 | 1.26842E-05 | 1.02315E-09 | 0.007471011 | 0.003040656 | 0.005173327 | 0.008253248 | 0.041207018 |
| 4.27563E-12 | 4.64562E-05 | 5.44177E-09 | 0.018175979 | 0.007903861 | 0.012937242 | 0.019954755 | 0.085214851 |
| 0.961037222 | 0.000848069 | 0.116322105 | 5.72712E-07 | 2.84826E-06 | 1.15006E-06 | 4.46813E-07 | 2.18005E-08 |
| 4.39994E-14 | 2.64281E-26 | 8.71178E-20 | 4.81883E-33 | 1.2045E-31 | 1.9314E-32 | 2.86338E-33 | 1.47805E-35 |
| 5.35866E-12 | 4.00482E-23 | 3.97895E-17 | 2.21828E-29 | 4.36113E-28 | 8.01131E-29 | 1.37584E-29 | 9.9486E-32 |
| 0.000172605 | 0.583343948 | 0.016918538 | 0.222231503 | 0.370629193 | 0.279044679 | 0.205729205 | 0.061394698 |
| 1.90556E-06 | 0.087081289 | 0.000478563 | 0.98892092 | 0.758953249 | 0.897332571 | 0.966450159 | 0.526922975 |
| 0.978748077 | 0.001259169 | 0.139600478 | 1.11723E-06 | 5.22666E-06 | 2.18426E-06 | 8.80678E-07 | 4.77003E-08 |
| 0.000590542 | 0.833255671 | 0.040472776 | 0.120143767 | 0.219395374 | 0.156886985 | 0.109712214 | 0.027720828 |
| 0.001386933 | 0.998919702 | 0.07013895 | 0.082650482 | 0.157143342 | 0.109778914 | 0.075033546 | 0.01780641 |
| 0.000542261 | 0.803721478 | 0.037681398 | 0.131854729 | 0.236857553 | 0.17093966 | 0.120716233 | 0.031534703 |
| 1 | 0.001280106 | 0.135991348 | 1.2621E-06 | 5.74683E-06 | 2.43794E-06 | 9.99563E-07 | 5.69549E-08 |
| 0.001280106 | 1 | 0.067723164 | 0.080072736 | 0.153807533 | 0.106849782 | 0.072569757 | 0.016811448 |
| 0.135991348 | 0.067723164 | 1 | 0.000364157 | 0.001213872 | 0.000616225 | 0.00030285 | 2.73266E-05 |
| 1.2621E-06 | 0.080072736 | 0.000364157 | 1 | 0.752421573 | 0.893788228 | 0.966775418 | 0.5176915 |
| 5.74683E-06 | 0.153807533 | 0.001213872 | 0.752421573 | 1 | 0.855714616 | 0.720668166 | 0.33826616 |
| 2.43794E-06 | 0.106849782 | 0.000616225 | 0.893788228 | 0.855714616 | 1 | 0.860803975 | 0.436479836 |
| 9.99563E-07 | 0.072569757 | 0.00030285 | 0.966775418 | 0.720668166 | 0.860803975 | 1 | 0.543908895 |
| 5.69549E-08 | 0.016811448 | 2.73266E-05 | 0.5176915 | 0.33826616 | 0.436479836 | 0.543908895 | 1 |

Tabla B.18: Parte 2: Resultados de p-valores prueba *t* de Welch.
Fuente: Elaboración Propia, MS Excel 2013.

