

*Modelos de pronóstico del precio del crudo: Un
acercamiento desde las redes neuronales artificiales*

NICOLÁS ANDRADE BURGOS

ESTADÍSTICO

CÓDIGO: 1010160436



UNIVERSIDAD NACIONAL DE COLOMBIA

FACULTAD DE CIENCIAS ECONÓMICAS

ESCUELA DE ECONOMÍA

BOGOTÁ, D.C.

FEBRERO DE 2016

Modelos de pronóstico del precio del crudo: Un acercamiento desde las redes neuronales artificiales

NICOLÁS ANDRADE BURGOS

ESTADÍSTICO

CÓDIGO: 1010160436

DISERTACIÓN PRESENTADA PARA OPTAR AL TÍTULO DE
MAGISTER EN CIENCIAS ECONÓMICAS

DIRECTOR

MUNIR ANDRÉS JALIL BARNEY, PH.D.

DOCTOR EN ECONOMÍA



UNIVERSIDAD NACIONAL DE COLOMBIA

FACULTAD DE CIENCIAS ECONÓMICAS

ESCUELA DE ECONOMÍA

BOGOTÁ, D.C.

FEBRERO DE 2016

Título en español

Modelos de pronóstico del precio del crudo: Un acercamiento desde las redes neuronales artificiales

Title in English

Models for oil price forecasting: An approach from artificial neural networks

Resumen: Los modelos enfocados en la predicción del precio de mercado del crudo WTI han tomado gran importancia en el contexto económico mundial, sobretodo en momentos recientes donde la caída extrema de los precios han llevado a multiples naciones a ver recortados significativamente sus ingresos derivados de su explotación. Los acercamientos tradicionales de series de tiempo donde se proponen los modelos ARIMA, ARCH y GARCH, modelos financieros y modelos estructurales son algunos de los enfoques más utilizados en la literatura existente, sin embargo la no linealidad de la serie así como problemas de alta volatilidad y autocorrelación serial de los residuales de los distintos modelos ajustados han introducido en la escena la utilización de las redes neuronales artificiales autorregresivas (ARNN). En el presente trabajo se propone evaluar el desempeño de pronóstico de una arquitectura óptima ARNN en comparación con modelos de series de tiempo clásicos entre los que se incluyen los modelos ARCH y GARCH además de una red neuronal artificial cuyas entradas incluyen los índices *DXY* y *S&P500* para las frecuencias mensual, anual, diaria y semanal del precio de mercado del crudo WTI. La estimación y selección de las distintas arquitecturas probadas para las ARNN, en las distintas frecuencias de trabajo, fueron realizadas a través del paquete *ARNN* del lenguaje *R*; adicionalmente para la medición del desempeño de los distintos modelos en el conjunto de validación fueron utilizadas distintas medidas de error de pronóstico así como criterios de información. Los resultados prácticos sugieren que las ARNN ajustadas para las series de precios de mercado mensuales, diarios y semanales revelan un mejor desempeño en cuanto al pronóstico de valores futuros de cada serie.

Abstract: The models aimed to predict the oil spot price WTI have taken great importance in the world economy, especially in recent times where extreme falling prices have led many nations to see significantly cut its revenue derived from their exploitation. Traditional approaches of time series where ARIMA, ARCH and GARCH models, financial models and structural models proposed, are some of the most used in the literature approaches, however the nonlinearity of the series as well as high volatility and serial autocorrelation problems of residuals of different adjusted models have been introduced into the scene the artificial autoregressive neural networks (ARNN). The present study intends to evaluate the forecasting performance of optimal architecture ARNN compared to classic time series models containing ARCH and GARCH in addition to an artificial neural network whose inputs include *DXY* and *S&P500* indices for monthly, annual, daily and weekly observations for oil spot price WTI. The estimation and selection of different architectures tested for ARNN in the different working frequencies were made through the package *ARNN* of *R* language; to measuring the performance of the different models in the validation set they were used different forecasting error measures and information criteria. The practical results suggest that ARNN adjusted for monthly, daily and weekly have better performance in terms of forecasting future values of each series.

Palabras clave: Series de Tiempo, redes neuronales artificiales autorregresivas, arquitectura, medidas de error de pronóstico, lenguaje *R*, precio de mercado del crudo, WTI, pronóstico

Keywords: Time Series, artificial autoregressive neural networks, architecture, forecasting error measures, *R* language, oil spot price, WTI, forecast

Nota de aceptación

Trabajo Final

Jurado
Evaluador 1

Jurado
Evaluador 2

Director
Munir Andrés Jalil Barney

Bogotá, D.C., Febrero 16 de 2015

Dedicado a

Este trabajo está dedicado a dos personas que me han enseñado las lecciones mas importantes de mi vida. A la memoria de mi padre que me dejó la sed por el conocimiento y el potencial para saciarla; y a mi hijo Joaquín quien me ha inspirado a crecer y quien siempre será una fuente continua de orgullo y felicidad.

Agradecimientos

A mi familia quienes estuvieron a mi lado en momentos de incertidumbre durante este proceso. Además de un agradecimiento especial al profesor Munir Jail por haberme dado la oportunidad de seguir aprendiendo y dirigirme a lo largo de este trabajo.

Índice general

Índice general	I
Índice de tablas	IV
Índice de figuras	VI
Introducción	IX
1. Marco Teórico	1
1.1. Literatura existente en el pronóstico de precios del crudo	1
1.1.1. Modelos financieros	1
1.1.2. Modelos estructurales	3
2. Las Redes Neuronales Artificiales	6
2.1. Definición y Descripción	6
2.1.1. Redes neuronales biológicas y redes neuronales artificiales	6
2.1.2. Arquitectura	8
2.2. Redes Neuronales Autorregresivas	9
2.2.1. Aspectos del proceso de estimación	10
2.2.2. Selección de Número Máximo de Nodos en la Capa Oculta	11
2.3. Aplicación de Modelos ANN en el pronóstico del precio del crudo	12
3. Enfoque metodológico	14
3.1. Metodología y diagnóstico	14
3.1.1. División del conjunto de información	14
3.1.2. Selección de arquitectura ARNN por frecuencia de trabajo	15
3.1.3. Desempeño por horizonte de pronóstico	15
3.2. Los Datos	16

3.3. Herramienta de Procesamiento	18
3.3.1. El paquete ARNN	19
4. Resultados	22
4.1. Definición de arquitecturas, estimación e identificación de modelos de contraste por frecuencia	22
4.1.1. Definición de arquitecturas ARNN para cada frecuencia de estudio .	22
4.1.2. Ajuste de las ARNN seleccionadas	23
4.1.3. Ajuste de los modelos de contraste ARIMA y GARCH	25
4.1.4. Ajuste ANN de contraste	26
4.2. Comparación de Pronósticos	26
5. Conclusiones y trabajo futuro	29
5.1. Conclusiones	29
5.2. Trabajo futuro	30
A. Tablas de Resultados ARNN	31
A.1. Estadísticos para selección de arquitecturas ARNN	31
B. Tablas de Resultados ANN	35
B.1. Estadísticos para selección de arquitecturas ANN: Precio de mercado del crudo e índices <i>DXY</i> y <i>S&P500</i>	35
C. Estimación de parámetros y caracterización de modelos de contraste	39
C.1. Caracterización de arquitecturas ARNN seleccionadas	39
D. Análisis de estadísticos en la identificación de los modelos de contraste	42
D.1. Identificación de modelos de contraste en la serie mensual	42
D.1.1. Análisis de Residuales y ajuste del modelo GARCH	44
D.2. Identificación de modelos de contraste en la serie anual	46
D.2.1. Análisis de Residuales y ajuste del modelo GARCH	48
D.3. Identificación de modelos de contraste en la serie diaria	48
D.3.1. Análisis de Residuales y ajuste del modelo GARCH	51
D.4. Identificación de modelos de contraste en la serie semanal	53
D.4.1. Análisis de Residuales y ajuste del modelo GARCH	55
E. Desarrollos Teóricos Complementarios	63
E.1. Pronostico y Medidas de Error de Pronóstico	63

E.2. Acercamiento de Box y Jenkins	65
E.2.1. ARIMA	65
E.2.2. Modelando los Residuales	67
F. Código R	69
F.1. Fuentes de Información	69
F.2. Implementación ARNN	70
F.3. Implementación de modelos ARIMA y GARCH	77
Bibliografía	81

Índice de tablas

4.1. Arquitecturas ARNN seleccionadas por frecuencia de trabajo	23
4.2. Parámetros estimados para los modelos RW, ARIMA y GARCH	26
4.3. Arquitecturas ANN seleccionadas por frecuencia de trabajo	26
4.4. Medidas de evaluación de pronósticos bajo rolling (Serie Mensual)	27
4.5. Medidas de evaluación de pronósticos bajo rolling (Serie Anual)	27
4.6. Medidas de evaluación de pronósticos bajo rolling (Serie Diaria)	27
4.7. Medidas de evaluación de pronósticos bajo rolling (Serie Semanal)	27
A.1. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie mensual de precios de mercado del crudo WTI	31
A.2. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie mensual de precios de mercado del crudo WTI	32
A.3. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie anual de precios de mercado del crudo WTI	32
A.4. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie anual de precios de mercado del crudo WTI	32
A.5. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie diaria de precios de mercado del crudo WTI	33
A.6. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie diaria de precios de mercado del crudo WTI	33
A.7. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie semanal de precios de mercado del crudo WTI	34
A.8. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie semanal de precios de mercado del crudo WTI	34
B.1. Resultados en el conjunto de entrenamiento y validación de diferentes ar- quitecturas ANN: Precio de mercado del crudo e índices <i>DXY</i> y <i>S&P500</i> . Serie mensual de precios de mercado del crudo WTI	35

B.2. Resultados en el conjunto de entrenamiento y validación de diferentes arquitecturas ANN: Precio de mercado del crudo e índices <i>DEXY</i> y <i>S&P500</i> . Serie anual de precios de mercado del crudo WTI	36
B.3. Resultados en el conjunto de entrenamiento y validación de diferentes arquitecturas ANN: Precio de mercado del crudo e índices <i>DEXY</i> y <i>S&P500</i> . Serie semanal de precios de mercado del crudo WTI	37
B.4. Resultados en el conjunto de entrenamiento y validación de diferentes arquitecturas ANN: Precio de mercado del crudo e índices <i>DEXY</i> y <i>S&P500</i> . Serie diaria de precios de mercado del crudo WTI	38
D.1. Estadístico AIC para diferentes ordenes p y q (Serie Mensual WTI)	44
D.2. Estadístico AIC para diferentes ordenes p y q (Serie Diaria WTI)	48
D.3. Estadístico AIC para diferentes ordenes p y q (Serie Diaria WTI)	51
D.4. Estadístico AIC para diferentes ordenes p y q (Serie Semanal WTI)	55
E.1. Resultados de las funciones de autocorrelación y autocorrelación parcial . . .	66

Índice de figuras

1. Precio de mercado del petróleo WTI de Enero 1986 a Febrero 2015 (promedios mensuales)	XI
2.1. Red Neuronal Artificial Simple	7
2.2. Representación de una red neuronal alimentada hacia adelante con una única superficie escondida	8
2.3. Arquitectura de una red neuronal autorregresiva.	10
3.1. Subdivisiones del período de estudio de una red neuronal.	15
3.2. Esquema Rolling	16
3.3. Precio de mercado del petróleo WTI de 1986 al 2014 (Promedios Anuales) .	17
3.4. Precio de mercado del petróleo WTI del 1 de Enero 1986 al 9 de Marzo de 2014 (Serie Diaria)	18
3.5. Precio de mercado del petróleo WTI de la primera semana de Enero 1986 a la primera semana de Marzo del 2014 (Promedios Semanales)	19
4.1. Desempeño de los pronósticos de la ARNN (Serie Mensual WTI)	23
4.2. Desempeño de los pronósticos de la ARNN (Serie Anual WTI)	24
4.3. Desempeño de los pronósticos de la ARNN (Serie Diaria WTI)	24
4.4. Desempeño de los pronósticos de la ARNN (Serie Semanal WTI)	24
D.1. Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Mensual WTI)	42
D.2. Logaritmo de la serie de precios mensuales del crudo WTI.	43
D.3. Log-retornos de la serie de precios mensuales del crudo WTI.	43
D.4. Funciones ACF y PACF de la serie de precios mensuales del crudo WTI en el conjunto de entrenamiento.	44
D.5. Residuales del modelo ajustado para la serie mensual de precios del crudo WTI	45

D.6. ACF y PACF para los residuales del modelo ajustado (Serie Mensual WTI)	45
D.7. ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Mensual WTI)	46
D.8. Test de McLeod.Li para los residuales del modelo ajustado (Serie Mensual WTI)	46
D.9. QQ - Plot de los residuales correspondientes al modelo ajustado (Serie Mensual WTI)	47
D.10.ACF y PACF para los residuales del modelo GARCH(1,1) ajustado (Serie Mensual WTI)	47
D.11.ACF y PACF para los residuales al cuadrado del modelo GARCH(1,1) ajustado (Serie Mensual WTI)	48
D.12.Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Anual WTI)	49
D.13.Logaritmo de la serie de precios anuales del crudo WTI.	49
D.14.Log-retornos de la serie de precios anuales del crudo WTI.	50
D.15.Funciones ACF y PACF de la serie de precios anuales del crudo WTI en el conjunto de entrenamiento.	50
D.16.Residuales del modelo ajustado para la serie mensual de precios del crudo WTI	51
D.17.ACF y PACF para los residuales del modelo ajustado (Serie Anual WTI)	51
D.18.ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Anual WTI)	52
D.19.Test de McLeod.Li para los residuales del modelo ajustado (Serie Anual WTI)	52
D.20.QQ - Plot de los residuales correspondientes al modelo ajustado (Serie Anual WTI)	53
D.21.Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Diaria WTI)	53
D.22.Logaritmo de la serie de precios diaria del crudo WTI.	54
D.23.Log-retornos de la serie de precios diarios del crudo WTI.	54
D.24.Funciones ACF y PACF de la serie de precios diarios del crudo WTI en el conjunto de entrenamiento.	55
D.25.Residuales del modelo ajustado para la serie diaria de precios del crudo WTI	55
D.26.ACF y PACF para los residuales del modelo ajustado (Serie Diaria WTI)	56
D.27.ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Diaria WTI)	56
D.28.Test de McLeod.Li para los residuales del modelo ajustado (Serie Diaria WTI)	57
D.29.QQ - Plot de los residuales correspondientes al modelo ajustado (Serie Diaria WTI)	57

D.30.ACF y PACF para los residuales del modelo GARCH(1,1) ajustado (Serie Diaria WTI)	58
D.31.ACF y PACF para los residuales al cuadrado del modelo GARCH(1,1) ajustado (Serie Diaria WTI)	58
D.32.Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Semanal WTI)	59
D.33.Logaritmo de la serie de precios semanal del crudo WTI.	59
D.34.Log-retornos de la serie de precios semanales del crudo WTI.	59
D.35.Funciones ACF y PACF de la serie de precios semanales del crudo WTI en el conjunto de entrenamiento.	60
D.36.Residuales del modelo ajustado para la serie semanal de precios del crudo WTI	60
D.37.ACF y PACF para los residuales del modelo ajustado (Serie Semanal WTI)	60
D.38.ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Semanal WTI)	61
D.39.Test de McLeod.Li para los residuales del modelo ajustado (Serie Semanal WTI)	61
D.40.QQ - Plot de los residuales correspondientes al modelo ajustado (Serie Semanal WTI)	61
D.41.ACF y PACF para los residuales del modelo GARCH(3,1) ajustado (Serie Semanal WTI)	62
D.42.ACF y PACF para los residuales al cuadrado del modelo GARCH(3,1) ajustado (Serie Semanal WTI)	62

Introducción

El petróleo es el bien básico más negociado en todo el mundo, no sólo en términos de volumen sino también de montos de dinero. Su consumo por lo general se da en lugares diferentes a los de su extracción, destacándose Estados Unidos como el mayor consumidor bruto y neto de petróleo en todo el mundo; a pesar de ello, la región con mayor importación neta es la asiática. Usualmente, los precios del petróleo son determinados por la interacción entre las fuerzas de oferta y demanda, sin embargo, presentan alta volatilidad especialmente en periodos de inestabilidad política y guerras en los países del medio oriente, crecimiento o recesión económica y las decisiones sobre producción de la organización de países exportadores de petróleo (OPEC). Los factores más influyentes en el precio del petróleo son los costos de extracción, transporte, transformación y manejo de inventarios, las expectativas de los agentes, las barreras o problemas geopolíticos en el medio oriente y las decisiones de producción de la organización de la OPEC.

Las exportaciones e importaciones de petróleo juegan un papel importante en las cuentas de la balanza de pagos de los países, puesto que en el momento en el que los ingresos por compra y venta de petróleo entran al mercado cambiario, la cuenta corriente se ve directamente afectada. Por esta razón se hace cada vez más pertinente el estudio de modelos que permitan pronosticar el comportamiento del precio del petróleo de tal forma que se constituyan en una guía que oriente planeación macroeconómica de los diferentes países y a la vez oriente la estrategia a seguir por los inversionistas participantes en el mercado.

Diversos modelos matemáticos han sido publicados para el estudio del comportamiento del mercado del petróleo. Zamani (2004) presenta un modelo autorregresivo para predecir el precio spot del petróleo WTI en función del nivel de inventarios de los países miembros de la OCDE (Organización para la Cooperación y el Desarrollo Económico), la demanda de los países no-OCDE y el nivel de producción de la OPEC; los resultados del pronóstico son alentadores y plantean su utilidad para los diseñadores de política económica y la OPEC en la determinación del nivel de producción. Robles-Agudo y Vásquez-Román (2008) proponen un modelo matemático para optimizar la planeación de la producción de gas y petróleo en varios pozos obteniendo resultados satisfactorios al poder involucrar diversas restricciones de presión en tuberías y de demanda. Unas de las técnicas matemáticas utilizadas para abordar el estudio del comportamiento de los mercados han sido los modelos multivariantes y univariantes, pero presentan deficiencias cuando se trata de realizar predicciones fuera de la muestra (Meese y Roesse, 1991). En un trabajo más reciente, Ghoshray y Johnson (2010) aplicaron modelos univariados al pronóstico de precios del petróleo, el gas y el carbón detectando roturas estructurales en las tendencias lo que su-

giere el efecto de estos cambios de la economía global en el comportamiento de los precios de los energéticos en el largo plazo.

Un elemento adverso para el mercado del petróleo con su respectiva influencia en el precio lo constituye la creciente preocupación mundial por el calentamiento global. En un trabajo reciente, Espíndola y Valderrama (2012) analizan el concepto de huella de carbono y su relación con los gases de efecto invernadero y el calentamiento global, enfatizando en la necesidad de avanzar en la difusión de bases conceptuales y adoptar una estrategia para el logro de un crecimiento global sostenible y la sustentabilidad de las organizaciones.

Estudios posteriores han demostrado que la presencia de dinámicas no lineales hacen necesario el empleo de modelos más sofisticados. En este sentido, Kisswani y Nusair (2013) no encontraron evidencia de estacionariedad en las series de precios del petróleo (Brent, Dubai y WTI) lo cual es atribuido a la presencia de no linealidades en el comportamiento del precio del petróleo. Algunas posibles causas de estas no linealidades pueden ser las barreras en el transporte y costos de transacción en su comercio, la existencia de cambios estructurales y la presencia de agentes heterogéneos en este mercado. Los resultados sugieren que los modelos lineales pueden no ser los más apropiados para el modelamiento del precio del petróleo.

Ante el comportamiento no lineal de este tipo de mercados, en la última década se ha incrementado el uso de nuevos métodos basados en redes neuronales artificiales. Su principal característica de permitir establecer relaciones lineales y no lineales entre las entradas y salidas de un sistema ha hecho posible mostrar su aplicabilidad en mercados de alta volatilidad, cuyas variables obedecen a comportamientos no lineales en diversas áreas de la ingeniería y en los mercados energéticos (García et al., 2008; Villada et al., 2011). En la literatura científica se encuentran publicaciones como Haidar et al. (2008), Kuo et al. (2009) y Alizadeh y Mafinezhad (2010); en los cuales se resalta la superioridad en el desempeño de las redes neuronales con respecto a los métodos econométricos y otros modelos lineales. Adicionalmente, se encuentran trabajos que combinan redes neuronales con la lógica difusa. En este sentido, un método híbrido de pronóstico que utiliza redes neuro-difusas e incluye el efecto de cinco indicadores económicos fue propuesto por Azadeh et al. (2012). El modelo mostró ser robusto ante inconsistencias, ruido y no linealidades en los datos; logrando mejor capacidad de generalización que los modelos convencionales.

La Figura 1 muestra el comportamiento del precio de mercado del crudo WTI en el período comprendido entre Enero de 1986 y Febrero del 2015. Inspeccionando esta gráfica es fácil verificar que los períodos de alta volatilidad del crudo se encuentran relacionados con eventos socioeconómicos y geopolíticos específicos. Las pequeñas fluctuaciones en el precio en los años 1986-1990 son el resultado de los repetidos ajustes a las cuotas de producción establecidos por la OPEC. Adicionalmente el fuerte incremento en 1990 fue ocasionado por la guerra del golfo y la caída pronunciada en el precio en el período 1997-1998 coincide con un pronunciado estancamiento de crecimiento económico Asiático. La reducción en los niveles de producción de la OPEC en 1999 se refleja inmediatamente con un alza contundente en los precios. Finalmente, la caída del precio en el 2001 está directamente relacionada con los ataques terroristas del 11 de septiembre así como el constante repunte en el período 2002-2008 son nuevamente justificadas por la caída en las cuotas de producción de la OPEC y capacidad de las reservas. Nuevamente en el año 2009 la serie sufrió un choque importante explicado en mayor medida por la crisis financiera ocurrida en los Estados Unidos, lo cual produjo una caída sin precedentes ya que el precio de mercado pasó de \$143 a \$43 dólares por barril, sin embargo la disminución continua de

las cuotas de producción de la OPEC generó aun aumento estable donde en promedio la serie se movía en torno a un nivel de \$100 dólares.




FIGURA 1. Precio de mercado del petróleo WTI de Enero 1986 a Febrero 2015 (promedios mensuales)

Acercándonos hacia períodos resientes, después de un período de regularidad la serie vuelve nuevamente a revelar su alta volatilidad, de tal manera que, en el cuarto trimestre del 2014 se presentan bajas importantes con una tendencia marcada a la caída del precio, llegando a niveles de \$47 dólares a comienzos del 2015; es frecuente que analistas a nivel mundial asocien este fuerte movimiento al conflicto bélico entre Ucrania y Rusia además de la situación económica y política que atraviesan países como Venezuela. Sin embargo existen otras vertientes que aseguran una relación directa de estos movimientos con el aumento de las reservas americanas de crudo así como a la incorporación de nuevas técnicas de extracción como el Fracking¹.

Todo lo anterior, ha recientemente atraído la atención de muchos investigadores. El precio del crudo se ha convertido en parte importante de los procesos de decisión para el desarrollo y planes de producción de las industrias, así como un elemento esencial en la planeación de corto y largo plazo de las políticas de exportaciones y reservas nacionales de los gobiernos. De esta forma, el pronóstico acertado del precio del crudo se ha convertido en un insumo crítico para tomar buenas decisiones tanto en la industria como en el gobierno (Plourde & Watkins, 1998). El pronóstico del precio del crudo es un área de investigación activa en la literatura, la cual está realizando grandes esfuerzos en el desarrollo de un sistema eficiente que pueda predecir su comportamiento. Continuando con la idea anterior, es importante proveer a los formuladores de política pronósticos acertados del precio del crudo que puedan ser utilizados en la construcción de una planeación económica nacional

¹El fracking consiste en un procedimiento que genera fracturas en rocas y formaciones de rocas mediante la inyección de fluidos en las grietas, las fisuras permiten que el crudo fluya fuera de la formación geológica permitiendo su extracción de manera más sencilla

e internacional para de esta manera reducir el descalabro que impone típicamente los cambios abruptos del precio.

Dado que gran parte de los documentos consultados se centran en el pronóstico del precio de mercado del petróleo para horizonte anuales, que ningún trabajo sugiere la mejor arquitectura de la ANN que realiza pronósticos de mayor acierto y que en muy pocos trabajos se ha medido el desempeño de las redes para frecuencias como la diaria y la semanal; este trabajo propone revisar el desempeño de un modelo basado en redes neuronales artificiales autorregresivas (ANNR) para el pronóstico del precio del petróleo WTI con información observada en diferentes frecuencias: diaria, semanal, mensual y anual. Se prueban diferentes arquitecturas de redes neuronales utilizando la serie de precios de mercado del crudo WTI y se comparan las mejores estructuras identificadas, basadas en diferentes medidas de error de pronóstico, con respecto a una caminata aleatoria RW, un modelo ARIMA, un modelo GARCH y una ANN donde se seleccionan como entradas la serie de precios de mercado del crudo más los índices *DXY*² y *S&P500*³ por cada frecuencia de trabajo. Los resultados demuestran la aplicabilidad y buen comportamiento de las redes neuronales artificiales autoregresivas en mercados energéticos, obteniendo bajos errores en su desempeño tanto dentro como fuera de la muestra.

²Índice que mide el valor del dólar estadounidense con relación a una canasta de monedas extranjeras.

³El índice se basa en la capitalización bursátil de 500 grandes empresas que poseen acciones que cotizan en las bolsas NYSE o NASDAQ.

CAPÍTULO 1

Marco Teórico

1.1. Literatura existente en el pronóstico de precios del crudo

La literatura en torno al pronóstico de precios del crudo se ha enfocado principalmente en dos clases de modelos: lineales econométricos reducidos representados mediante una ecuación simple. El primer grupo (“modelos financieros”) incluyen los modelos que son directamente inspirados por la teoría económica financiera y se basan en la hipótesis de eficiencia de los mercados (MEH), mientras que los modelos que pertenecen a la segunda clase, (“modelos estructurales”) consideran los efectos de los agentes del mercado del crudo y las variables reales sobre los precios del mismo¹. Tanto los modelos financieros como estructurales frecuentemente utilizan especificaciones de series temporales puras para realizar una evaluación comparativa².

1.1.1. Modelos financieros

En general, los modelos financieros utilizados para pronosticar los precios del crudo examinan la relación entre el precio de mercado del crudo en el tiempo t (S_t) y el precio futuro del crudo en el tiempo t con maduración T (F_t), analizando en particular, cuándo los precios futuros son predictores eficientes insesgados de los precios de mercado. El modelo de referencia utilizado es:

$$S_{t+1} = \beta_0 + \beta_1 F_t + \varepsilon_{t+1} \quad (1.1)$$

donde la hipótesis nula conjunta de insesgamiento ($\beta_0 = 0$ y $\beta_1 = 1$) no debe ser rechazada, y no se debe encontrar presencia de autocorrelación en el término error (Eficiencia). El rechazo de la hipótesis nula conjunta sobre los coeficientes β_0 y β_1 es usualmente relacionado en la literatura con la presencia de una prima de riesgo variable en el tiempo.

¹Como se ha mencionado en el Capítulo 1, los modelos que se analizarán en esta investigación son formas lineales reducidas representadas mediante una ecuación simple. En este contexto se utiliza la expresión “modelo estructural” para identificar una especificación cuyas variables explicativas capturan los aspectos reales y estratégicos del mercado del crudo.

²Algunas excepciones importantes son los trabajos de Pindyck (1998) y Radchenko (2005) los cuales proponen modelos alternativos de pronóstico en un marco de series de tiempo puro.

Un subgrupo de modelos, que también están basados en la teoría financiera pero han sido menos investigados, explotan la siguiente relación entre los precios de mercado y futuros

$$F_t = S_t e^{(r+\omega-\delta)(T-t)} \quad (1.2)$$

donde r es la tasa de interés, ω es el costo de almacenamiento y δ es el rendimiento convenido. La relación (1.2) sugiere que los precios futuros deben ser igual al costo de financiar la compra y mantenimiento del activo hoy antes de la fecha de maduración de los futuros (incluyendo el costo de los préstamos para la compra inicial del activo, o tasa de interés, y cualquier costo de almacenamiento)³.

Samii (1992) unifica los dos acercamientos descritos en las ecuaciones (1.1) y (1.2) introduciendo un modelo en que el precio de mercado es función de los precios futuros y la tasa de interés. Utilizando tanto información diaria (20 Septiembre 1991 - 15 Julio de 1992) como mensual (Enero 1984-Junio 1992) de la serie de precio de mercado del WTI y precios futuros a tres y seis meses de maduración, el concluye que el papel que juega la tasa de interés no es claro y que, aunque la correlación entre los precios de mercado y futuros es muy alta, no es posible identificar cuál es la variable conductora.

Una comparación global de los modelos financieros y de series de tiempo es realizada por Zeng & Swanson (1998), ellos evalúan el desempeño dentro y fuera de la muestra de algunas especificaciones. Los autores utilizan un conjunto de datos diarios en el período comprendido entre el 4 de Enero de 1990 y el 31 de Octubre de 1991 proponiendo así como modelos a evaluar la caminata aleatoria, un modelo autorregresivo y dos modelos alternativos de corrección de errores (ECM, ver Engle & Granger (1987)), cada uno con una definición diferente de equilibrio de largo plazo. La desviación del nivel de equilibrio, lo cual caracteriza al primer modelo ECM puede ser visto como la diferencia entre los precios futuros mañana y los precios futuros de hoy. En el segundo ECM, el término corrección de error, remarca la relación entre los precios de mercado y los precios futuros, lo cual involucra los costos de almacenamiento y los rendimientos convenidos, como se muestra en la ecuación (1.2). El desempeño predictivo de cada modelo se evalúa utilizando algunos criterios formales e informales. La evidencia empírica muestra que las especificaciones ECM superan a las otras.

Bopp & Lady (1991) investigan el desempeño de los rezagos de precios futuros y precios de mercado como variables explicativas para pronosticar el precio de mercado del crudo. Utilizando datos mensuales para el período comprendido entre 1980 y 1988, ellos encuentran soporte empírico con referencia a la teoría de almacenamiento. Los autores también comparan el desempeño de una caminata aleatoria contra el modelo financiero de referencia. En este caso, la evidencia empírica sugiere que ambos modelos se desempeñan igualmente bien.

Serletis (1991) analiza datos diarios de los precios futuros durante un mes (como una variable explicativa del precio de mercado), datos precios futuros de dos meses (reportados en NYMEX) del combustible para calefacción, gasolina sin plomo y petróleo crudo. El Argumenta que la presencia de una prima variable en el tiempo empeora la capacidad de predicción de precios futuros.

³Ver, entre otros, Clewlow & Strickland (2000) y Ising (2006) para detalles de la relación (1.2) en commodities energéticos

En la literatura empírica acerca de los precios del crudo no hay un consenso unánime acerca de la validez de MEH. Por ejemplo, Green & Mork (1991) ofrecen evidencia en contra de la validez del insesgamiento y la MEH, analizando los precios mensuales del crudo para el Medio Oriente y el norte de África en el período comprendido entre 1978 y 1985. Sin embargo, los autores remarcan que, si se hubiera considerado la submuestra en 1981 y 1985, la MEH hubiera sido soportada por los datos, debido a las diferentes condiciones de mercado que caracteriza los dos períodos.

La falta de fiabilidad de insesgamiento y la MEH es también trabajado por Moosa & Al-Loughani (1994), los cuales analizan datos mensuales del WTI comprendido entre el período de Enero de 1986 a Julio de 1990. Los autores aprovechan la cointegración entre las series del precio de mercado del crudo y los contratos futuros a tres y seis meses utilizando ECM, y demuestran que los precios futuros nunca son insesgados y eficientes. Moosa y Al-Loughni proponen un modelo GARCH para tener en cuenta la estructura variable en el tiempo de la prima de riesgo.

Gulen (1998) reafirma la validez del MEH introduciendo el precio del crudo publicado como una variable explicativa adicional en la especificación econométrica. En particular, utilizando datos mensuales del WTI (precio de mercado y precios futuros para uno, tres y seis meses) para el período comprendido entre Marzo de 1983 y Octubre de 1995, el verifica el poder explicativo del precio publicado utilizando tanto los precios futuros como los publicados como variables independientes. La evidencia empírica de este estudio sugieren que los precios futuros superan a los precios publicados, aunque estos últimos tengan un buen comportamiento predictivo en el corto plazo.

Chernenko et.al (2004) realiza una prueba con el fin de probar la validez de la MEH enfocándose en la relación de diferencia de precios:

$$S_{t+T} - S_t = \beta_0 + \beta_1(F_t - S_t) + \epsilon_t \quad (1.3)$$

Analizando datos mensuales de la serie WTI para el período comprendido entre Abril DE 1989 a Diciembre del 2003 los autores comparan el modelo descrito en la ecuación (1.3) con respecto a una caminata aleatoria encontrando que el desempeño empírico de los dos modelos es muy similar, confirmado así la validez del la MEH.

El mismo modelo en (1.3) es evaluado por Chinn et al. (2005) con un conjunto de datos mensual de la serie WTI (precios de mercado) y dos, seis y doce meses de precios futuros. Los resultados empíricos en este caso soportan el insesgamiento y la MEH.

Otra aplicación de los modelos financieros a la relación entre precios futuros y precios de mercado es la propuesta por Abosedra (2005), quien compara la habilidad de pronóstico de los precios futuros en el modelo (1.3) con respecto al pronóstico ofrecido por los precios de mercado. Utilizando datos para el período entre Enero de 1991 y Diciembre del 2001, encuentra que los precios futuros son predictores insesgados y eficientes del precio de mercado del crudo.

1.1.2. Modelos estructurales

Los modelos estructurales enfatizan la importancia de las variables explicativas en la descripción de las características del mercado de crudo. Algunos ejemplos de estas variables son aquellas que son estratégicas para el mercado del crudo (niveles de inventario de la

industria y el gobierno), variables reales (consumo y producción de crudo), y las variables que representan las decisiones tomadas por la OPEC en el mercado internacional del crudo.

Kaufmann (1995) modela el precio real de importación del crudo utilizando como variables explicativas estructurales la demanda de crudo mundial, el nivel de las reservas de crudo de la OECD, la capacidad de producción de la OPEC y la capacidad instalada de la OPEC y Estados Unidos (definidos como la razón entre la producción de crudo y la capacidad de producción). El autor también explica el comportamiento estratégico de la OPEC y el choque en el precio del crudo de 1974 mediante variables dummy específicas. El análisis utiliza datos anuales para el período comprendido entre 1954 y 1989. Los resultados de la regresión muestran que la especificación utilizada captura exitosamente las variaciones del precio del crudo, es decir, los coeficientes de las variables estructurales son significantes y el modelo explica en un alto porcentaje los cambios en el precio del crudo dentro del período de muestra.

Más recientemente, Kaufmann et al. (2004) y Dees et al. (2007) especifican un modelo de pronóstico diferente teniendo en cuenta un conjunto de datos trimestral. En particular, la primera investigación hace referencia al período 1986-2000, mientras que la segunda considera una muestra entre 1984-2002. En ambos estudios los autores ponen una atención particular al comportamiento de la OPEC, utilizando como regresoras estructurales la cuota de la OPEC (definido como la cantidad de crudo que será producido por los miembros de la OPEC), sobreproducción de la OPEC (definido como la cantidad de crudo producido que excede la cuota de la OPEC), la capacidad de utilización y la razón entre las reservas OECD y la demanda de crudo OECD. Utilizando un ECM, los autores demuestran que la OPEC influencia el precio real del crudo.

Una serie de autores introducen el nivel de inventario relativo del crudo (definido como el cambio de los inventarios de crudo con referencia a su nivel normal) como determinante adicional de los precios, suponiéndose entonces que ésta resume la relación entre la demanda y producción de crudo. En general, dos clases de reservas de crudo son consideradas, industriales y gubernamentales. El nivel relativo de reservas industriales (RIS) es calculado como la diferencia entre el nivel actual (IS) y el nivel normal de las reservas industriales de crudo (IS*), la última corresponde a los inventarios de crudo industriales desestacionalizados y removida la tendencia. Como las reservas gubernamentales en crudo tienden a estar constantes en el corto plazo, el nivel relativo de las reservas gubernamentales de crudo (RGS) puede ser obtenido simplemente removiendo la componente de tendencia de la serie.