| anf_r10_hyb | anf_r10_back | ar_14 | ma_21 | ma_23 | arma_12_12 | arma_14_15 | garch_2_3 | garch_2_4 | garch_2_5 | garch_2_7 |
|-------------|--------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
| 1.28448E-16 | 1.65497E-17 | 6.7627E-38 | 9.87965E-69 | 3.00572E-64 | 1.0418E-26 | 1.10928E-22 | 3.76882E-37 | 1.34436E-27 | 1.02463E-27 | 2.45678E-27 |
| 5.27185E-16 | 1.61622E-17 | 8.00761E-43 | 3.18239E-73 | 1.10909E-67 | 7.97896E-31 | 3.42448E-24 | 2.04895E-41 | 6.87831E-32 | 2.81949E-31 | 2.66827E-31 |
| 0.104869822 | 0.047831522 | 1.25597E-18 | 8.62035E-50 | 3.69098E-45 | 3.63052E-08 | 2.83436E-05 | 5.93881E-18 | 6.26849E-09 | 3.85071E-09 | 9.64765E-09 |
| 0.561814096 | 0.352109736 | 1.57862E-15 | 5.17208E-46 | 1.45181E-41 | 6.1604E-06 | 0.001329271 | 6.00891E-15 | 1.33902E-06 | 7.77916E-07 | 1.87226E-06 |
| 0.328763458 | 0.184482633 | 1.43531E-16 | 2.81148E-47 | 8.93776E-43 | 1.09076E-06 | 0.000360899 | 5.83037E-16 | 2.19367E-07 | 1.29058E-07 | 3.1609E-07 |
| 0.558923488 | 0.350660378 | 1.78832E-15 | 6.39461E-46 | 1.75449E-41 | 6.46283E-06 | 0.001354191 | 6.74797E-15 | 1.41456E-06 | 8.21247E-07 | 1.97279E-06 |
| 0.376541907 | 0.216376148 | 2.17716E-16 | 4.40072E-47 | 1.39114E-42 | 1.54109E-06 | 0.000477939 | 8.79355E-16 | 3.13083E-07 | 1.83798E-07 | 4.493E-07 |
| 0.658064698 | 0.430650686 | 5.78868E-15 | 3.14797E-45 | 7.81015E-41 | 1.34658E-05 | 0.002247949 | 2.09058E-14 | 3.0865E-06 | 1.78456E-06 | 4.23302E-06 |
| 0.496796971 | 0.304418194 | 1.17217E-15 | 4.03214E-46 | 1.11352E-41 | 4.60189E-06 | 0.001033478 | 4.45108E-15 | 9.95809E-07 | 5.79046E-07 | 1.39474E-06 |
| 0.7320411 | 0.491991806 | 1.11755E-14 | 7.40078E-45 | 1.75642E-40 | 2.08242E-05 | 0.003074088 | 3.95414E-14 | 4.89037E-06 | 2.82318E-06 | 6.6498E-06 |
| 0.735273217 | 1 | 1.53008E-13 | 2.85161E-43 | 5.39070E-39 | 0.000101947 | 0.009098621 | 4.929E-13 | 2.66175E-05 | 1.53542E-05 | 3.49357E-05 |
| 1.53008E-13 | 9.68202E-13 | 1 | 3.15326E-42 | 5.35652E-38 | 0.000338436 | 0.021286053 | 2.96509E-12 | 9.49169E-05 | 5.49507E-05 | 0.00012184 |
| 2.85161E-43 | 3.15326E-42 | 3.04934E-14 | 1 | 4.07057E-12 | 0.000101933 | 9.02908E-07 | 0.939125674 | 0.000373606 | 0.000926757 | 0.000342423 |
| 5.39076E-39 | 5.35652E-38 | 4.07057E-12 | 0.5885013 | 1 | 1.33633E-28 | 2.11663E-32 | 2.5667E-14 | 2.83678E-27 | 4.3798E-26 | 2.71056E-27 |
| 0.000101947 | 0.000338436 | 0.000101933 | 1.33633E-28 | 3.09611E-25 | 1 | 0.233422596 | 0.000165017 | 0.733704061 | 0.585763401 | 0.764940323 |
| 0.009098621 | 0.021286053 | 9.02908E-07 | 2.11663E-32 | 8.14802E-29 | 0.233422596 | 1 | 1.70912E-06 | 0.128942065 | 0.089649705 | 0.140941958 |
| 4.929E-13 | 2.96509E-12 | 0.939125674 | 2.5667E-14 | 3.38315E-12 | 0.000165017 | 1.70912E-06 | 1 | 0.000574582 | 0.001366801 | 0.000527332 |
| 2.66175E-05 | 9.49169E-05 | 0.000373606 | 2.83678E-27 | 5.21146E-24 | 0.733704061 | 0.128942065 | 0.000574582 | 1 | 0.833629129 | 0.968608894 |
| 1.53542E-05 | 5.49507E-05 | 0.000926757 | 4.3798E-26 | 6.20103E-23 | 0.585763401 | 0.089649705 | 0.001366801 | 0.833629129 | 1 | 0.804340292 |
| 3.49357E-05 | 0.00012184 | 0.000342423 | 2.71056E-27 | 4.91048E-24 | 0.764940323 | 0.140941958 | 0.000527332 | 0.968608894 | 0.804340292 | 1 |
| 7.33528E-13 | 4.27563E-12 | 0.961037222 | 4.39994E-14 | 5.35866E-12 | 0.000172605 | 1.90556E-06 | 0.978748077 | 0.000590542 | 0.001386933 | 0.000542261 |
| 1.26842E-05 | 4.64562E-05 | 0.000848069 | 2.64281E-26 | 4.0048E-23 | 0.583343948 | 0.087081289 | 0.001259169 | 0.833255671 | 0.998919702 | 0.803721478 |
| 1.02315E-09 | 5.44177E-09 | 0.116322105 | 8.71178E-20 | 3.97895E-17 | 0.016918538 | 0.000478563 | 0.139600478 | 0.040472776 | 0.07013895 | 0.037681398 |
| 0.007471011 | 0.018175979 | 5.72712E-07 | 4.81883E-33 | 2.21828E-29 | 0.222231503 | 0.998892092 | 1.11723E-06 | 0.120143767 | 0.082650482 | 0.131854729 |
| 0.003040656 | 0.007903861 | 2.84826E-06 | 1.2045E-31 | 4.36113E-28 | 0.370629193 | 0.758953249 | 5.22666E-06 | 0.219395374 | 0.157143342 | 0.236857553 |
| 0.005173327 | 0.012937242 | 1.15006E-06 | 1.9314E-32 | 8.01131E-29 | 0.279044679 | 0.897332571 | 2.18426E-06 | 0.156886985 | 0.109778914 | 0.17093966 |
| 0.008253248 | 0.019954755 | 4.46813E-07 | 2.86338E-33 | 1.37584E-29 | 0.205729205 | 0.966450159 | 8.80678E-07 | 0.109712214 | 0.075033546 | 0.120716233 |
| 0.041207018 | 0.085214851 | 2.18005E-08 | 1.47805E-35 | 9.9486E-32 | 0.061394698 | 0.526922975 | 4.77003E-08 | 0.027720828 | 0.01780641 | 0.031534703 |