Ye et al. (2002), (2005) & (2007) desarrollan tres modelos diferentes basados en el nivel de inventarios relativos del crudo con el fin de pronosticar los precios de mercado WTI. En el trabajo del 2002, los autores llevan a cabo la construcción de un modelo a partir de un conjunto de datos mensual para el período comprendido en Enero de 1992 y Febrero de 2001, donde los precios del crudo son explicados a través del nivel relativo de las reservas de crudo industrial y de una variable que describe un nivel de las reservas de crudo inferior al normal. Ye et al. (2005) presentan un modelo básico mensual de la serie de precios de mercado para el WTI el cual utiliza como variables explicativas tres rezagos del nivel relativo de las reservas de crudo industrial, un rezago de la variable dependiente, un conjunto de variables dummy que involucran la ocurrencia de los ataques terroristas del 11 de Septiembre del 2001 (D01) y una variable dummy la cuál toma el valor de uno para el año 1999 (S99) y cero para años superiores utilizada con el fin de captar cambios

estructurales en el comportamiento de la OPEC en el mercado del crudo. Los autores comparan estas especificaciones con:

- i) Un modelo autorregresivo que incluye los términos AR(1), AR(12) y las variables dummy D01 y S99).
- ii) Un modelo estructural donde el precio de mercado del crudo es función del rezago de un mes de los inventarios industriales de crudo, el desvío de las reservas de crudo industrial reportado con respecto al nivel del año anterior, el rezago de un mes del precio de mercado del crudo, así como también las variables dummy D01 Y S99.

Cada modelo es estimado para el período 1992-2003. El modelo básico supera a las otras dos especificaciones: en particular, el modelo de series de tiempo es incapaz de capturar la variabilidad del precio del crudo. El desempeño de cada modelo es evaluado mediante el cálculo de pronósticos fuera de la muestra para el período 2000-2003. La precisión de pronóstico de los dos modelos estructurales depende de la presencia de valles o picos de los precios del crudo en el período de muestra. Cuando se consideran pronósticos tres meses hacia adelante, el modelo básico exhibe un alto desempeño de pronóstico incluso bajo presencia de picos en el precio del crudo, mientras que la segunda especificación estructural supera al modelo básico en presencia de valles en el precio del crudo. Con base en esta última evidencia, Ye et al. (2007), utilizando los mismos datos, incorporan la transmisión asimétrica de los cambios en las reservas de crudo hacia los precios del mismo. Los autores definen el nivel relativo de reservas de crudo industrial a través de las clases bajo (LIS) y alto (HIS) las cuales se presentan a continuación:

$$\begin{aligned}
 LIS_t &= RIS_t + \sigma_{IS} & Si \quad RIS_t < -\sigma_{IS} \\
 LIS_t &= 0 & En \text{ otro caso.} \\
 HIS_t &= RIS_t - \sigma_{IS} & Si \quad RIS_t < \sigma_{IS} \\
 HIS_t &= 0 & En \text{ otro caso.}
 \end{aligned} \tag{1.4}$$

donde σ_{IS} indica desviación estándar del nivel de reservas del crudo industrial.

El modelo estimado fue entonces:

$$\begin{aligned}
 S_t = \alpha + \alpha_1 S_{t-1} + \sum_{j=0}^5 \psi_j D01_{jt} + \lambda S99_t + \sum_{i=0}^k \beta_i RIS_{t-i} + \sum_{i=1}^k (\gamma_i LIS_{t-i} + \delta_i LIS_{t-i}^2) \\
 + \sum_{i=0}^k (\phi_i HIS_{t-i} + \varphi_i HIS_{t-i}^2) + \epsilon_t \tag{1.5}
 \end{aligned}$$

el cual muestra un mejor desempeño de pronóstico con respecto a la especificación lineal propuesta por Ye et al. (2005).

Las Redes Neuronales Artificiales

2.1. Definición y Descripción

Las redes neuronales artificiales son sistemas de procesamiento de información, desarrolladas por científicos cognitivos con el propósito de entender el sistema nervioso biológico e imitar los métodos computacionales del cerebro y su impresionante habilidad para reconocer patrones.

2.1.1. Redes neuronales biológicas y redes neuronales artificiales


Las redes neuronales artificiales se inspiran en la estructura y funciones de las neuronas biológicas. Una red neuronal artificial es esencialmente una colección de neuronas interconectadas, agrupadas en capas. La neurona artificial recibe distintos valores de entrada (inputs) que son multiplicados por una ponderación. En el escenario más simple, estos productos son sumados para obtener un valor de salida (output). La forma más básica de red neuronal se encuentra estrechamente vinculada con las técnicas econométricas de regresión estándar. Este tipo de red simplificada posee dos capas, una de inputs y otra de output. La figura 2.1 ilustra la representación gráfica estándar de una red neuronal feedforward (alimentada hacia delante, es decir que la información fluye desde los inputs hacia el output.)

Cada neurona está representada por un círculo y las flechas indican conexiones entre ellas. El output y_t y los inputs x_1, x_2, \dots, x_i son vectores de $n \times 1$ donde n es el número de observaciones.

Cada conexión entre un input y un output está caracterizada por un peso β_i que expresa la importancia relativa de un input particular en el cálculo del output. Para calcular el valor del output en el momento t , la neurona output colecciona los valores de cada neurona input en la observación t y multiplica cada uno de ellos por un peso asociado con la conexión relevante. A continuación se suman estos productos y se obtiene

$$y_t = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_l x_l = \sum_{i=1}^l \beta_i x_i \quad (2.1)$$

FIGURA 2.1. Red Neuronal Artificial Simple



Fuente: Moshiri & Foroutan (2006)

La ecuación (2.1) indica que y es una suma ponderada de x_i , donde cada x_i (las neuronas input) se vincula con y (la neurona output) por los parámetros β_i (las ponderaciones). En este modelo lineal, cuando x_i cambia en una unidad, y cambia β_i unidades.

La neurona output luego procesa este valor usando una función de activación. En la forma más simple de la red neuronal, la función de activación es la identidad. En este caso, el valor dado en (2.1) constituiría el output final de la red para la observación en t . En sus cálculos, la red tratará de reproducir el valor del output, dados los valores de los inputs. Ahora, si se cree que existen asimetrías entre los inputs o variables de política y el output, es decir que la relación entre estas variables depende de la magnitud y la dirección de los inputs, entonces (2.1) debe generalizarse con la introducción de no linealidades en la relación. Esto puede lograrse incorporando una función de umbral, que permita que una suma ponderada de los inputs suficientemente grande active un cambio de régimen discreto. Sin embargo, el cambio de régimen no tiene que ser abrupto y para ello se emplean funciones de activación suaves, tales como la función logística descrita en la ecuación (2.2)

$$G(z) = \frac{1}{1 + \exp(-z)} \quad (2.2)$$

La función (2.2) puede aplicarse al modelo lineal en (2.1) para permitir una relación no lineal entre los inputs y el output. Si además se cree que el efecto de los inputs sobre el outputs no es directo, como usualmente ocurre en las relaciones económicas, sino que existen variables intermedias que operan entre ellas; entonces el uso de unidades escondidas como etapas intermedias, donde los inputs x_i y sus pesos son sometidos a una nueva ponderación antes de afectar al output permite que la red capture la relación no lineal entre las variables input y el output.


Un modelo lineal $y_t = \beta' X_t + e_t$ es apto para modelar relaciones en las que choques positivos y negativos de igual magnitud producen efectos idénticos, pero en direcciones opuestas. Así mismo, es adecuado para describir relaciones en las que los efectos son siempre proporcionales a la magnitud del choque y además independientes del momento en el que éste ocurre. Si, efectivamente, la relación entre las variables objeto de estudio es no lineal, el investigador se enfrenta a una amplia gama de posibilidades entre las que se encuentran las redes neuronales artificiales.

2.1.2. Arquitectura

Por arquitectura de una red neuronal artificial se entiende el conjunto de inputs incluidos en la parte no lineal, p , que puede estar completamente contenido en el conjunto de k variables asociadas a la parte lineal; así como el número de unidades escondidas, q , y el número de superficies escondidas, necesarias para la determinación del componente no lineal Misas et al. (2003).

El tipo de red neuronal que se pretende abordar en esta investigación es multicapa (posee tres superficies), se alimenta hacia adelante (la información fluye desde la superficie input hacia la superficie output) y con una única superficie escondida o “single hidden layer feedforward network”. En la figura 2.2 puede observarse una representación gráfica del tipo de red neuronal descrito.

FIGURA 2.2. Representación de una red neuronal alimentada hacia adelante con una única superficie escondida



Fuente: Jalil & Misas (2007)

En la base de esta red se encuentra una superficie input conformada por el conjunto de variables explicativas X_t . Estas k variables explicativas pueden ser rezagos de la misma variable dependiente, l , así como de las variables exógenas, m , $X_t = \{y_{t-1}, \dots, y_{t-l}, w_{1t}, \dots, w_{mt}\}$ y relacionarse tanto lineal como no linealmente con la variable explicada. Éstas últimas conforman el conjunto Z_t , donde $Z_t \subseteq X_t$.

Cada uno de estos inputs es multiplicado por una ponderación. Como es de esperarse, la estimación de las ponderaciones iniciales correspondientes a la parte lineal θ_i , para $i = 1, \dots, l + m$ se lleva a cabo a través de mínimos cuadrados ordinarios y la sumatoria de los productos de estas variables por sus respectivos pesos se va directamente al output como lo ilustra el gráfico 2.2.

$$\hat{y}_{t(\text{lineal})} = \phi_0 + \phi_1 y_{t-1} + \dots + \phi_l y_{t-l} + \phi_{l+1} w_{1t} + \dots + \phi_{l+m} w_{mt} \quad (2.3)$$

Por su parte, los pesos asociados a la parte no lineal $\gamma_{i,j}$ para $i = 0, \dots, p$ y $j = 1, \dots, q$ son obtenidos aleatoriamente a partir de una distribución uniforme en el intervalo $[-a, a]$. Antes de entrar a la superficie oculta, estos pesos se encargan de amplificar o disminuir el efecto de las señales originales. En la superficie oculta existen unidades escondidas que

pueden estar asociadas a una variedad de funciones que permiten la transición suave o discreta desde un régimen a otro. Allí, las funciones de activación transforman las combinaciones $Z_t' \gamma_{i,j}$ en los valores comprendidos entre cero y uno. Finalmente, estos valores son multiplicados por β_j $j = 1, \dots, q$. Los valores iniciales de β_j se hallan, una vez más, por mínimos cuadrados ordinarios.

$$\hat{y}_{t(nolineal)} = \sum_{j=1}^q \beta_j G(\gamma_{0,j} + \gamma_{1,j} y_{t-1} + \dots + \gamma_{l,j} y_{t-l} + \gamma_{l+1,j} w_{1t} + \dots + \gamma_{l+m,j} w_{mt}) \quad (2.4)$$

La suma de la parte lineal y la parte no lineal produce el output $y_t = \hat{y}_t + \epsilon_t$, donde

$$\hat{y}_t = \phi_0 + X_t' \phi_i + \sum_{j=1}^q \beta_j G(Z_t' \gamma_{i,j}) \quad (2.5)$$

Siguiendo a Swanson & White (1995), en la terminología de redes los parámetros asociados con la parte no lineal, $\gamma_{i,j}$ y β_j , se conocen como ponderaciones del *input to hidden layer* y *hidden layer to output*, respectivamente, mientras que los parámetros correspondientes a la parte lineal de la red, ϕ_i , se conocen como ponderaciones *input to output*. La red adquiere conocimiento a través del conjunto de parámetros $\Theta = \gamma_{ij}, \beta_j, \phi_i$.

2.2. Redes Neuronales Autorregresivas

Ya que el objetivo del presente trabajo es la evaluación del desempeño del pronóstico de la serie de precios de mercado del crudo para distintos horizontes de tiempo, se utilizará una Red Neuronal Autorregresiva (ARNN), la cual se construye mediante la combinación de un componente autorregresivo (AR) y un componente perceptrón multicapa (MLP) con múltiples capas ocultas (Chow, 2002); como resultado se obtiene un modelo que absorbe las ventajas de los modelos autorregresivos y las redes neuronales el cuál es capaz de detectar dinámicas complejas, como las observadas en la serie de precios de mercado del crudo (WTI).

En una red neuronal autorregresiva la variable dependiente Y_t (Serie de precios de mercado del crudo en la temporalidad seleccionada) se obtiene a través de la siguiente configuración no lineal:

$$Y_t = \beta_* + \sum_{i=1}^K \psi_i x_t^{(i)} + \sum_{h=1}^H \beta_h G \left((2\sigma_y)^{-1} \alpha_{*,h} + \sum_{i=1}^K \alpha_{i,h} x_t^{(i)} \right) + e_t \quad (2.6)$$


, donde $x_t^{(i)}$ con $i = 1 \dots K$ es el conjunto de regresores y $e_t = \sigma \epsilon_t$. El conjunto $x_t^{(i)}$ puede ser representado por los rezagos de la variable Y_t , así como por variables auxiliares o exógenas las cuales se encuentran de alguna manera relacionada con Y_t . G , como se ha mencionado en la sección presidente, es la función de activación o transferencia. σ es la desviación estándar de los errores. ϵ_t es una variable aleatoria con distribución de probabilidad normal estándar.

Por otra parte, el conjunto de parámetros del modelo ($\omega = \{\beta_*, \beta_h, \psi_i, \alpha_{*,h}, \alpha_{i,h}\}$) para $h = 1, \dots, H; i = 1, \dots, K$ son obtenidos mediante la maximización del logaritmo de la función de verosimilitud de los errores asumiendo que los residuales e_t siguen una distribución normal con media cero y varianza desconocida:

$$L = -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log \sigma^2 - \frac{1}{2} \sum_{t=1}^T \frac{e_t^2}{\sigma^2} \quad (2.7)$$

,donde σ^2 es el promedio de los errores al cuadrado. Adicionalmente es importante resaltar que maximizar la función (2.7) es equivalente a minimizar el error cuadrático medio, el cual es el procedimiento de estimación más comúnmente encontrado en la literatura de redes neuronales. La arquitectura descrita anteriormente se representa a través de la figura (2.3).

FIGURA 2.3. Arquitectura de una red neuronal autorregresiva.



Fuente: Zhang & Zhang (1999)

2.2.1. Aspectos del proceso de estimación

El ejercicio de identificación (estimación del valor de los parámetros y selección de la cantidad de capas o nodos ocultos) del modelo en (2.6) se encuentra estrechamente ligado a las siguientes consideraciones:

- Grandes diferencias en la magnitudes de los parámetros de la red puede causar que las neuronas en la capa oculta se encuentren cerca a su nivel de saturación, es decir, diferentes valores de los inputs de la red producen la misma salida o output de la red, lo cual genera que el gradiente de la función (2.7) sea cercano a cero y por lo tanto el proceso de optimización no se detiene.
- Una ARNN puede tener múltiples arquitecturas o configuraciones que producen el mismo output. Las neuronas de la capa oculta cambian sus posiciones produciendo arquitecturas diferentes cuyo comportamiento es idéntico.

- En algunos casos dependiendo de la selección de $G()$ la contribución de las neuronas en la capa oculta puede permanecer constante, es decir, se pueden tener diferentes redes neuronales con el mismo comportamiento.

Lo anterior lleva entonces a afirmar que puede suceder el caso que diferentes modelos con diferentes arquitecturas sean similares en cuanto al desempeño del pronóstico que realicen, razón por la cual el proceso de estimación de los parámetros puede convertirse en un gran problema ya que el algoritmo de optimización se puede detener en un máximo local. Con el fin de resolver estos problemas la función (2.6) se delimita imponiéndose las siguientes definiciones:

1. Como lo sugieren LeCun et al. (1998) elegir funciones de transferencia (G) de tipo sigmoidea simétricas alrededor del origen, ya que esto ayuda al método de optimización a converger más rápidamente que mediante la utilización de una función de transferencia tradicional; adicionalmente, la adición de un término lineal puede ayudar a la convergencia. Por las razones expuestas anteriormente se realizó la selección de (G) como la función presentada a continuación:

$$G(x) = \frac{1 - \exp(-x)}{1 + \exp(-x)} + kx \quad (2.8)$$

, donde k representa una constante pequeña. Para efectos del presente trabajo se tomó $k = 0,0025$

2. La contribución de cada unidad oculta, $\beta_h G()$, no cambia de signo si los parámetros $\beta_h, \alpha_{*,h}, \alpha_{i,h}$ cambian de signo ya que $\beta_h G(x) = -\beta_h G(-x)$. Lo anterior conllevó a tomar la decisión de imponer la restricción $\beta_h > 0 \quad \forall h$.
3. Se eligió ordenar los parámetros de forma creciente: $0 < \beta_1 < \beta_2 < \dots < \beta_h$ de tal manera que se evitó obtener diferentes configuraciones simplemente por la permutación de los nodos de la capa oculta.

Todas las restricciones impuestas con anterioridad estuvieron encaminadas en reducir la cantidad de modelos posibles, de tal manera que el proceso de estimación de los parámetros de la red. Es importante resaltar que si en (2.6) $\psi_i = 0$ la expresión se reduce a un percepción multicapa (MLP). Adicionalmente al tomar $H = 0$, el modelo descrito en (2.6) se reduce a un modelo lineal con entradas exógenas.

2.2.2. Selección de Número Máximo de Nodos en la Capa Oculta

El proceso de definición de la mejor estructura de la red (ARNN) se realiza mediante el siguiente procedimiento:

1. Sea H el número de nodos en la capa oculta de la última red neuronal autorregresiva estimada. Si $H = 1$ se realiza este paso únicamente la primera vez. Adicionalmente se estima un modelo tentativo con $H + 1$ unidades en la capa oculta.
2. La consideración de un nuevo nodo $H + 1$ se hace a través del valor crítico del estadístico de prueba del la razón de verosimilitud:

$$S = 2(L_{H+1} - L_H) \quad (2.9)$$

3. En caso de no rechazar la entrada del nuevo nodo, se retoma de nuevo el primer punto, de manera contraria estamos ante la evidencia que los modelos con H y $H + 1$ nodos no son estadísticamente diferentes, por lo cual el número máximo óptimo de nodos sería H .
4. En el caso en que se rechaza la entrada del nuevo nodo, se estima un modelo restringido y se calcula su razón de verosimilitud $L_H^{(i)}$. El modelo restringido es obtenido mediante la eliminación de la entrada i del modelo seleccionado.
5. Para cada uno de los modelos restringidos se estima la razón de verosimilitud como se describe en la siguiente expresión:

$$S^{(i)} = 2(L_{H+1} - L_H^{(i)}) \quad (2.10)$$

6. Finalmente se elimina la entrada i que tenga el mayor valor crítico para el estadístico definido en la ecuación (2.10). Si es posible eliminar ninguna entrada se culmina el proceso; en caso contrario, se retoma el paso 4.