Tabla B.19: Parte 3: Resultados de p-valores prueba *t* de Welch.
Fuente: Elaboración Propia, MS Excel 2013.

| p-valor | anf_r05_hyb | anf_r05_back | anf_r06_hyb | anf_r06_back | anf_r07_hyb | anf_r07_back | anf_r08_hyb | anf_r08_back | anf_r09_hyb | anf_r09_back | anf_r10_hyb | anf_r10_back |
|-------------|-------------|--------------|-------------|--------------|-------------|--------------|-------------|--------------|-------------|--------------|-------------|--------------|
| 1 | 0.000219217 | 1.92816E-13 | 1.19416E-15 | 1.10119E-14 | 1.40683E-15 | 5.74467E-15 | 8.5608E-16 | 2.75971E-15 | 5.14423E-16 | | | |
| 0.000219217 | 1 | 1.80082E-11 | 6.49702E-15 | 7.73255E-13 | 9.9709E-15 | 8.10086E-14 | 5.99734E-15 | 3.55088E-14 | 2.73555E-15 | | | |
| 1.92816E-13 | 1.80082E-11 | 1 | 0.284428982 | 0.514892112 | 0.289856618 | 0.449568547 | 0.233420214 | 0.34169423 | 0.1957671 | | | |
| 1.19416E-15 | 6.49702E-15 | 0.284428982 | 1 | 0.680920549 | 0.994440822 | 0.754245127 | 0.893064394 | 0.914021323 | 0.812660332 | | | |
| 1.10119E-14 | 2.73255E-13 | 0.514892112 | 0.680920549 | 1 | 0.687376855 | 0.920355195 | 0.58938012 | 0.764428975 | 0.521256752 | | | |
| 1.40683E-15 | 9.9709E-15 | 0.289856618 | 0.994440822 | 0.687376855 | 1 | 0.760635183 | 0.888097519 | 0.919877349 | 0.808143065 | | | |
| 5.74467E-15 | 8.10086E-14 | 0.449568547 | 0.754245127 | 0.920355195 | 0.760635183 | 1 | 0.657388716 | 0.840025746 | 0.585172158 | | | |
| 8.5608E-16 | 5.99734E-15 | 0.233420214 | 0.893064394 | 0.58938012 | 0.888097519 | 0.657388716 | 1 | 0.810545232 | 0.919216063 | | | |
| 2.75971E-15 | 3.55088E-14 | 0.34169423 | 0.914021323 | 0.764428975 | 0.919877349 | 0.840025746 | 0.810545232 | 1 | 0.732958752 | | | |
| 5.14423E-16 | 2.73555E-15 | 0.1957671 | 0.812660332 | 0.521256752 | 0.808143065 | 0.585172158 | 0.919216063 | 0.732958752 | 1 | | | |
| 1.28448E-16 | 5.27185E-16 | 0.104869822 | 0.561814096 | 0.328763458 | 0.558923488 | 0.376541907 | 0.658064698 | 0.496796971 | 0.7320411 | | | |
| 1.65497E-17 | 1.61622E-17 | 0.047831522 | 0.352109736 | 0.184482633 | 0.350660378 | 0.216376148 | 0.430650686 | 0.304418194 | 0.491991806 | | | |
| 6.7627E-38 | 8.00761E-43 | 1.25597E-18 | 1.57862E-15 | 1.45331E-16 | 1.78832E-15 | 2.17716E-16 | 5.78868E-15 | 1.17217E-15 | 1.11755E-14 | | | |
| 9.87965E-69 | 3.18239E-73 | 8.62035E-50 | 5.17208E-46 | 2.81148E-47 | 6.39461E-46 | 4.40072E-47 | 3.14797E-45 | 4.03214E-46 | 7.40078E-45 | | | |
| 3.00572E-64 | 1.10909E-67 | 3.69098E-45 | 1.45181E-41 | 8.93776E-43 | 1.75449E-41 | 1.39114E-42 | 7.81015E-41 | 1.11352E-41 | 1.75642E-40 | | | |
| 1.0418E-26 | 7.97896E-31 | 3.63052E-08 | 6.1604E-06 | 1.09076E-06 | 6.46283E-06 | 1.54109E-06 | 1.34658E-05 | 4.60189E-06 | 2.08242E-05 | | | |
| 1.10928E-22 | 3.42448E-24 | 2.83436E-05 | 0.001329271 | 0.000360899 | 0.001354191 | 0.000477939 | 0.002247949 | 0.001033478 | 0.003074088 | | | |
| 3.76882E-37 | 2.04895E-41 | 5.93881E-18 | 6.00891E-15 | 5.83037E-16 | 6.74797E-15 | 8.79355E-16 | 2.09058E-14 | 4.45108E-15 | 3.95414E-14 | | | |
| 1.34436E-27 | 6.87831E-32 | 6.26849E-09 | 1.33902E-06 | 2.19367E-07 | 1.41456E-06 | 3.13083E-07 | 3.0865E-06 | 9.95809E-07 | 4.89037E-06 | | | |
| 1.02463E-27 | 2.81949E-31 | 3.85071E-09 | 7.77916E-07 | 1.29058E-07 | 8.21247E-07 | 1.83798E-07 | 1.78456E-06 | 5.79046E-07 | 2.82318E-06 | | | |
| 2.45678E-27 | 2.66827E-31 | 9.64765E-09 | 1.87226E-06 | 3.1609E-07 | 1.97279E-06 | 4.493E-07 | 4.23302E-06 | 1.39474E-06 | 6.6498E-06 | | | |
| 8.4171E-37 | 1.56987E-40 | 1.14038E-17 | 9.9469E-15 | 1.00838E-15 | 1.11082E-14 | 1.51461E-15 | 3.34487E-14 | 7.35978E-15 | 6.243E-14 | | | |
| 5.61637E-28 | 5.09607E-32 | 2.64944E-09 | 5.99494E-07 | 9.60801E-08 | 6.34746E-07 | 1.37477E-07 | 1.40551E-06 | 4.45395E-07 | 2.24469E-06 | | | |
| 1.32232E-33 | 3.87387E-39 | 2.1619E-14 | 1.71526E-11 | 1.82519E-12 | 1.90006E-11 | 2.73279E-12 | 5.46864E-11 | 1.26597E-11 | 9.96436E-11 | | | |
| 3.1833E-23 | 9.50341E-26 | 1.68992E-05 | 0.000978606 | 0.000248849 | 0.001000266 | 0.000333307 | 0.001711111 | 0.000754973 | 0.002378302 | | | |
| 6.73143E-24 | 1.97649E-26 | 4.83413E-06 | 0.000341831 | 8.09969E-05 | 0.000350982 | 0.000109673 | 0.000623704 | 0.000261708 | 0.000885589 | | | |
| 1.69569E-23 | 5.24408E-26 | 1.01284E-05 | 0.000636331 | 0.000157183 | 0.000651604 | 0.000211478 | 0.001132215 | 0.000489337 | 0.001587387 | | | |
| 3.5889E-23 | 9.09098E-26 | 1.91465E-05 | 0.001095036 | 0.000279867 | 0.00118881 | 0.00037458 | 0.001908286 | 0.000845275 | 0.002647733 | | | |
| 1.39883E-21 | 1.88165E-23 | 0.000235813 | 0.007869665 | 0.002421614 | 0.007962628 | 0.003142582 | 0.012377229 | 0.006218373 | 0.016293311 | | | |