Una vez se ha obtenido la arquitectura optimizada final del modelo ARNN, se continua con el procedimiento de diagnóstico de los residuales, e_t para $t = 1 \dots T$, en los cuales se verifican los siguientes tres supuestos: $e_t \rightarrow N(\mu, \sigma)$, que los residuales no estén correlacionados y que no haya evidencia de heterocedasticidad.

2.3. Aplicación de Modelos ANN en el pronóstico del precio del crudo

En esta sección se presenta una revisión de la literatura en torno al pronóstico del precio del crudo basado en modelos ANN. Kaboudan (2001) y Rast (2001) son los primeros en introducir la técnica ANN con el fin de predecir el precio del crudo. Kaboudan (2001) introduce los algoritmos genéticos (GP), el modelo ANN y la caminata aleatoria (RW) para pronosticar los precios del petróleo crudo mensuales. Para este propósito, el autor utiliza varias series de tiempo mensual durante el período de 1993 a 1999, tales como, los precios de mercado del crudo, la producción mundial de crudo, el consumo de la OCDE y las reservas de crudo mundiales. Teniendo en cuenta la medida de error de pronóstico MSE, concluyó que el algoritmo de predicción genética modelo (MSE = 1,85) superó al RW (MSE = 2,29) y también la técnica de redes neuronales (MSE = 3,54).

En otra investigación, Mirmirani & Li (2004) aplicaron dos técnicas diferentes para predecir el evolución de los precios del petróleo. Un vector autorregresivo (VAR) es la primera técnica, modelo basado en tres variables explicativas: los precios del petróleo, el consumo de petróleo y el suministro de petróleo. Mientras, el suministro de petróleo y el consumo de sus derivados se utilizan como entradas en el segundo modelo o red neuronal de retropropagación (BPNN) con el algoritmo genético (GA). El entrenamiento o ajuste se realizó utilizando datos mensuales durante el período comprendido entre enero de 1986 y noviembre de 2002 y se utilizó como medidas de desempeño los estadísticos: (RMSE) y (MAE). Los resultados de desempeño arrojaron que las RNA con el modelo GA (RMSE =

1,2354, MAE = 0,8629) ofrece mucho un mejor desempeño que la técnica de VAR (RMSE = 4,69861, MAE = 4,18883).

En el estudio de Moshiri & Foroutan (2006), se proponen tres modelos a competir, una red neuronal feedforward (FNN), un modelo ARMA (autorregresivo de media móvil) y un modelo heterocedastico condicional autorregresivo generalizado (GARCH) para realizar pronósticos de la serie diaria de los precios del crudo . Los datos utilizados en este estudio fueron los precios diarios del crudo que cubren el período entre el 4 de abril de 1983 y el 13 de enero de 2003. Para la evaluación de desempeño de los modelos propuestos se tuvieron en cuenta los estadísticos MAE, MSE y RMSE. Sobre la base de estas medidas calculadas, concluyeron que la ANN (MAE = 2,04, MSE = 8,14 y RMSE = 2,85) revela un mejor desempeño que el modelo ARMA (MAE = 4,81, MSE = 29,27 amd RMSE = 5,41) y también que el modelo GARCH (MAE = 2,90, MSE = 15.25 y RMSE = 3,90).

En el próximo trabajo, Xie et al. (2006) aplicaron un modelo de máquina de vectores de soporte (SVM) para predecir el precio del crudo utilizando los precios mensuales WTI durante el período comprendido entre enero de 1970 a diciembre de 2003. El método propuesto se comparó con un modelo ARIMA y BPNN. Los resultados obtenidos basados el los estadísticos de desempeño RMSE y Dstat, encontraron que el modelo SVM se comporta mejor que los otros dos modelos. Sin embargo, el BPNN supera al SVM y al ARIMA para dos subperíodos de los cuatro subperíodos analizados.

En otro estudio, Amin & Gharacheh (2007) propusieron una modelo de inteligencia artificial híbrido para pronosticar el precio mensual del crudo WTI. El modelo híbrido se compone de tres técnicas populares de la inteligencia artificial AI, FNN, GA y K-means la agrupación. Para evaluar el desempeño del modelo propuesto, los autores compararon los resultados de predicción del modelo híbrido con respecto a lo revelado por los cuatro modelos. La serie de precios del crudo WTI para la realización del estudio fue seleccionada desde el primero de enero de 1983 hasta diciembre de 2006 para el primer experimento (comparación con el primer modelo), de enero 1974 hasta diciembre 1999 para el segundo y desde enero de 1983 hasta Diciembre de 2002 para el tercer experimento (comparación con el tercer modelo). Por último, se seleccionaron los datos de los precios del petróleo en el cuarto y último experimento (comparación con ANN) para el cual se eligió el período comprendido entre enero de 1974 hasta diciembre de 2001. Sobre la base de nueve criterios de desempeño (MAE, MAPE, Max AE, SSE, MSE, RMSE, Dstat, U2-Theil (RMSE del modelo / RMSE del proceso RW) y el coeficiente de correlación al cuadrado (R²)), los resultados del modelo híbrido superan considerablemente a los otros modelos en cuanto a la mayoría de las medidas de desempeño.

Con el mismo fin de pronosticar los precios del crudo, Liu et al. (2007) emplearon una red neuronal difusa. Más precisamente, se aplicaron en este trabajo un total combinado de tres herramientas de predicción como lo son la función de base radial (RBF) de redes neuronales, el método semiparamétrico basado en cadenas de Markov y análisis de descomposición wavelet. Para la tarea de simulación, los autores utilizaron el precio Brent del crudo comprendido entre el 20 de mayo de 1987 a 30 de agosto de 2006. Para evaluar el desempeño del modelo planteado se utilizo el estadístico MSE. Con base a este criterio, los autores mostraron que el método de pronóstico propuesto supera a los otros modelos individuales (1,02980, 2,70602, 2,81591 y 4,52168 respectivamente para el modelo propuesto; cadena de Markov, red neuronal RBF y el análisis wavelet).

Enfoque metodológico

3.1. Metodología y diagnóstico


Para el desarrollo aplicado del trabajo final se seleccionó el perceptrón multicapa con conexiones hacia adelante, debido a que dentro del marco de las redes neuronales, el perceptrón ha mostrado ser una de las arquitecturas más útiles en la resolución del tipo de problemas exhibidos por la serie de precios del crudo. Lo anterior fundamentalmente debido a su capacidad como aproximador universal. La arquitectura de esta red, se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles. Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, la capa de salida y la capa oculta. Cada neurona posee su respectivo nivel de umbral y la función de transferencia utilizada en todas las neuronas fue la tangente hiperbólica.

3.1.1. División del conjunto de información

El proceso de entrenamiento elegido fue el supervisado, el cual consiste en dividir el conjunto de información en un primer subconjunto correspondiente a dos tercios o siete octavos del conjunto de datos, según la frecuencia de la serie; y un segundo conjunto, con la cantidad de observaciones de la serie faltante utilizado para validación. Como es ampliamente conocido, en las redes neuronales artificiales es habitual subdividir el período de estudio en dos partes, de tal forma que en la primera se lleva a cabo el proceso de entrenamiento o aprendizaje y en la segunda el de evaluación (figura 3.1).

Específicamente para las series anual y mensual del precio de mercado del crudo se tomaron los dos tercios mas antiguos de cada serie para hacer parte del subconjunto de entrenamiento y el tercio restante conformó el subconjunto de validación. Por otra parte para las series de frecuencias mas altas como la serie diaria y semanal se utilizaron siete octavos de la series para conformar el subconjunto de entrenamiento y el octavo restante para conformar el subconjunto de validación. Así mismo es importante mencionar que se utilizaron los mismos subconjuntos para el ajuste y validación de los modelos de contraste diferentes a la red neuronal artificial autorregresiva.

FIGURA 3.1. Subdivisiones del período de estudio de una red neuronal.



Fuente: Misas et al. (2003)

3.1.2. Selección de arquitectura ARNN por frecuencia de trabajo

Se probaron diferentes arquitecturas de redes neuronales autorregresivas con una capa oculta en cada frecuencia de trabajo. Con el fin de encontrar la mejor arquitectura para pronosticar las distintas frecuencias de la serie del precio de mercado del crudo, se arrancó ajustando una ARNN con una neurona y un razago de la serie en dicha capa de tal manera que se comienza a aumentar estos dos parámetros en cantidad hasta el punto en que no se perciban cambios significativos en los distintos estadísticos de evaluación de desempeño tanto en subconjunto de entrenamiento como en el subconjunto validación. La selección de la mejor arquitectura de la red por frecuencia de trabajo, se realizó considerando seis medidas estándares en el conjunto de entrenamiento y en el conjunto de evaluación de la muestra para medir el desempeño de pronóstico de cada modelo estimado: Error Medio (ME), raíz del error cuadrático medio (RMSE), error medio absoluto (MAE), porcentaje del error medio (MPE), porcentaje del error medio absoluto (MAPE), error medio absoluto escalado (MASE)¹.

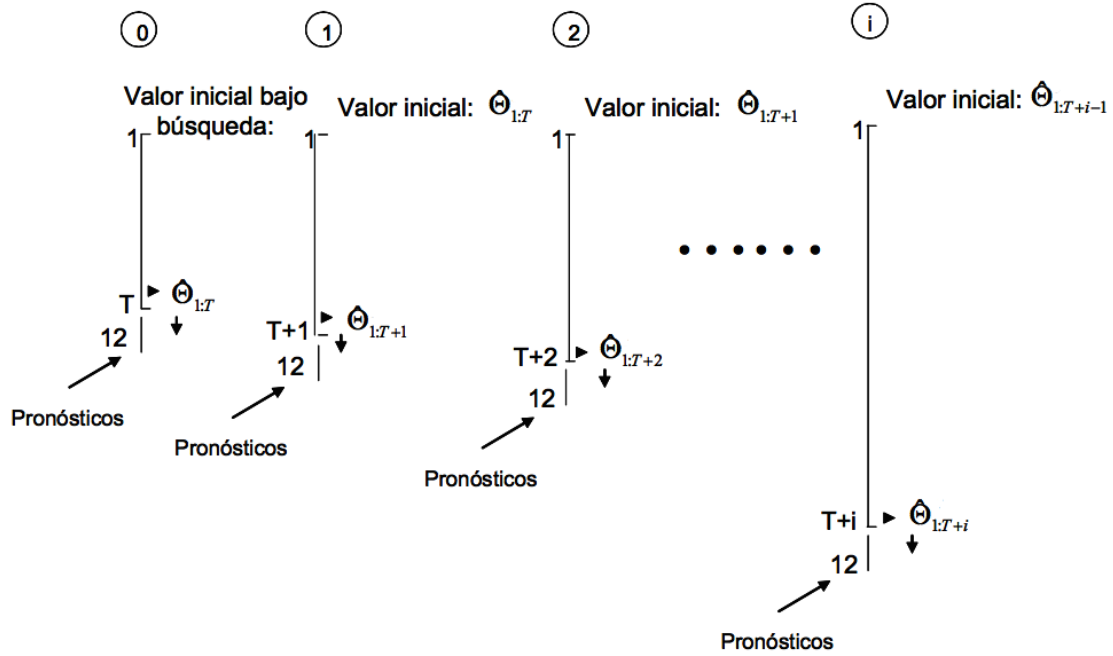
Una vez obtenidas las distintas medidas de error de pronóstico para las diferentes frecuencias de trabajo y arquitecturas consideradas, se realizó la selección de la mejor arquitectura ARNN. Adicionalmente se procedió a realizar el ajuste de tres modelos distintos para el proceso de contraste una Caminata Aleatoria, un modelo ARIMA y un modelo GARCH para cada frecuencia por separado ². Finalizado el paso anterior se continua la evaluación por fuera de la muestra de cada modelo bajo un esquema de rolling.

3.1.3. Desempeño por horizonte de pronóstico

En el esquema Rolling se parte del conjunto de parámetros estimados para la arquitectura seleccionada en el período de entrenamiento, es decir, $\hat{\Theta}_{1:T}$ y se genera un pronóstico de horizonte 12, $\hat{y}_{1:T}^1, \dots, \hat{y}_{1:T}^{12}$. Posteriormente, se reestiman los parámetros de la arquitectura considerando: (i) como conjunto de información aquel que reúne la muestra inicial o muestra de entrenamiento $\{y_1 : y_T\}$ con la observación inmediatamente siguiente $\{y_{T+1}\}$, es decir, $\{y_1 : y_T\} \cup \{y_{T+1}\} = \{y_1 : y_{T+1}\}$, y (ii) como valor inicial de los parámetros aquellos obtenidos en el período de entrenamiento $\hat{\Theta}_{1:T}$. De esta forma se produce un nuevo conjunto de parámetros $\hat{\Theta}_{1:T+1}$ con los cuales se lleva a cabo un pronóstico de horizonte 12, $\hat{y}_{1:T+1}^1, \dots, \hat{y}_{1:T+1}^{12}$. De esta forma, en el i -ésimo paso se considera como conjunto de información a $\{y_1 : y_T\} \cup \{y_{T+1}\} \cup \dots \cup \{y_{T+i}\} = \{y_1 : y_{T+i}\}$ para la reestimación y

¹Ver Apéndice D.²La profundización teórica de los tres modelos de contraste se puede encontrar en el Apéndice D.

FIGURA 3.2. Esquema Rolling



Fuente: Jalil & Misas (2007)

como valores iniciales de los parámetros a aquellos estimados en el paso anterior, es decir, $\hat{\Theta}_{1:T+i-1}$. Con tales parámetros se generan pronósticos de horizonte 12, $\hat{y}_{1:T+i}^1, \dots, \hat{y}_{1:T+i}^{12}$. Este procedimiento se lleva a cabo hasta el momento $(T^* - 1)$ para tener información observada de la variable y_t y construir las medidas de evaluación por horizonte $h = 1, 2, \dots, 12$ (Jalil & Misas, 2007). La figura 3.2 presenta la metodología anteriormente explicada.

Finalmente, obtenidos las distintas medidas de error de pronóstico para cada horizonte de pronóstico h y cada uno de los modelos que se contrastaron en las diferentes temporalidades se procedió a resaltar los modelos con mejor desempeño para cada horizonte o conjunto de horizontes.

3.2. Los Datos

Los datos históricos utilizados para el desarrollo de los diferentes modelos planteados fueron obtenidos de la plataforma de la agencia de administración de energía de los Estados Unidos (www.eia.gov)³. Las variables de entrada corresponden a los precios de cierre diarios, semanales, mensuales y anuales en dólares americanos para el petróleo WTI (West Texas Intermediate) y como salida única se tiene el precio a pronosticar para cada una de las frecuencias de trabajo.

Para el caso de la serie diaria se obtuvo un conjunto total de 7361 observaciones correspondientes a 244 meses de negociación comprendidos entre el 2 de Enero de 1986 y

³En el Apéndice E se despliega en el código implementado la fuente exacta de extracción de los datos, además de los valores extraídos. Lo anterior con el fin de realizar de forma sencilla ejercicios de replicación de los resultados obtenidos

el 9 de Marzo del 2015, se tomaron 6437 días para entrenamiento (214 meses) y se dejaron 924 días correspondientes a 30 meses para pronóstico fuera de la muestra. Con respecto a la serie semanal se trabajaron 1184 datos correspondientes a 244 meses de negociación comprendidos en la misma ventana de tiempo de la serie diaria, se tomaron 1028 semanas para entrenamiento (207 meses) y se dejaron 156 semanas correspondientes a 37 meses para pronóstico fuera de la muestra. De manera similar en la misma ventana de tiempo se retuvieron para la serie mensual 244 datos de los cuales 160 se tomaron para la fase de entrenamiento y 84 para pronóstico fuera de la muestra. Con respecto a la serie de precios anuales se trabajaron 20 observaciones, de éstas 15 observaciones se utilizaron para el proceso de entrenamiento y las restantes fueron utilizadas para pronóstico ⁴. Finalmente para los modelos de contraste se utilizaron los mismos conjuntos de datos para cada uno de los horizontes de tiempo de trabajo.

En las figuras 3.3, 3.4 y 3.5 se puede observar el comportamiento de las series de tiempo para cada uno de los horizontes de trabajo. De manera similar a lo expuesto en el Capítulo 1 las series de más alta frecuencia exhiben una marcada relación con la serie mensual presentada en la figura 1, de tal manera que es posible asociar eventos geopolíticos a puntos de incremento o reducción pronunciada de los precios del crudo.




FIGURA 3.3. Precio de mercado del petróleo WTI de 1986 al 2014 (Promedios Anuales)

En particular, se puede observar que los precios del petróleo experimentan altibajos importantes en los períodos de entrenamiento, adicionalmente en el período de validación se observan períodos de alta volatilidad, especialmente durante 2008, año de la crisis financiera mundial.

Entre algunos factores que contribuyen a la presencia de alta volatilidad en las distintas series se encuentran factores como la limitación de cantidad de suministro de petróleo mundial y las relaciones hostiles entre los EE.UU. y algunos países productores de petróleo. El precio del crudo tocó un máximo histórico de US \$ 147.30 en el momento en que la burbuja inmobiliaria en los EE.UU. comenzó a estallar, y la crisis de crédito sin precedentes se comenzó a manifestar. El dramático descenso en los precios del petróleo que siguió

⁴Como consecuencia de la baja cantidad de observaciones en la serie anual se realizó un esquema de evaluación rolling con $h = 5$




FIGURA 3.4. Precio de mercado del petróleo WTI del 1 de Enero 1986 al 9 de Marzo de 2014 (Serie Diaria)

produjo un nivel de dificultad adicional en el momento de modelar la serie. A pesar de que el precio mostró en general un nivel constante de recuperación después de la crisis financiera en 2008, posteriormente a exhibido un desplome que ha traído múltiples preocupaciones en distintas economías; lo anterior introdujo un gran desafío en el encontrar un modelo que realizara pronósticos consistentes y acertados, al ser confrontado con tales circunstancias impredecibles.

3.3. Herramienta de Procesamiento

Como lo sugieren Ihaka & Gentleman (1996) una de las principales herramientas estadísticas y econométricas para realizar el análisis y la predicción de series de tiempo es el lenguaje de programación R, ya que posee un amplio repertorio de funciones para ese fin a través de la publicación de distintos paquetes de carácter público y de consulta en la misma herramienta. Adicionalmente, el lenguaje provee mecanismos para crear paquetes instalables en su propio entorno de programación, los cuales actúan como una colección de múltiples funciones existentes o nuevas en el mismo entorno. Durante la creación de cada paquete, el código fuente es analizado con el fin de verificar unas condiciones mínimas de calidad, que incluyen, entre otras, que cada función implementada esté adecuadamente documentada en el sistema de ayuda. Aunque esta herramienta computacional *R* está diseñada fundamentalmente para el cómputo estadístico, resulta muy apropiada para la programación de algoritmos de inteligencia computacional tales como las redes neuronales artificiales Velasquez & Montoya (2010).

En los últimos años se vienen realizando esfuerzos importantes con el fin lograr el desarrollo e implementación de modelos adaptativos de redes neuronales en el paquete R, por tal razón a continuación se ofrece recuento de los desarrollos disponibles en la actualidad:




FIGURA 3.5. Precio de mercado del petróleo WTI de la primera semana de Enero 1986 a la primera semana de Marzo del 2014 (Promedios Semanales)

- En la versión 7.3-1 del paquete NNET (Ripley, 2011), la función del mismo nombre permite crear modelos no lineales de regresión y clasificación usando redes de propagación hacia adelante con una sola capa oculta, entre las que se incluyen los MLP y redes similares a las ARNN; la optimización es realizada usando el algoritmo BFGS del paquete OPTIM.
- El paquete AMORE (Espinoza et al., 2005) permite la creación de modelos de regresión basados en modelos tipo MLP; la mayor novedad de este paquete es la implementación del algoritmo TAO para la estimación de los parámetros de la red neuronal (Espinoza et al., 2005).
- Los modelos de redes de propagación hacia adelante con restricciones monótonas para la solución de problema de regresión (Zhang & Zhang, 1999) son implementados en el paquete MONMLP (Cannon, 2010).
- El paquete NEURALNET permite la estimación de modelos MLP con el algoritmo RPROP (Fritsch & Guenther, 2010).
- El paquete RSNNs permite el uso de los modelos de redes neuronales artificiales implementados en el Stuttgart Neural Network Simulator desde el entorno (Bergmeir, 2011).
- La función NNET del paquete TSDYN (Di Narzo et al., 2011) permite el uso de redes neuronales tipo MLP para la predicción de series de tiempo. La optimización es realizada usando el algoritmo BFGS implementado en la función OPTIM. En este mismo paquete se implementan otras metodologías, tales como los modelos STAR.

3.3.1. El paquete ARNN

El paquete ARNN fue creado por Juan D. Velásquez, Cristian O. Zambrano y Laura Vélez del Grupo de Computación Aplicada de la Universidad Nacional de Colombia, sede

Medellín. Este paquete crea Redes Neuronales Autorregresivas y Redes Neuronales Perceptrón Multicapa, el paquete crea una Red Neuronal feed-forward autorregresiva con una capa de entrada, un nodo para cada rezago, una capa oculta con H nodos y una capa de salida con un nodo, estos nodos se activan con la función sigmoidea y el nodo de salida se activa con la función $g(u)=u$.

Las principales ventajas del paquete ARNN se describen a continuación:

- Las funciones implementadas están debidamente documentadas en el sistema de ayuda nativo del entorno. De esta forma, el paquete se integra naturalmente dentro de entorno.
- Su diseño y arquitectura computacional está basado profundamente en el paquete forecast de Hyndman & Khandakar (2008), por lo que sólo fue necesario implementar las funciones propias del modelo ARNN. El paquete forecast tiene implementaciones de otros modelos de predicción ampliamente utilizados, por lo que resulta fácil contrastar los resultados con los de otros modelos alternativos.
- No hay implementaciones de modelos ARNN con funciones adaptativas de activación.

El paquete consta de dos funciones principales: arnn para crear y estimar el modelo y forecast para pronosticar varios periodos adelante. En general la implementación o ajuste del modelo ARNN se realiza mediante la puesta en marcha de los pasos expuestos a continuación: ⁵:

- **Definición de parámetros e inicialización de matrices de guardado de resultados.**

En este primer paso se definen los parámetros que controlan la proporción de observaciones que se utilizaron para el conjunto de entrenamiento y el conjunto de validación. Adicionalmente se definieron dos parámetros, los cuales intervienen en el control del número máximo de nodos capa oculta así como la cantidad de máxima de rezagos a utilizar. Por otra parte como parte final de este paso se crea la matriz de almacenamiento de los resultados la cual guarda para cada modelo estimado los diferentes estadísticos de ajuste tanto dentro como fuera de la muestra.

- **Partición de la serie en el conjunto de entrenamiento y validación.**

Basados en la definición de los parámetros del primer paso se realiza la generación de una nueva serie de tiempo conformada por los primeras t observaciones de la serie original. Adicionalmente el valor de t fue establecido mediante la expresión $t = N \times \theta$ donde θ corresponde a la proporción de observaciones que conformarían el conjunto de entrenamiento y N la cantidad total de observaciones.

- **Generación iterativa de modelos.**

– *Estimación de parámetros.*

⁵El detalle del proceso de procesamiento de los datos, ajuste del modelo, estimación de los parámetros y desempeño del modelo se pueden observar en el código del lenguaje R desplegado en el Apéndice 2.

A través de la función *arnn* del paquete *ARNN* se realiza el proceso de estimación de todos los parámetros de la red. La cantidad de parámetros a estimar depende del número de rezagos utilizados en la red además del número de nodos en la capa oculta.

- *Generación de estadísticos de ajuste en la muestra de entrenamiento.*

Haciendo uso de la función *accuracy* del paquete *forecast* se encuentran los diferentes estadísticos de error de pronóstico para la muestra de entrenamiento.

- *Generación de pronósticos en la muestra de validación.*

Nuevamente utilizando la función *arnn* y el modelo estimado en el primer paso se generan pronósticos dentro del conjunto de validación.

- *Generación de estadísticos de ajuste en la muestra de validación.*

Por segunda ocasión se hace uso de la función *accuracy* del paquete *forecast* mediante el cual se encuentran los diferentes estadísticos de error de pronóstico para la muestra de validación.

- *Almacenamiento de estadísticos en la matriz de resultados.*

Finalmente una vez obtenidos los valores de los parámetros del modelo de los distintos estadísticos de ajuste para el conjunto de entrenamiento y validación se almacenan todos los valores obtenidos en la matriz de resultados.

- **Generación de gráficos de ajuste de la serie dentro y fuera de la muestra.**

Una vez escogida la arquitectura de la red con mejor desempeño en cuanto a las distintas medidas de error de pronóstico se generan los gráficos: serie de tiempo en el período de entrenamiento con respecto a los valores ajustados y la serie de tiempo en el período de validación con respecto a los valores ajustados y un intervalo de confianza.

Resultados

4.1. Definición de arquitecturas, estimación e identificación de modelos de contraste por frecuencia

Al retomar las secciones anteriores se observa que el realizar un ajuste de un modelo no lineal para la serie de precios de mercado del crudo podría brindar información útil para la toma de decisiones y definición de políticas por parte de los organismos económicos mundiales y de cada país. Con sustento en lo anterior se decidió, tomar el precio de mercado del crudo WTI en diferentes frecuencias y realizar un ejercicio en el que se le ajustan modelos lineales como no lineales con el fin de realizar una comparación de los mismos sustentados en medidas simétricas de error de pronóstico ¹.

La evaluación de pronóstico del precio de mercado del crudo WTI se lleva a cabo sobre los pronósticos de un modelo no lineal, red neuronal autorregresiva (ARNN), un modelo lineal ARIMA, un modelo GARCH, una caminata aleatoria (WR) y una red neuronal artificial (ANN) con entradas la serie de precios de mercado del crudo más los índices *DXY* y *S&P500*. El estudio abarca el período comprendido entre el 2 de Enero de 1986 y el 9 de Marzo de 2015.

4.1.1. Definición de arquitecturas ARNN para cada frecuencia de estudio

Como resultado de la aplicación de la metodología descrita en el capítulo precedente se obtuvieron los estadísticos contenidos en la tablas A.1, A.2 para la frecuencia mensual, A.3, A.4 para la frecuencia anual, A.5, A.6 para la frecuencia diaria y A.7, A.8 para la frecuencia semanal . Como se puede observar en la mismas, se analizaron múltiples arquitecturas ARNN para las distintas frecuencias de trabajo, así como diferentes medidas de error de pronóstico tanto para el conjunto de entrenamiento como para el de validación. Adicionalmente se incorporaron los estadísticos correspondientes a diferentes criterios de información para el cada modelo de prueba; de tal manera que asignándose una impor-

¹Para el proceso de comparación de modelos se decidió retener únicamente los estadísticos RMSE y MAE sustentado en las propiedades específicas de éstos mismos. El RMSE es más apropiado para representar el rendimiento del modelo que el MAE cuando se espera que la distribución del error sea normal. Sin embargo al fallar el supuesto de normalidad en los residuales el MAE es más adecuado en la medición de desempeño.

tancia mayor sobre el comportamiento del modelo en el conjunto de validación se escogió la arquitectura del modelo ARNN con mejor desempeño.

En la tabla 4.1 se resumen las arquitecturas seleccionadas por frecuencia de trabajo:

TABLA 4.1. Arquitecturas ARNN seleccionadas por frecuencia de trabajo

Parámetros	Frecuencias			
	Mensual	Anual	Diaria	Semanal
P (Rezagos)	2	3	2	2
Q (Neuronas)	3	1	2	4

Como complemento a la caracterización de las arquitecturas seleccionadas se realizan las estimaciones de los parámetros de las redes seleccionadas así como la varianza estimada σ^2 , el valor máximo de la función log - verosimil, los criterios de información clásicos y bayesianos; y finalmente los diferentes estadísticos de error de pronóstico en el período de entrenamiento y validación (Ver Apéndice B.1)

4.1.2. Ajuste de las ARNN seleccionadas

Como complemento de la caracterización de las ARNN seleccionadas se generaron los gráficos 4.1, 4.2, 4.3 y 4.4 los cuales en la región izquierda muestra los valores observados de cada serie de tiempo versus los valores pronosticados por la red en todo el período de información (Conjunto de entrenamiento y conjunto de validación). De éstos, excepto para la serie anual de precios del crudo, se puede concluir la presencia de un buen ajuste de cada arquitectura ARNN tanto en el conjunto de entrenamiento como en el conjunto de validación.




FIGURA 4.1. Desempeño de los pronósticos de la ARNN (Serie Mensual WTI)




FIGURA 4.2. Desempeño de los pronósticos de la ARNN (Serie Anual WTI)




FIGURA 4.3. Desempeño de los pronósticos de la ARNN (Serie Diaria WTI)

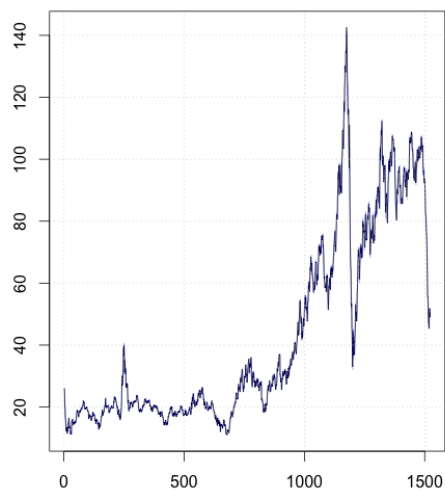


FIGURA 4.4. Desempeño de los pronósticos de la ARNN (Serie Semanal WTI)

4.1.3. Ajuste de los modelos de contraste ARIMA y GARCH

Con el fin de obtener la caracterización de los diferentes modelos de contraste deseados para cada frecuencia de trabajo se efectuó la implementación de la siguiente metodología para seleccionar las características de cada modelo de contraste propuesto:

1. Identificación de modelos ARIMA

- Seguimiento paso a paso de la metodología sugerida por (Box & Jenkins, 1990).
 - Diagnóstico de estacionariedad de la serie (Función Log - Verosimil de Box y Cox).
 - Calculo de test de Dickey-Fuller aumentado (ADF) para probar la estacionariedad de la serie transformada (Ver Definición A.13).
 - Despliegue de las funciones de autocorrelación y autocorrelación parcial con el fin de encontrar el orden de la parte autorregresiva (AR) y de promedio móvil (MA).
 - Estimación del modelo e inferencia sobre los parámetros.
 - Obtención de valores del estadístico AIC para distintos modelos ajustados.
 - Selección del modelo ARIMA.

2. Análisis de Residuales y ajuste del modelo GARCH

- Despliegue del gráfico de residuales del modelo ARIMA ajustado (Diagnóstico de estacionariedad de los residuales).
- Despliegue de las funciones de autocorrelación y autocorrelación parcial para los residuales y residuales al cuadrado del modelo ajustado (Diagnostico de correlación de los residuales).
- Test de McLeod-Li para reforzar el diagnóstico de presencia de correlación en los residuales.
- Despliegue del grafico Q-Q y el test no-paramétrico Jarque-Bera para el diagnóstico de normalidad de los residuales.
- Despliegue de valores del estadístico AIC para distintos órdenes de modelos GARCH.
- Selección del modelo GARCH.

Como resultado de la implementación de la metodología de identificación anteriormente descrita se obtiene la Tabla 4.2, en ésta se presentan los valores estimados de los parámetros para cada modelo de contraste dentro de cada frecuencia de trabajo. En el caso de la frecuencia mensual se identifican como modelos de contraste el ARIMA(2,1,2) y GARCH(1,1), para la frecuencia anual se identifica el modelo ARIMA(0,1,2), en el caso de la frecuencia diaria se retuvieron el modelo ARIMA(1,1,2) y GARCH(1,1); finalmente para la frecuencia semanal se identificaron los modelos ARIMA(3,1,4) y GARCH(3,1).

TABLA 4.2. Parámetros estimados para los modelos RW, ARIMA y GARCH

Modelos de Contraste Serie Mensual WTI											
Modelo	AR(1)	AR(2)	AR(3)	MA(1)	MA(2)	MA(3)	MA(4)	GARCH(1)	GARCH(2)	GARCH(3)	ARCH(1)
RW				0,15							
ARIMA	0,60	-0,20		-0,55	0,42						
GARCH	0,62	-0,24		-0,53	-0,38			0,18			0,57

Modelos de Contraste Serie Anual WTI											
Modelo	AR(1)	AR(2)	AR(3)	MA(1)	MA(2)	MA(3)	MA(4)	GARCH(1)	GARCH(2)	GARCH(3)	ARCH(1)
RW				-0,1898							
ARIMA				0,4259	-0,5741						

Modelos de Contraste Serie Diaria WTI											
Modelo	AR(1)	AR(2)	AR(3)	MA(1)	MA(2)	MA(3)	MA(4)	GARCH(1)	GARCH(2)	GARCH(3)	ARCH(1)
RW				-0,0084							
ARIMA	0,6998			-0,7102	-0,0379						
GARCH	0,67			-0,68	-0,0323			$6,67e^{-6}$			$9,25e^{-2}$

Modelos de Contraste Serie Semanal WTI											
Modelo	AR(1)	AR(2)	AR(3)	MA(1)	MA(2)	MA(3)	MA(4)	GARCH(1)	GARCH(2)	GARCH(3)	ARCH(1)
RW				0,1055							
ARIMA	-0,54	-0,27	-0,66	0,65	0,29	0,76	0,20				
GARCH	-0,54	-0,27	-0,66	0,65	0,29	0,76	0,20	$7,24e^{-1}$	$1,19e^{-1}$	$8,48e^{-8}$	$9,12e^{-5}$

4.1.4. Ajuste ANN de contraste

De manera similar a la metodología planteada para encontrar la mejores arquitecturas ARNN por frecuencia de trabajo, se aplicó el mismo procedimiento para encontrar las mejores arquitecturas para los modelos ANN de contraste. Los resultados del ejercicio realizado pueden ser observados en las tablas B.1, B.2, B.3, B.4 de tal manera que las ANN de contraste que se retuvieron para el proceso de comparación se resumen tabla 4.3.

TABLA 4.3. Arquitecturas ANN seleccionadas por frecuencia de trabajo

Parámetros	Frecuencias			
	Mensual	Anual	Diaria	Semanal
P (Rezagos)	2	1	1	3
Q (Neuronas)	5	5	6	4

4.2. Comparación de Pronósticos

Debido a que hasta este punto se han generado los mejores modelos y definido las arquitecturas que mejor se ajustan a las series mensuales, anuales, diarias y semanales, en el presente apartado se pretende analizar el desempeño de cada modelo seleccionado para cada frecuencia en el conjunto de validación establecido. Para lograr lo anterior se retendrán dos medidas de error de pronóstico (RMSE y MAE) para cada modelo, lo cual ayudará a tener una mejor idea de que tan bien cada uno de estos modelos predicen valores futuros de cada serie cuando el tiempo avanza. Con el fin de tener una lectura más fácil se resaltaré el modelo con menores medidas de error de pronóstico.