Tabla B.20: Resultados de p-valores prueba *MCS*.
Fuente: Elaboración Propia, Matlab 2016a, MS Excel 2013.

| Abreviatura | Correlativo | | Ranking | p-valor |
|------------------------|-------------|------------------|-----------------|----------|
| anfis_scr05_suge_hyb | 1 | Excluidos | 14 | 0 |
| anfis_scr05_suge_back | 2 | | 15 | 0 |
| anfis_scr06_suge_hyb | 3 | | 18 | 0 |
| anfis_scr06_suge_back | 4 | | 13 | 0 |
| anfis_scr07_suge_hyb | 5 | | 22 | 0 |
| anfis_scr07_suge_back | 6 | | 24 | 0 |
| anfis_scr08_suge_hyb | 7 | | 19 | 0 |
| anfis_scr08_suge_back | 8 | | 21 | 0 |
| anfis_scr09_suge_hyb | 9 | | 23 | 0 |
| anfis_scr09_suge_back | 10 | | 20 | 0 |
| anfis_scr10_suge_hyb | 11 | | 16 | 0 |
| anfis_scr10_suge_back | 12 | | 28 | 0 |
| ar_14 | 13 | | 27 | 0 |
| ma_21 | 14 | | 29 | 0 |
| ma_23 | 15 | | 17 | 0 |
| arma_12_12 | 16 | | 26 | 0 |
| arma_14_15 | 17 | | 11 | 0 |
| garch_2_3 | 18 | | 25 | 0 |
| garch_2_4 | 19 | | 5 | 0 |
| garch_2_5 | 20 | | 7 | 0 |
| garch_2_7 | 21 | | 9 | 0 |
| garch_2_8 | 22 | | 12 | 0 |
| garch_3_2 | 23 | | 10 | 0 |
| ann_hn10_ratio_75_20_5 | 24 | | 3 | 0 |
| ann_hn15_ratio_75_20_5 | 25 | | 8 | 0 |
| ann_hn20_ratio_75_20_5 | 26 | | 4 | 0 |
| ann_hn10_ratio_80_15_5 | 27 | | 6 | 0 |
| ann_hn15_ratio_80_15_5 | 28 | | 2 | 0.043 |
| ann_hn20_ratio_80_15_5 | 29 | | Incluido | 1 |

Tabla B.21: Resultados de p-valores prueba *MCS* para modelo *anfis_scr10_suge_back* .
Fuente: Elaboración Propia, Matlab 2016a, MS Excel 2013.

| Abreviatura | Correlativo | | Ranking | p-valor |
|------------------------------|-------------|------------------|----------|----------|
| <i>anfis_scr10_suge_back</i> | 1 | Excluidos | 3 | 0 |
| ar_14 | 2 | | 4 | 0 |
| ma_21 | 3 | | 7 | 0 |
| ma_23 | 4 | | 2 | 0 |
| arma_12_12 | 5 | | 11 | 0 |
| arma_14_15 | 6 | | 13 | 0 |
| garch_2_3 | 7 | | 12 | 0 |
| garch_2_4 | 8 | | 10 | 0 |
| garch_2_5 | 9 | | 9 | 0 |
| garch_2_7 | 10 | | 8 | 0 |
| garch_2_8 | 11 | | 5 | 0 |
| garch_3_2 | 12 | | 15 | 0 |
| ann_hn10_ratio_75_20_5 | 13 | | 16 | 0 |
| ann_hn15_ratio_75_20_5 | 14 | | 17 | 0 |
| ann_hn20_ratio_75_20_5 | 15 | | 6 | 0.001 |
| ann_hn10_ratio_80_15_5 | 16 | | 14 | 0.001 |
| ann_hn15_ratio_80_15_5 | 17 | | 18 | 0.001 |
| ann_hn20_ratio_80_15_5 | 18 | Incluido | 1 | 1 |

Tabla B.22: Resultados de p-valores prueba *MCS* para modelo *anfis_scr06_suge_hyb*.**Fuente:** Elaboración Propia, Matlab 2016a, MS Excel 2013.

| Abreviatura | Correlativo | Método R | Ranking | p-valor | Método SQ | Ranking | p-valor |
|------------------------|-------------|------------------|----------|----------|------------------|----------|--------------|
| anfis_scr06_suge_hyb | 1 | Excluidos | 12 | 0 | Excluidos | 12 | 0 |
| anfis_scr06_suge_back | 2 | | 13 | 0 | | 13 | 0 |
| anfis_scr07_suge_hyb | 3 | | 16 | 0 | | 16 | 0 |
| anfis_scr07_suge_back | 4 | | 20 | 0 | | 20 | 0 |
| anfis_scr08_suge_hyb | 5 | | 11 | 0 | | 11 | 0 |
| anfis_scr08_suge_back | 6 | | 22 | 0 | | 22 | 0 |
| anfis_scr09_suge_hyb | 7 | | 21 | 0 | | 21 | 0 |
| anfis_scr09_suge_back | 8 | | 17 | 0 | | 17 | 0 |
| anfis_scr10_suge_hyb | 9 | | 19 | 0 | | 19 | 0 |
| anfis_scr10_suge_back | 10 | | 18 | 0 | | 18 | 0 |
| ar_14 | 11 | | 14 | 0 | | 14 | 0 |
| ma_21 | 12 | | 26 | 0 | | 26 | 0 |
| ma_23 | 13 | | 25 | 0 | | 25 | 0 |
| arma_12_12 | 14 | | 24 | 0 | | 24 | 0 |
| arma_14_15 | 15 | | 27 | 0 | | 27 | 0 |
| garch_2_3 | 16 | | 23 | 0 | | 23 | 0 |
| garch_2_4 | 17 | | 15 | 0 | | 15 | 0 |
| garch_2_5 | 18 | | 10 | 0 | | 10 | 0.007 |
| garch_2_7 | 19 | | 9 | 0 | | 9 | 0.021 |
| garch_2_8 | 20 | | 8 | 0.022 | Incluidos | 8 | 0.069 |
| garch_3_2 | 21 | | 6 | 0.022 | | 6 | 0.069 |
| ann_hn10_ratio_75_20_5 | 22 | | 2 | 0.022 | | 2 | 0.069 |
| ann_hn15_ratio_75_20_5 | 23 | | 7 | 0.022 | | 7 | 0.069 |
| ann_hn20_ratio_75_20_5 | 24 | | 4 | 0.022 | | 4 | 0.069 |
| ann_hn10_ratio_80_15_5 | 25 | | 5 | 0.022 | | 5 | 0.069 |
| ann_hn15_ratio_80_15_5 | 26 | | 3 | 0.022 | | 3 | 0.069 |
| ann_hn20_ratio_80_15_5 | 27 | Incluido | 1 | 1 | | 1 | 1 |