Como se puede observar en la tabla 4.4 (Serie Mensual), en el caso del RMSE a horizontes menores o iguales a 3 meses el mejor pronóstico se obtendría a través del modelo GARCH, lo anterior sugiere que la presencia de no linealidad en la serie y alta volatilidad no son captados únicamente por la red neuronal sino también por modelos que capten la presencia de correlación en los residuales. Para los restantes horizontes,

TABLA 4.4. Medidas de evaluación de pronósticos bajo rolling (Serie Mensual)

HORIZONTE	P	Q	RMSE					MAE				
			ARNN	ARIMA	GARCH	RW	ANN	ARNN	ARIMA	GARCH	RW	ANN
1	2	3	9,69	11,91	9,64	22,39	9,73	6,48	9,83	6,87	16,22	6,53
2	2	3	9,21	11,27	9,12	20,67	9,25	6,32	9,86	6,89	15,14	6,59
3	2	3	9,48	11,85	9,39	22,38	9,53	6,09	10,41	7,28	16,16	6,84
4	2	3	8,69	11,85	9,59	21,31	8,73	6,27	10,55	7,37	15,53	6,92
5	2	3	8,65	11,83	9,57	21,53	8,77	6,17	10,52	7,35	16,04	6,81
6	2	3	8,19	11,85	9,59	21,64	8,54	6,06	10,53	7,36	15,73	6,92
7	2	3	7,78	11,99	9,70	22,07	8,23	6,12	10,60	7,41	16,07	7,01
8	2	3	7,69	12,33	9,98	21,14	8,44	5,86	10,72	7,49	15,75	6,44
9	2	3	7,92	12,43	10,06	21,09	8,25	5,72	10,76	7,52	15,98	6,65
10	2	3	8,02	13,79	11,16	21,24	8,39	6,61	11,09	7,75	15,60	6,89
11	2	3	7,85	9,72	7,87	21,97	8,21	6,03	9,63	6,73	15,43	6,66
12	2	3	7,92	9,73	7,87	21,45	8,45	5,83	9,64	6,74	15,87	6,46

TABLA 4.5. Medidas de evaluación de pronósticos bajo rolling (Serie Anual)

HORIZONTE	P	Q	RMSE					MAE				
			ARNN	ARIMA	GARCH	RW	ANN	ARNN	ARIMA	GARCH	RW	ANN
1	3	1	33,22	28,73		34,98	31,72	29,53	28,12		30,71	29,31
2	3	1	30,15	27,19		34,80	29,54	28,82	28,21		28,04	28,71
3	3	1	28,36	28,58		34,52	28,14	27,75	27,61		30,07	27,70
4	3	1	28,67	28,59		34,14	28,01	28,59	28,40		30,64	28,30
5	3	1	28,54	28,53		32,96	28,30	28,10	27,91		30,11	28,01

TABLA 4.6. Medidas de evaluación de pronósticos bajo rolling (Serie Diaria)

HORIZONTE	P	Q	RMSE					MAE				
			ARNN	ARIMA	GARCH	RW	ANN	ARNN	ARIMA	GARCH	RW	ANN
1	2	2	1,89	3,19	2,91	7,02	2,09	1,39	2,71	2,33	4,81	1,89
2	2	2	1,72	3,02	2,75	6,87	2,61	1,36	2,72	2,34	4,61	1,92
3	2	2	1,61	3,17	2,89	6,60	2,54	1,31	2,87	2,47	4,68	1,88
4	2	2	1,63	3,17	2,90	6,72	2,61	1,35	2,91	2,50	4,71	1,79
5	2	2	1,62	3,17	2,89	6,72	2,72	1,32	2,90	2,49	4,70	1,88
6	2	2	1,52	3,17	2,90	6,97	2,53	1,30	2,90	2,50	4,53	1,92
7	2	2	1,54	3,21	2,93	6,84	2,72	1,31	2,92	2,51	4,74	1,93
8	2	2	1,51	3,30	3,01	6,86	2,66	1,26	2,96	2,54	4,77	1,95
9	2	2	1,46	3,33	3,04	6,95	2,77	1,23	2,97	2,55	4,66	1,87
10	2	2	1,70	3,69	3,37	6,97	2,89	1,42	3,06	2,63	4,78	1,70
11	2	2	1,57	2,60	2,37	6,96	2,48	1,29	2,66	2,28	4,64	1,93
12	2	2	1,59	2,60	2,38	6,85	2,42	1,25	2,66	2,28	4,75	1,92

TABLA 4.7. Medidas de evaluación de pronósticos bajo rolling (Serie Semanal)

HORIZONTE	P	Q	RMSE					MAE				
			ARNN	ARIMA	GARCH	RW	ANN	ARNN	ARIMA	GARCH	RW	ANN
1	2	4	3,34	6,72	4,02	11,23	3,59	2,67	4,97	3,51	8,71	2,89
2	2	4	3,03	6,36	3,80	10,27	3,66	2,61	4,99	3,52	8,13	2,99
3	2	4	2,85	6,68	4,00	11,16	3,44	2,51	5,27	3,72	8,47	2,76
4	2	4	2,88	6,69	4,00	10,65	3,26	2,58	5,33	3,77	8,50	2,87
5	2	4	2,87	6,67	3,99	10,93	3,17	2,54	5,32	3,76	8,59	2,91
6	2	4	2,69	6,69	4,00	10,64	3,67	2,50	5,33	3,76	8,32	3,01
7	2	4	2,73	6,76	4,05	10,78	3,27	2,52	5,36	3,79	8,29	3,10
8	2	4	2,66	6,96	4,16	11,08	3,89	2,41	5,42	3,83	8,27	3,09
9	2	4	2,58	7,01	4,20	10,99	3,71	2,36	5,44	3,84	8,71	2,92
10	2	4	3,01	7,78	4,65	11,03	3,61	2,73	5,61	3,96	8,52	2,96
11	2	4	2,78	5,48	3,28	10,70	3,40	2,48	4,87	3,44	8,39	3,15
12	2	4	2,81	5,49	3,28	10,89	3,31	2,40	4,87	3,44	8,30	3,21

claramente se obtienen reducciones del error de pronóstico al considerar arquitectura de la red neuronal artificial autorregresiva propuesta. En lo referente a la medida MAE, claramente se observa, para todo horizonte, la ventaja de trabajar con redes neuronales

artificiales autorregresivas. Tanto el RMSE como el MAE sugieren la baja conveniencia de trabajar con modelos lineales como el modelo ARIMA.

Al analizar con mayor profundidad los resultados exhibidos para la frecuencia anual, la serie presenta la menor cantidad de picos o valores extremos en comparación de las demás series, es decir, se puede hablar de una serie suavizada para la cual como se observa en el cuadro 4.2 no se ajustó un modelo GARCH debido a la no existencia de correlación en los residuales del modelo ajustado. Por otra parte al analizar los resultados del Rolling propuesto para esta frecuencia trabajo (cuadro 4.5) se observa indistintamente del horizonte de pronóstico un desempeño superior del modelo lineal ARIMA así como un mejor desempeño de la ANN sobre la ARNN. La explicación de lo anterior se debe a que la serie anual presenta pocos picos de activación que sean tenidos en cuenta por la ARNN, además del cumplimiento de muchos de los supuestos de los modelos clásicos para ésta serie.

Por otra parte las series de más alta frecuencia como las series diaria y semanal exhibieron el comportamiento esperado en torno a los distintos modelos ajustados, las redes neuronales ARNN(2,2) y ARNN(2,4) tuvieron el mejor desempeño por encima de la caminata aleatoria, el modelo clásico ARIMA, el modelo GARCH y la red neuronal ANN no importando el horizonte de pronóstico evaluado. En estos dos casos la ARNN ajustada se activa en múltiples puntos extremos de ambas series lo cual permite un mejor reconocimiento del comportamiento de las mismas.

En general la presencia de no linealidad en las series trabajadas, así como la presencia de puntos de alta volatilidad y no estacionariedad en las series hacen de las redes neuronales autorregresivas planteadas mejores modelos para el pronóstico de observaciones futuras. Por otra parte a medida que las series disminuyen su frecuencia y la presencia de altos puntos de volatilidad otros tipo de modelos pueden llegar a ser tan efectivos como la ARNN.

Conclusiones y trabajo futuro

5.1. Conclusiones

Este trabajo compara pronósticos provenientes de un modelo no lineal (Red Neuronal Artificial Autorregresiva) con los de una camita aleatoria (RW), un modelo lineal tradicional (ARIMA), un modelo condicional heterocedástico autoregresivo (GARCH) y una red neuronal artificial (ANN) para diferentes frecuencias de observación de la serie de precios de mercado del crudo WTI. Los pronósticos se obtienen a través de la metodología Rolling y su evaluación se lleva a cabo con respecto a medidas de error de pronóstico como el RMSE y el MAE. A continuación se presentan las principales conclusiones del ejercicio:

- La metodología general del modelamiento de series de tiempo con presencia de no linealidad, alta volatilidad y correlación en los residuales acoge como principales candidatos a los modelos ARCH y GARCH. Sin embargo el realizar el modelamiento de las distintas frecuencias a través de una red neuronal autorregresiva la cual, debido a su arquitectura, supere las condiciones de alta volatilidad y autocorrelación serial en los residuales captura mejor los cambios en el nivel de la serie así como puntos de alta volatilidad incluso superando al modelo ANN.
- La Red Neuronal Autorregresiva simula mejor que los modelos ARIMA la volatilidad que tiene la serie de precios del crudo WTI a lo largo del tiempo, a pesar de que los pronósticos que genera no son de alta precisión, se percibe que con un desarrollo más riguroso del paquete ARNN implementado o de otro paquete u otro software se puede llegar a construir una arquitectura ARNN con la que se logren los pronósticos deseados.
- En el caso de las frecuencias mensual, diaria y semanal de serie de precios de crudo WTI, se observó que las redes neuronales artificiales tuvieron mejor desempeño en cuanto las medidas de error de pronóstico MAE y RMSE sin importar el horizonte de pronóstico evaluado. Cabe resaltar que para la serie mensual el desempeño para horizontes pequeños 1 a 3 meses la red no superó el desempeño revelado por el modelo GARCH ajustado.
- Se encontraron resultados consistentes y estables derivados de la adaptación del paquete ARNN del software estadístico R para la estimación de los parámetros de

las redes ajustadas, donde se utilizó la parametrización por defecto del paquete y se seleccionó la función adaptativa como función de transferencia.

- El trabajo con Redes Neuronales Artificiales es muy importante para las Ciencias Económicas debido a sus características de cálculo en paralelo, memoria distribuida y adaptabilidad sobre las series de tiempo que se pretenden modelar.

5.2. Trabajo futuro

- Emplear las redes neuronales artificiales con otro tipo de modelos como los de lógica difusa fuzzy models o wavelets para tratar de analizar la potencialidad de las técnicas híbridas resultantes frente a los modelos clásicos más empleados en el modelamiento de la serie de precios del crudo WTI.
- Incluir variables explicativas complementarias en la ARNN ajustada. Algunas de estas pueden ser el consumo de crudo, la producción mundial, el volumen de reservas, el volumen de importaciones netas, el porcentaje de crudo utilizado para refinamiento, los contratos futuros de crudo NYMEX.
- Mejorar los resultados de las redes neuronales aplicadas en este estudio empleando máquinas vectoriales y diferentes tipos de RNA dentro de un mismo modelo.
- Desarrollar un método de estimación directa de los parámetros de la red neuronal para producir las series sintéticas y los estadísticos de almacenamiento y sequía de forma rápida sin necesidad de explorar todo el espacio estudiado durante la fase de entrenamiento de las mismas (como puede ser el caso de generar un algoritmo de barrido automático de todo el espacio de trabajo para encontrar el óptimo de forma automática en la fase de calibración).

APÉNDICE A

Tablas de Resultados ARNN

A.1. Estadísticos para selección de arquitecturas ARNN

TABLA A.1. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie mensual de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Entrenamiento					
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>	<i>MASE</i>
2	1	9,240E-08	1,931869028	1,411893889	0,069703953	6,199110461	0,968261657
2	2	-5,962E-08	1,931869028	1,411893887	0,069703306	6,199110455	0,968261655
2	3	-2,831E-09	1,931869026	1,411893924	0,069703287	6,199110625	0,968261681
2	4	-1,128E-07	1,931869002	1,411893878	0,069702492	6,199110362	0,968261649
2	5	-8,514E-07	1,931868627	1,411893698	0,069691568	6,199108913	0,968261526
2	6	-7,297E-06	1,931867564	1,411893228	0,069639723	6,199105216	0,968261203
3	1	-1,266E-04	1,881718139	1,372061304	0,019431756	6,101380532	0,954035461
3	2	-9,220E-06	1,919879445	1,401365507	0,08321181	6,236334618	0,974411554
3	3	-1,240E-07	1,919880845	1,401366191	0,083297988	6,236341993	0,974412029
4	4	-1,266E-06	1,919880911	1,401366219	0,083294592	6,236342051	0,974412049
3	5	7,341E-07	1,919880913	1,401366214	0,083306214	6,236342473	0,974412045
3	6	-5,202E-03	1,797677102	1,322365224	0,022479597	6,05660641	0,919480283
4	1	-2,073E-07	1,921635486	1,413185369	0,116992602	6,361038357	0,982246332
4	2	-4,737E-08	1,921635489	1,413185426	0,116993766	6,361038717	0,982246371
4	3	-1,112E-06	1,921631778	1,413179933	0,116960546	6,361003335	0,982242553
4	4	-6,494E-07	1,921635488	1,413185410	0,116989043	6,36103847	0,98224636
4	5	-2,337E-06	1,921635489	1,413185372	0,116974893	6,361037941	0,982246334
4	6	-1,195E-06	1,921635101	1,413185136	0,116987633	6,36103647	0,98224617
5	1	-1,789E-03	1,808384458	1,343812542	0,175388653	6,12878268	0,940511337
5	2	-1,522E-07	1,899166432	1,411745550	0,162203733	6,385377269	0,988056484
5	3	5,385E-08	1,899166411	1,411745477	0,162204761	6,385376951	0,988056432
5	4	-3,065E-04	1,743069938	1,315542097	0,034493916	5,970863843	0,920725338
5	5	-5,315E-04	1,658423680	1,273757583	-0,005079629	5,874626411	0,891481074
5	6	-4,013E-02	1,641251209	1,234215125	-0,092955943	5,742041788	0,863805986
6	1	1,853E-03	1,712592462	1,287230515	-0,003977599	5,984054622	0,911899243
6	2	-4,422E-04	1,586854927	1,214595641	0,128194405	5,713858598	0,860443279
6	3	-5,351E-03	1,509583062	1,151403460	-0,016929565	5,528428879	0,815676703
6	4	4,697E-03	1,469135208	1,092763289	0,017580188	5,262747894	0,774134861
6	5	5,028E-03	1,384533032	1,035108469	0,076067326	5,005663078	0,73329106
6	6	2,358E-03	1,398172318	1,033719250	0,018709825	4,988247077	0,73230691

TABLA A.2. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie mensual de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Validación				
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>
(2	1)	1,220141205	8,27830227	5,94468893	1,028449008	7,416489581
(2	2)	1,220140471	8,278302222	5,944688972	1,028448123	7,416489675
(2	3)	1,220142719	8,2782961	5,944684258	1,028451092	7,416483624
(2	4)	1,220142681	8,278302093	5,944688653	1,028450758	7,416489155
(2	5)	1,220163434	8,278307683	5,944690626	1,028475253	7,416490516
(2	6)	1,220202817	8,278311044	5,944689089	1,028521895	7,416486481
(3	1)	-1,077460754	10,86411684	8,017508059	-2,192801141	9,824328702
(3	2)	0,694919795	12,20141903	8,611409824	-0,263380053	10,44113538
(3	3)	0,694801031	12,20139916	8,611416919	-0,263520411	10,44115205
(4	4)	0,694791853	12,20139752	8,611417935	-0,263531092	10,44115422
(3	5)	0,694781493	12,20139009	8,611414186	-0,263542744	10,44115017
(3	6)	-3,04170246	11,46127348	8,684349819	-4,172597898	10,52627578
(4	1)	0,426064958	15,8330633	11,11740169	-1,361856514	13,3453923
(4	2)	0,426062902	15,83306137	11,11740081	-1,361858772	13,34539131
(4	3)	0,425978753	15,83312687	11,1174657	-1,361964017	13,3454755
(4	4)	0,426075009	15,8330618	11,11739837	-1,361844405	13,34538749
(4	5)	0,426114921	15,83306422	11,11739111	-1,361797224	13,34537525
(4	6)	0,426043023	15,8330619	11,11740568	-1,361882518	13,34539864
(5	1)	5,470216519	23,95916684	11,04873034	3,750146931	12,28545371
(5	2)	-0,354979986	18,41471794	12,62201292	-3,022770999	15,14434051
(5	3)	-0,354981593	18,41471941	12,62201437	-3,022773056	15,14434238
(5	4)	-4,113226702	14,50713738	10,95091725	-6,795474198	13,42469207
(5	5)	-3,981781659	11,03302211	9,196442676	-6,238449323	11,36415547
(5	6)	3,13158355	12,42636605	7,543588472	1,824163252	8,832149182
(6	1)	-160788,6805	1690168,731	160805,4447	-272303,8016	272320,2838
(6	2)	-143,1596747	608,5161265	172,4463625	-183,4394058	213,8356843
(6	3)	-7505,322729	94055,06226	15375,01158	-8505,422936	16520,89381
(6	4)	13473,69732	75925,54597	13542,0197	13954,97856	14026,42145
(6	5)	-30,97992965	2045,532064	484,5685828	-146,659792	552,2331677
(6	6)	4145,403427	49513,92845	6093,554384	8045,813337	11299,86987

TABLA A.3. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie anual de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Entrenamiento					
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>	<i>MASE</i>
2	1	0,0079	3,3104	2,4197	0,1304	12,7629	0,6858
2	2	0,0117	2,7067	2,0887	0,0307	10,4713	0,5920
2	3	-0,0059	2,6704	2,0282	-0,0902	10,1168	0,5749
2	4	-0,0054	1,6087	1,2211	-0,0090	6,6959	0,3461
2	5	0,0391	1,9176	1,1785	0,2081	6,6584	0,3340
3	1	-0,0000001	3,9557	3,4255	-0,0678	17,2989	0,9135
3	2	-0,0012	0,9603	0,7174	0,0143	3,5561	0,1913
3	3	-0,0035	0,6621	0,4782	-0,0267	2,4312	0,1275
3	4	-0,0049	0,5638	0,4050	0,0105	2,1481	0,1080
3	5	-0,0064	0,7752	0,5654	-0,0530	2,6946	0,1508

TABLA A.4. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie anual de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Validación				
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>
2	1	-951673,1151	1487665,2266	951673,1151	-1070322,4136	1070322,4136
2	2	-6232199,0587	10007127,5913	6232199,0587	-7016897,8831	7016897,8831
2	3	-2556477,5059	4028843,7379	2556477,5059	-2887881,1175	2887881,1175
2	4	-105,9152	107,8238	105,9152	-135,7230	135,7230
2	5	17674311577,23	49996361537,66	17678454595,91	17732675859,08	17737140708,74
3	1	-26,3466	30,7709	28,2336	-36,9960	39,6045
3	2	-25522,7229	65419,9773	25550,1533	-26021,0569	26059,6549
3	3	-145,0443	221,8491	145,0443	-204,1882	204,1882
3	4	-227721,9168	535545,7280	364686,9596	-236891,7855	426226,9290
3	5	-34,6732	48,8793	44,6395	-54,0080	64,0073