Tabla B.23: Resultados de p-valores prueba t de Welch para Análisis de Sensibilidad del modelo **anfis_scr06_suge_hyb**.
Fuente: Elaboración Propia, MS Excel 2013.

| anfis_scr06_suge_hyb | 50 % (260 datos) | 60 % (313 datos) | 70 % (365 datos) | 80 % (417 datos) | 90 % (468 datos) | 92.13 % (480 datos) | 95 % (495 datos) |
|-----------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|----------------------------|-------------------------|
| 50 % (260 datos) | 1 | 0.031599222 | 0.0015628 | 6.68968E-06 | 7.17989E-07 | 4.2052E-09 | 2.53767E-09 |
| 60 % (313 datos) | 1 | 1 | 0.306122055 | 0.013299524 | 0.003207702 | 6.49602E-05 | 4.23511E-05 |
| 70 % (365 datos) | | | 1 | 0.129080422 | 0.04573205 | 0.001773312 | 0.001207043 |
| 80 % (417 datos) | | | | 1 | 0.656744569 | 0.105529291 | 0.081231053 |
| 90 % (468 datos) | | | | | 1 | 0.219798313 | 0.173763923 |
| 92.13 % (480 datos) | | | | | | 1 | 0.886523166 |
| 95 % (495 datos) | | | | | | | 1 |

C | Pronóstico de Carga Mensual 2017

Tabla C.1: Pronóstico de Consumo Energético Para Julio 2016-2017 mediante modelo **anfis_scr06_suge_hyb**.

| Año 2016 | | Año 2017 | |
|-----------------|-------------|-----------------|-------------|
| Enero | 9.102587 | Enero | 8.119330245 |
| Febrero | 8.247054 | Febrero | 7.052715442 |
| Marzo | 7.985055 | Marzo | 8.230496164 |
| Abril | 7.460904 | Abril | 7.060141304 |
| Mayo | 7.598107 | Mayo | 8.142232138 |
| Junio | 7.970408 | Junio | 8.288807105 |
| Julio | 8.505602853 | Julio | 8.447880858 |
| Agosto | 7.831097651 | Agosto | 8.141368218 |
| Septiembre | 7.202683622 | Septiembre | 7.008142353 |
| Octubre | 7.97753461 | Octubre | 7.947173997 |
| Noviembre | 8.18557135 | Noviembre | 8.115568421 |
| Diciembre | 9.065923693 | Diciembre | 9.163887696 |

D | Documentación - Modelo ANFIS

D.1. Código Modelo Anfis

```
1 load thesis.mat
2 z=thesis(:,3);
3
4 for t=16:522,
5     data2(t-15,:)= [ z(t-14) z(t-13) z(t-12) z(t-11) z(t-10) z(t-9)
6         z(t-8) z(t-7) z(t-6) z(t-5) z(t-4) z(t-3) z(t-2) z(t-1) ];
7     zout(t-15,:)= [ z(t) ];
8 end
9 datos = [data2 zout];
10
11 train_data=datos(1:365,:);
12 check_data=datos(366:end,:);
13
14
15 fismat = genfis2(data2,zout,0.6);
16
17 train_opt=[100 0 0.01 0.9 1.1];
18
19 [fismat1,error1,ss,fismat2,error2] = ...
20     anfis(train_data,fismat,train_opt,[1 1 1 1],check_data ,1);
21
22
23 figure(1)
```

```
24 plot([error1 error2])
25 hold on;
26 plot([error1 error2], 'o')
27 hold off;
28 legend('error1', 'error2')
29 xlabel('Epochs')
30 ylabel('RMSE (Root Mean Squared Error)')
31 title('Error Curves')
32
33
34 figure(2)
35 index=1:507;
36 index=index';
37 anfis_output = evalfis(data2, fismat2);
38 plot(index,zout, 'b'); hold on;
39 plot(index,anfis_output, 'r'); hold off;
```

D.2. Código para Pronóstico 2017

```
1 pronostico=[];
2 input=thesis(509:522,3)';
3 last=thesis(522,2);
4 genox=0;
5 for i=1:18,
6     resultado=evalfis(input, fismat2);
7     genox=last+resultado
8     pronostico=[pronostico genox];
9     input=[input(2:14) resultado]
10 end
```