TABLA A.5. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie diaria de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Entrenamiento					
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>	<i>MASE</i>
2	1	-1,14E-06	1,093376144	0,634746551	-0,008310071	1,784005256	1,000103672
2	2	0,001431782	1,09098837	0,634390099	0,001615252	1,783870747	0,999542049
2	3	-0,000827039	1,076105824	0,631855198	0,004916689	1,780895549	0,99554807
2	4	0,001623328	1,078317749	0,632790583	0,013698294	1,782675462	0,997021859
3	1	-1,13E-07	1,09210432	0,635519776	-0,008062081	1,785032419	1,001779424
3	2	0,000260671	1,083984351	0,634610903	0,005077151	1,785750276	1,000346753
3	3	0,000631799	1,074335226	0,631626534	0,023682163	1,781026348	0,995642447
3	4	0,002363004	1,075927478	0,632353277	0,022369809	1,782030861	0,996788024
4	1	1,55E-07	1,091750118	0,63572114	-0,011461379	1,785766623	1,002439539
4	2	3,22E-08	1,091750118	0,635721126	-0,011461056	1,785766576	1,002439516
4	3	9,68E-08	1,091750118	0,635721134	-0,011461099	1,785766601	1,002439528
4	4	-6,26E-08	1,091750118	0,63572114	-0,011461682	1,785766629	1,002439538
5	1	1,18E-06	1,091312461	0,63479478	-0,012653499	1,785803713	1,000884566
5	2	1,67E-07	1,091312446	0,634794852	-0,012657137	1,785803777	1,000884679
5	3	2,35E-07	1,091312435	0,634794838	-0,01265754	1,78580363	1,000884658
5	4	5,81E-08	1,091312445	0,634794864	-0,012657323	1,785803844	1,000884698
6	1	3,90E-07	1,089633281	0,634918894	-0,012212172	1,787211492	1,001442484
6	2	-3,76E-07	1,089633282	0,634918957	-0,012216066	1,787211812	1,001442584
6	3	1,57E-06	1,089633282	0,634918746	-0,012200295	1,787211681	1,001442251
6	4	3,79E-06	1,089633248	0,634918718	-0,012197416	1,787210718	1,001442207
7	1	1,86E-06	1,08970862	0,634960692	-0,013880132	1,785406032	1,001473046
7	2	-1,31E-06	1,08970862	0,634960665	-0,013900183	1,785405986	1,001473003
7	3	1,40E-06	1,08970862	0,634960649	-0,013881801	1,785406074	1,001472978
7	4	-4,59E-07	1,08970862	0,634960745	-0,013894294	1,785406258	1,00147313
8	1	-1,18E-06	1,089474315	0,635040923	-0,013453592	1,785938388	1,001554386
8	2	6,58E-08	1,089474315	0,635041131	-0,013445347	1,78593901	1,001554714
8	3	-2,29E-07	1,089474315	0,635041115	-0,013446952	1,785939099	1,001554742
8	4	-2,95E-08	1,089474315	0,635041102	-0,013445972	1,785938939	1,001554667

TABLA A.6. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie diaria de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Validación				
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>
2	1	0,063168448	1,419353562	1,05543563	0,068612957	1,214045806
2	2	0,040265464	1,414672189	1,049321004	0,045765312	1,206709402
2	3	-0,022485883	1,451116392	1,085326689	-0,021258156	1,248305793
2	4	0,034296557	1,473903881	1,09740745	0,037186897	1,263421122
3	1	0,105504773	1,897075476	1,419523447	0,118507997	1,615638181
3	2	0,07232271	1,93662183	1,448663762	0,083889934	1,646155331
3	3	0,023878072	1,942312437	1,459288911	0,031603884	1,660969323
3	4	0,102036957	1,966956727	1,473643295	0,112099284	1,675667704
4	1	0,159386182	2,395458748	1,823362035	0,177468845	2,076981063
4	2	0,159384963	2,395458509	1,823361932	0,177467548	2,076980943
4	3	0,159385432	2,395458696	1,823362043	0,177468049	2,076981074
4	4	0,159385216	2,395458956	1,82336225	0,177467811	2,076981316
5	1	0,213458199	2,786932538	2,135850219	0,240084902	2,419558153
5	2	0,213456979	2,786931392	2,135849315	0,240083524	2,419557115
5	3	0,213457523	2,786931267	2,135849197	0,240084106	2,41955698
5	4	0,213457517	2,78693099	2,135848992	0,24008406	2,419556745
6	1	0,258045383	3,072785542	2,362403145	0,29220596	2,674596485
6	2	0,258045683	3,072784954	2,362402703	0,29220623	2,674595955
6	3	0,258036903	3,07278258	2,362401146	0,292197046	2,674593982
6	4	0,258044507	3,072780401	2,362399295	0,292205236	2,67459192
7	1	0,311176039	3,365048074	2,589725742	0,352471161	2,942502889
7	2	0,311182532	3,365047862	2,589725436	0,352477882	2,942502452
7	3	0,311175371	3,365048589	2,589726196	0,352470446	2,942503323
7	4	0,311180227	3,365048935	2,589726374	0,3524755	2,942503515
8	1	0,364197935	3,635246845	2,801491558	0,415071829	3,169469629
8	2	0,36419508	3,635248879	2,801493292	0,415068891	3,169471599
8	3	0,364195335	3,635248789	2,801493235	0,415069145	3,169471531
8	4	0,364195307	3,63524886	2,801493259	0,415069126	3,169471558

TABLA A.7. Resultados en el conjunto de entrenamiento de diferentes arquitecturas ARNN para la serie semanal de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Entrenamiento					
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>	<i>MASE</i>
2	1	-1,73779E-07	1,880159	1,160138	-0,05179	3,256114	0,984360
2	2	0,00826176	1,801689	1,149638	0,01029	3,253642	0,975452
2	3	0,002136856	1,793730	1,144920	0,02764	3,249226	0,971448
2	4	-0,013929323	1,796826	1,136146	-0,04227		
3	1	7,83848E-05	1,791069	1,137205	-0,00613	3,248344	0,966131
3	2	-0,00069189	1,786284	1,130815	-0,00335	3,233731	0,960703
3	3	0,000932729	1,754055	1,123555	0,00681	3,223663	0,954535
3	4	-1,978481438	1,740301	1,111667	-0,00430	3,196278	0,944435
4	1	0,002943055	1,826149	1,144561	0,01523	3,254434	0,974254
4	2	-0,003234834	1,762947	1,124997	-0,03985	3,219907	0,957601
4	3	-0,004849398	1,824950	1,145659	-0,02680	3,259681	0,975189
4	4	-1,97843E-05	1,871422	1,154295	-0,06033	3,244708	0,982540
5	1	2,74358E-06	1,870911	1,155424	-0,05875	3,241223	0,983308
5	2	-1,38027E-05	1,870911	1,155424	-0,05884	3,241225	0,983308
5	3	-5,05983E-06	1,870911	1,155424	-0,05878	3,241223	0,983308
5	4	2,29768E-05	1,870911	1,155423	-0,05867	3,241220	0,983307
6	1	2,24931E-06	1,866840	1,156141	-0,07616	3,246956	0,984042
6	2	2,98351E-06	1,866840	1,156141	-0,07615	3,246956	0,984041
6	3	-0,002005229	1,776906	1,122935	-0,02099	3,196332	0,955779
6	4	0,000198841	1,820278	1,129337	-0,04938	3,176230	0,961228
7	1	1,38357E-06	1,867514	1,156999	-0,08597	3,250371	0,985016
7	2	2,12102E-06	1,867514	1,156999	-0,08597	3,250371	0,985016
7	3	-0,000175379	1,786949	1,110911	-0,05578	3,165985	0,945778
7	4	-0,00015583	1,792550	1,115986	0,02864	3,192030	0,950099
8	1	-0,001158567	1,769042	1,127170	-0,05547	3,207471	0,960056
8	2	3,9911E-05	1,831593	1,135053	-0,09971	3,204360	0,966771
8	3	-0,000451426	1,822952	1,135386	-0,08921	3,198309	0,967055
8	4	-0,00014689	1,823599	1,135382	-0,08419	3,187865	0,967051

TABLA A.8. Resultados en el conjunto validación de diferentes arquitecturas ARNN para la serie semanal de precios de mercado del crudo WTI

Rezagos	Nodos	Estadísticas en el conjunto de Validación				
		<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>
2	1	0,321882	2,872396	2,187468	0,393459	2,481297
2	2	0,100077	3,105195	2,348333	0,180084	2,664874
2	3	0,136198	3,209836	2,439947	0,206586	2,766513
2	4	0,116157	2,973312	2,246704	0,165509	2,542442
3	1	0,283047	4,271597	3,369521	0,353072	3,822880
3	2	0,282942	4,234428	3,339844	0,351588	3,791900
3	3	0,365390	4,396865	3,467798	0,442307	3,937086
3	4	0,241292	4,353109	3,406683	0,312688	3,865805
4	1	0,685962	5,534244	4,439849	0,780109	5,042246
4	2	0,788583	5,457594	4,363592	0,865812	4,966389
4	3	0,697471	5,531901	4,438308	0,790069	5,038671
4	4	0,863369	5,674408	4,548201	0,966628	5,167518
5	1	1,098509	6,678848	5,387701	1,213580	6,085149
5	2	1,098527	6,678849	5,387702	1,213598	6,085149
5	3	1,098504	6,678848	5,387702	1,213574	6,085149
5	4	1,098523	6,678855	5,387707	1,213595	6,085155
6	1	1,333569	7,581314	5,981709	1,487451	6,701344
6	2	1,333563	7,581313	5,981708	1,487445	6,701344
6	3	1,102486	7,411833	5,872176	1,222718	6,555246
6	4	1,409037	7,653466	6,030380	1,569015	6,752063
7	1	1,554953	8,461512	6,381225	1,726373	7,109074
7	2	1,554951	8,461512	6,381225	1,726371	7,109074
7	3	1,375869	8,347030	6,236545	1,551227	6,965259
7	4	1,251456	8,276479	6,242591	1,392693	6,951747
8	1	1,246634	8,747092	6,669765	1,382733	7,358252
8	2	1,839088	9,370519	7,081665	2,018588	7,820700
8	3	1,867747	9,497969	7,158956	2,051601	7,904345
8	4	1,855992	9,477070	7,144507	2,039282	7,888633

APÉNDICE B

Tablas de Resultados ANN

B.1. Estadísticos para selección de arquitecturas ANN: Precio de mercado del crudo e índices *DXY* y *S&P500*

TABLA B.1. Resultados en el conjunto de entrenamiento y validación de diferentes arquitecturas ANN: Precio de mercado del crudo e índices *DXY* y *S&P500*. Serie mensual de precios de mercado del crudo WTI

Rezagos	Nodos	Conjunto de Entrenamiento		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	0,9721	0,8173	0,7871
1	4	0,9196	0,7324	0,7149
1	5	0,9229	0,7621	0,7080
1	6	0,8809	0,7171	0,6733
2	3	0,8459	0,7098	0,6616
2	4	0,7579	0,6421	0,5861
2	5	0,6060	0,5324	0,4633
2	6	0,8765	0,6821	0,6414
3	4	0,9123	0,7921	0,7248
3	3	0,7771	0,6172	0,5492
3	4	1,8164	0,6591	0,6163
3	5	0,9251	0,7941	0,7435
4	3	0,8545	0,7401	0,6877
4	4	0,6098	0,5561	0,4651
4	5	0,9580	0,8421	0,8184
4	6	0,8610	0,7371	0,6875

Rezagos	Nodos	Conjunto de Validación		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	0,9924	0,8421	0,8073
1	4	0,9534	0,7524	0,7561
1	5	0,9621	0,7891	0,73848
1	6	0,9132	0,7376	0,6938
2	3	0,8529	0,7461	0,7024
2	4	0,7797	0,6712	0,6129
2	5	0,6429	0,5521	0,4831
2	6	0,8969	0,7012	0,6621
3	4	0,9234	0,8124	0,7623
3	3	0,7981	0,6627	0,5781
3	4	1,8942	0,6881	0,6561
3	5	0,9561	0,8131	0,7728
4	3	0,8871	0,768901	0,7071
4	4	0,6423	0,5816	0,4921
4	5	0,9723	0,8789	0,8371
4	6	0,8834	0,7790	0,7152

TABLA B.2. Resultados en el conjunto de entrenamiento y validación de diferentes arquitecturas ANN: Precio de mercado del crudo e índices *DXY* y *S&P500*. Serie anual de precios de mercado del crudo WTI

Rezagos	Nodos	Conjunto de Entrenamiento		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	1,3421	1,5734	1,5571
1	4	1,2669	1,5871	1,5702
1	5	1,2450	1,5632	1,5503
1	6	1,2738	1,5861	1,5732
2	3	1,2892	1,5791	1,5641
2	4	1,2940	1,5931	1,5829
2	5	1,2871	1,6001	1,5807
2	6	1,2961	1,6161	1,6014
3	4	1,3004	1,6107	1,5921
3	3	1,3142	1,6251	1,6039
3	4	1,3198	1,6341	1,6171
3	5	1,3352	1,6481	1,6237
4	3	1,3421	1,6328	1,6289
4	4	1,3561	1,6571	1,6451
4	5	1,3451	1,6629	1,6499
4	6	1,3591	1,6702	1,6621

Rezagos	Nodos	Conjunto de Validación		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	1,3421	1,5734	1,5571
1	4	1,2669	1,5871	1,5702
1	5	1,2450	1,5632	1,5503
1	6	1,2738	1,5861	1,5732
2	3	1,2892	1,5791	1,5641
2	4	1,2940	1,5931	1,5829
2	5	1,2871	1,6001	1,5807
2	6	1,2961	1,6161	1,6014
3	4	1,3004	1,6107	1,5921
3	3	1,3142	1,6251	1,6039
3	4	1,3198	1,6341	1,6171
3	5	1,3352	1,6481	1,6237
4	3	1,3421	1,6328	1,6289
4	4	1,3561	1,6571	1,6451
4	5	1,3451	1,6629	1,6499
4	6	1,3591	1,6702	1,6621

TABLA B.3. Resultados en el conjunto de entrenamiento y validación de diferentes arquitecturas ANN: Precio de mercado del crudo e índices *DXY* y *S&P500*. Serie semanal de precios de mercado del crudo WTI

Rezagos	Nodos	Conjunto de Entrenamiento		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	1,1522	1,2516	1,2510
1	4	1,1523	1,2617	1,2522
1	5	1,1583	1,2815	1,2531
1	6	1,1621	1,2614	1,2581
2	3	1,1682	1,2681	1,2541
2	4	1,1671	1,2718	1,2608
2	5	1,1734	1,2671	1,2577
2	6	1,1708	1,2701	1,2644
3	4	1,1509	1,2501	1,2503
3	3	1,1577	1,2609	1,2601
3	4	1,1678	1,2675	1,2631
3	5	1,1704	1,2701	1,2689
4	3	1,1634	1,2709	1,2676
4	4	1,1809	1,2806	1,2761
4	5	1,1789	1,2843	1,2789
4	6	1,1690	1,2794	1,2691

Rezagos	Nodos	Conjunto de Validación		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	1,1921	1,2731	1,2610
1	4	1,2123	1,2799	1,2608
1	5	1,2283	1,2931	1,2634
1	6	1,2121	1,2914	1,2799
2	3	1,2082	1,2844	1,2703
2	4	1,2071	1,2850	1,2777
2	5	1,2134	1,2899	1,2701
2	6	1,2108	1,2910	1,2801
3	4	1,1909	1,2701	1,2602
3	3	1,2177	1,2821	1,2701
3	4	1,2278	1,2901	1,2732
3	5	1,2004	1,2879	1,2734
4	3	1,2134	1,2989	1,2899
4	4	1,2009	1,2816	1,2718
4	5	1,2189	1,2910	1,2814
4	6	1,2190	1,2999	1,2288

TABLA B.4. Resultados en el conjunto de entrenamiento y validación de diferentes arquitecturas ANN: Precio de mercado del crudo e índices *DXY* y *S&P500*. Serie diaria de precios de mercado del crudo WTI

Rezagos	Nodos	Conjunto de Entrenamiento		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	1,5222	1,5871	1,5672
1	4	1,5223	1,5931	1,5821
1	5	1,5383	1,6001	1,5891
1	6	1,5208	1,5708	1,5651
2	3	1,5382	1,5891	1,5789
2	4	1,5471	1,5901	1,5810
2	5	1,5331	1,6021	1,5901
2	6	1,5421	1,5914	1,5821
3	4	1,5409	1,6071	1,5918
3	3	1,5499	1,6114	1,6010
3	4	1,5521	1,6171	1,6001
3	5	1,5601	1,6214	1,6111
4	3	1,5534	1,6271	1,6115
4	4	1,5671	1,6171	1,6022
4	5	1,5621	1,6261	1,6114
4	6	1,5714	1,6371	1,6311

Rezagos	Nodos	Conjunto de Validación		
p	q	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
1	3	1,6224	1,7210	1,6817
1	4	1,6231	1,7214	1,6944
1	5	1,634183	1,7310	1,6966
1	6	1,6310	1,7198	1,6810
2	3	1,6344	1,7289	1,6944
2	4	1,6421	1,7218	1,7071
2	5	1,6420	1,7289	1,7112
2	6	1,6456	1,7365	1,7120
3	4	1,6589	1,7317	1,7214
3	3	1,6510	1,7489	1,7321
3	4	1,6522	1,7499	1,7344
3	5	1,6517	1,7411	1,7310
4	3	1,6627	1,7512	1,7411
4	4	1,6614	1,7518	1,7410
4	5	1,6718	1,7699	1,7510
4	6	1,6714	1,7618	1,7506

APÉNDICE C

Estimación de parámetros y caracterización de modelos de contraste

C.1. Caracterización de arquitecturas ARNN seleccionadas

A continuación se presenta la caracterización de las redes neuronales artificiales autorregresivas seleccionadas como modelo de pronóstico para cada frecuencia de trabajo de la serie precios de mercado de crudo WTI:

Serie Mensual

Parámetros:

M	Wio[1]	Wio[2]	Wih[1,1]	Wih[2,1]	Wih[1,2]	Wih[2,2]
-0.42499635	1.18227959	-0.20301215	0.60861203	0.51628211	0.61815248	0.52465817
Wih[1,3]	Wih[2,3]	Wbh[1]	Wbh[2]	Wbh[3]	Who[1]	Who[2]
0.59483519	0.50735479	0.02200701	0.02282060	0.02175295	0.07995570	0.07993431
Who[3]	Wbo					
0.08357403	0.34929157					

Sigma² estimado: 3.74834453483648

LogL: -476.727409751757

Information Criteria:

AK	AKc	HQ	SC
985.4548	988.0209	1007.6188	1040.3944

In-sample error measures:

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
----	------	-----	-----	------	------	------

Training set -2.8306e-09 1.9318 1.4118 0.069703 6.1991 0.96826 0.0096282

Out-sample error measures:

	ME	RMSE	MAE	MPE	MAPE
Test set	1.220143	8.278296	5.944684	1.028451	7.416484

Serie Anual

Parámetros:

M	Wio[1]	Wio[2]	Wio[3]	Wih[1,1]	Wih[2,1]
-0.430667214	1.050128625	-0.481430180	0.730667708	0.417476289	0.389606844
Wih[3,1]	Wbh[1]	Who[1]	Wbo		
0.320829797	-0.007238768	-2.096367765	-2.095891102		

Sigma² estimated as: 16.6911546836345

LogL: -37.7429139080264

Information Criteria:

AK	AKc	HQ	SC
95.48583	205.48583	94.32460	101.13532

In-sample error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	-6.5932e-08	3.9557	3.4255	-0.067752	17.29893	0.91346	-0.0089565

Out-sample error measures:

	ME	RMSE	MAE	MPE	MAPE
Test set	-26.3466	30.77094	28.23358	-36.99601	39.6045

Serie Diaria

Parametros:

M	Wio[1]	Wio[2]	Wih[1,1]	Wih[2,1]	Wih[1,2]
-0.857113492	0.833132302	0.168384921	-0.002092652	0.003969655	0.125029487
Wih[2,2]	Wbh[1]	Wbh[2]	Who[1]	Who[2]	Wbo
-0.125377845	-0.129446538	-0.341017743	0.714474041	-0.892075150	0.539577283

Sigma² estimated as: 1.19044053297449

LogL: -9693.76121158765

Information Criteria:

AK	AKc	HQ	SC
----	-----	----	----

19411.52 19411.57 19439.63 19492.76

In-sample error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	0.0014317	1.0909	0.63439	0.0016152	1.7838	0.9995	0.00039843

Out-sample error measures:

	ME	RMSE	MAE	MPE	MAPE
Test set	0.04026546	1.414672	1.049321	0.04576531	1.206709

Serie Semanal

Parametros:

M	Wio[1]	Wio[2]	Wih[1,1]	Wih[2,1]	Wih[1,2]
-1.5806081460	0.9470808262	0.0693867742	-0.0200912655	0.5163345255	0.10851733
Wih[2,2]	Wih[1,3]	Wih[2,3]	Wih[1,4]	Wih[2,4]	Wbh[1]
-0.1186800691	-0.2661076341	0.2400223525	-0.0908004351	0.0942810618	0.0281033
Wbh[2]	Wbh[3]	Wbh[4]	Who[1]	Who[2]	Who[3]
-1.3829895074	-0.5628613051	-1.3307316852	-0.8619869123	-0.0181434065	-0.0003932
Who[4]	Wbo				
0.1472850902	-0.7261342259				

Sigma² estimated as: 3.23101295698908

LogL: -2663.58671493335

Information Criteria:

AK	AKc	HQ	SC
5367.173	5367.816	5406.089	5471.002

In-sample error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	-0.01392932	1.796826	1.136146	-0.042274	3.236286	0.9640037	-0.026170

Out-sample error measures:

	ME	RMSE	MAE	MPE	MAPE
Test set	0.1161575	2.973312	2.246704	0.1655091	2.542442

Análisis de estadísticos en la identificación de los modelos de contraste

D.1. Identificación de modelos de contraste en la serie mensual

En primer lugar se necesita observar si la transformación logarítmica es la más adecuada, lo cual se puede observar a través del gráfico de la función log-verosimil de Box y Cox. Dado que $\lambda = 0$ cae dentro del intervalo de confianza al 95 %, se adopta la decisión de realizar ésta transformación. Al revisar la figura D.1 se puede observar que la serie en el período de entrenamiento es no estacionaria.




FIGURA D.1. Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Mensual WTI)

En la figura D.2 se observa el comportamiento de la serie de tiempo transformada a través de la función logaritmo




FIGURA D.2. Logaritmo de la serie de precios mensuales del crudo WTI.

Por otra parte el test de Dickey-Fuller aumentado (ADF) para probar la estacionariedad de la serie mensual transformada arroja un valor- p de 0,47; lo anterior sugiere que no se puede rechazar la hipótesis nula a un nivel de significancia del 5 %. Por tal razón se toma la decisión de trabajar con la serie de log-retornos, los cuales se calculan mediante la expresión $L_t = \log\left(\frac{P_t}{P_{t-1}}\right)$. En esta ocasión, el test ADF arroja un valor- p más pequeño que 0,05, lo cual sugiere la presencia de estacionariedad en la serie de log-retornos (Ver figura D.3).




FIGURA D.3. Log-retornos de la serie de precios mensuales del crudo WTI.

Siguiendo con el proceso de identificación del modelo ARIMA, se trabajó en encontrar el orden de la parte autorregresiva (AR) y de promedio móvil (MA). Con el fin de lograr lo anterior se desplegaron las funciones de autocorrelación y autocorrelación parcial para la serie de tiempo compuesta por el conjunto de entrenamiento. Como se observa en la figura D.4 no se encuentra presencia de picos significantes en ambas funciones después del segundo rezago. Por lo tanto el modelo ARMA(2,2) se puede postular como un candidato.

Finalmente para cerrar el proceso de identificación del primer modelo de contraste, se decidió obtener valores del estadístico AIC para distintos modelos ajustados; para lo




FIGURA D.4. Funciones ACF y PACF de la serie de precios mensuales del crudo WTI en el conjunto de entrenamiento.

anterior se variaron los parámetros p y q en el intervalo $[0, 2]$ buscándose el mayor valor del AIC. De la tabla D.1 se concluye que el modelo a retener para la serie de lob-retornos de los precios mensuales del crudo WTI es el ARMA(2,2). En particular, si conjuntamente ambos órdenes son aumentados en 1 unidad en el modelo ARMA(2,2) se obtienen valores mayores de AIC, generando un problema de sobreajuste.

Orden (p, q)	(0,0)	(0,1)	(0,2)	(1,0)	(1,1)	(1,2)	(2,0)	(2,1)	(2,2)
AIC	-208,9	-213,2	-219,0	-216,1	-216,4	-217,7	-218,7	-217,0	-222,4

TABLA D.1. Estadístico AIC para diferentes ordenes p y q (Serie Mensual WTI)

D.1.1. Análisis de Residuales y ajuste del modelo GARCH

Con el fin de obtener el segundo modelo de contraste observamos en primera instancia el gráfico de los residuales del modelo ARMA (2,2) ajustado para el período de entrenamiento. Al analizar la figura D.5 se puede afirmar que los residuales del modelo muestran un comportamiento estacionario alrededor de un valor medio 0. Adicionalmente se puede remarcar que, durante la crisis financiera, se observan residuales de mayor magnitud.

Continuando con el procedimiento de identificación, se procedió en la despliegue de las funciones de autocorrelación y autocorrelación parcial para los residuales y residuales al cuadrado del modelo ajustado. Como se esperaba, no existe una correlación significativa entre los distintos rezagos de los residuales; lo cual es apoyado por las figuras D.6 y D.7, sin embargo el Test de McLeod-Li sugiere que existe una evidencia fuerte de que los residuales del modelo ajustado se encuentran correlacionados. La figura D.8 muestra como los valores p para diferentes rezagos a partir del segundo rezago se encuentran por debajo de límite 0,05. De este manera, se puede afirmar que un modelo GARCH es el apropiado para ajustar al conjunto de datos.

Adicionalmente la figura D.9 (QQ -Plot) para diagnostico de normalidad sugiere una evidencia leve de normalidad en la serie, lo cual es reforzado por test no-paramétrico

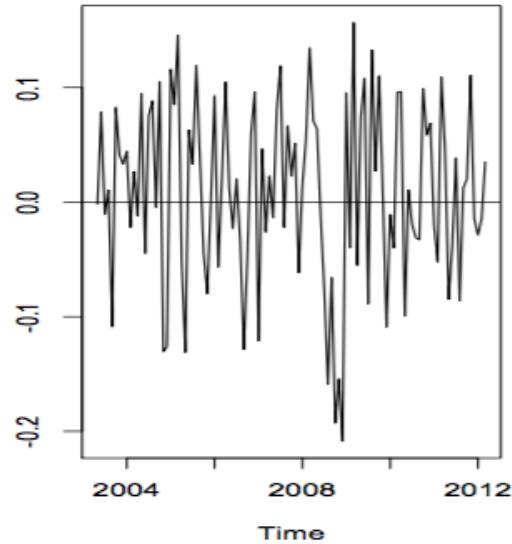


FIGURA D.5. Residuales del modelo ajustado para la serie mensual de precios del crudo WTI




FIGURA D.6. ACF y PACF para los residuales del modelo ajustado (Serie Mensual WTI)

Jarque-Bera el cual arroja un valor p de 0,1492 y nos conlleva al escenario de no rechazar la hipótesis nula la cual sugiere que los residuales se distribuyen normal.

La intuición racional detrás de la presencia de autocorrelación de los residuales del primer modelo de contraste ajustado se encuentra asociado a que la crisis financiera logró tener un efecto significativo en la aparición de un cluster de volatilidad. Con el fin de concluir el ejercicio se desplegaron un conjunto de valores del estadístico AIC para distintos órdenes del modelo GARCH, pudiéndose concluir que el modelo GARCH(1,1) genera el valor más pequeño (-234,5455). Con el fin de validar la elección se graficaron las funciones de autocorrelación y autocorrelación parcial de los residuales y residuales al cuadrado del modelo GARCH(1,1), los cuales se pueden evidenciar en las Figuras D.10 y D.11.




FIGURA D.7. ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Mensual WTI)




FIGURA D.8. Test de McLeod.Li para los residuales del modelo ajustado (Serie Mensual WTI)

D.2. Identificación de modelos de contraste en la serie anual

De manera similar a lo observado en el conjunto de entrenamiento de la serie mensual, la transformación logarítmica es la más adecuada, lo cual se puede observar a través del gráfico de la función log-verosimil de Box y Cox (Ver D.12). Dado que $\lambda = 0$ cae dentro del intervalo de confianza al 95 %, se adopta la decisión de realizar ésta transformación. Como conclusión de lo anterior se puede mantener la hipótesis de que la serie anual en su conjunto de validación es no estacionaria

En la figura D.13 se observa el comportamiento de la serie de tiempo transformada a través de la función logaritmo

Adicionalmente el test de Dickey-Fuller aumentado (ADF) para probar la estacionariedad de la serie anual transformada mediante la función logaritmo arroja un valor- p de 0,96; lo cual sugiere la presencia de no estacionariedad en la serie. De manera similar a lo realizado con la serie mensual, se tomó la decisión de trabajar con la serie de log-retornos.




FIGURA D.9. QQ - Plot de los residuos correspondientes al modelo ajustado (Serie Mensual WTI)




FIGURA D.10. ACF y PACF para los residuos del modelo GARCH(1,1) ajustado (Serie Mensual WTI)

En esta ocasión, el test ADF arroja un valor- p de 0,027 más pequeño que 0,05, lo cual sugiere la presencia de estacionariedad en la serie de log-retornos (Ver figura D.14).

Continuando con la identificación del modelo ARIMA, se realizaron los procedimientos necesarios con el fin de encontrar el orden (AR) y (MA) del modelo. Continuando con la anterior idea, se desplegaron las funciones de autocorrelación y autocorrelación parcial para la serie de tiempo anual compuesta por el conjunto de entrenamiento. Como se observa en la figura D.15 no hay presencia de picos significantes en ambas funciones después del segundo rezago. Por lo tanto, de manera similar, el modelo ARMA(2,2) se puede postular como mejor candidato a ajustar.

Nuevamente se decidió obtener valores del estadístico AIC para distintos modelos ajustados; para lo anterior se variaron los parámetros p y q en el intervalo $[0, 2]$ buscándose el mayor valor del AIC. De la tabla D.2 se concluye que el modelo a retener para la serie de log-retornos de los precios diarios del crudo WTI es el ARMA(0,2).




FIGURA D.11. ACF y PACF para los residuales al cuadrado del modelo GARCH(1,1) ajustado (Serie Mensual WTI)

Orden (p, q)	(0,0)	(0,1)	(0,2)	(1,0)	(1,1)	(1,2)	(2,0)	(2,1)	(2,2)
AIC	-1.8216	-0.6746	-5.2447	0.0925	-0.4771	-3.3504	-4.2388	-3.584	-2.0738

TABLA D.2. Estadístico AIC para diferentes ordenes p y q (Serie Diaria WTI)

D.2.1. Análisis de Residuales y ajuste del modelo GARCH

Con el propósito de obtener el segundo modelo de contraste se desplegó el gráfico de los residuales del modelo ARMA (0,2) ajustado para la serie de tiempo anual del precio del crudo en el período de entrenamiento. Como conclusión de analizar la figura D.16 se puede afirmar que los residuales del modelo muestran un comportamiento aparentemente estacionario, sin embargo el test ADF revela un valor- p de 0,444 lo cual conlleva a concluir que los residuales del modelo ajustado no son estacionarios.

Siendo congruentes con la última conclusión, se continuo con la obtención de las funciones de autocorrelación y autocorrelación parcial para los residuales y residuales al cuadrado del modelo ajustado. De la ACF y PACF es posible afirmar que no existe una correlación significativa entre los distintos rezagos de los residuales; lo cual es apoyado por las figuras D.17 y D.18 además del Test de McLeod-Li el cual sugiere que no existe una evidencia fuerte de que los residuales del modelo ajustado se encuentren correlacionados (Ver Figura D.19). Lo anterior conduce a afirmar que un modelo GARCH no es apropiado para modelar los residuales del modelo ajustado.

Con respecto al contraste que evalúa la presencia de normalidad de los residuales, la figura D.20 (QQ -Plot) sugiere una evidencia fuerte de normalidad en la serie, lo cual es reforzado por test no-paramétrico Jarque-Bera el cual arroja un valor p de 0,717 por lo tanto no se puede rechazar la hipótesis de que los residuales se distribuyen normal.

D.3. Identificación de modelos de contraste en la serie diaria

Continuando con la idea anterior se decide utilizar la transformación logarítmica. La decisión se encontró fundamentada en el análisis del gráfico de la función log-verosimil de




FIGURA D.12. Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Anual WTI)




FIGURA D.13. Logaritmo de la serie de precios anuales del crudo WTI.

Box y Cox (Ver D.21). Dado que $\lambda = 0$ cae dentro del intervalo de confianza al 95 %, se adopta la decisión de realizar ésta transformación. Similarmente a lo ocurrido en la serie de precios anuales se puede mantener la hipótesis de que la serie diaria en su conjunto de validación es no estacionaria

En la figura D.22 se observa el comportamiento de la serie de tiempo transformada a través de la función logaritmo

Por otra parte el test de Dickey-Fuller aumentado (ADF) para probar la estacionariedad de la serie diaria transformada mediante la función logaritmo arroja un valor- p de 0,1687; lo cual sugiere la presencia de no estacionariedad en la serie. De manera similar a lo realizado con la serie anual, se tomó la decisión de trabajar con la serie de log-retornos para la cual el test ADF arroja un valor- p de 0,01 menor a 0,05, lo cual sugiere la presencia de estacionariedad en la serie de log-retornos (Ver figura D.23).

Durante la identificación del modelo ARIMA, se realizaron los procedimientos necesarios con el fin de encontrar el orden (AR) y (MA) del modelo. Continuando con la




FIGURA D.14. Log-retornos de la serie de precios anuales del crudo WTI.




FIGURA D.15. Funciones ACF y PACF de la serie de precios anuales del crudo WTI en el conjunto de entrenamiento.

anterior idea, se desplegaron las funciones de autocorrelación y autocorrelación parcial para la serie de tiempo diaria compuesta por el conjunto de entrenamiento. Como se observa en la figura D.24 se encuentran picos significantes en ambas funciones después del segundo rezago además el comportamiento de la PACF se asemeja al de un modelo ARMA en el cual la componente MA es de mayor orden que la parte autorregresiva. Lo anterior conlleva a proponer el modelo ARMA (1,2) como el candidato a ser ajustado para la serie de frecuencia diaria.

Para complementar el ejercicio se obtuvieron valores del estadístico AIC para distintos modelos ajustados; para lo anterior se variaron los parámetros p y q en el intervalo $[0, 2]$ buscándose el mayor valor del AIC. De la tabla D.3 se concluye que el modelo a retener para la serie de log-retornos de los precios diarios del crudo WTI es el ARMA(1,2).




FIGURA D.16. Residuales del modelo ajustado para la serie mensual de precios del crudo WTI




FIGURA D.17. ACF y PACF para los residuales del modelo ajustado (Serie Anual WTI)

Orden (p, q)	(0,0)	(0,1)	(0,2)	(1,0)	(1,1)	(1,2)	(2,0)	(2,1)	(2,2)
AIC	-28683	-28681	-28693	-28681	-28698	-28703,39	-28693	-28703,24	-28701

TABLA D.3. Estadístico AIC para diferentes ordenes p y q (Serie Diaria WTI)

D.3.1. Análisis de Residuales y ajuste del modelo GARCH

Para la obtención del segundo modelo de contraste se obtuvo el gráfico de los residuales del modelo ARMA (1,2) ajustado para la serie de tiempo diaria del precio del crudo en el período de entrenamiento. Como conclusión de analizar la figura D.25 se puede afirmar que los residuales del modelo muestran un comportamiento aparentemente estacionario, lo cual es confirmado por el test ADF el cual revela un valor- p de 0,01 por lo tanto no se puede afirmar que los residuales del modelo ajustado no sean estacionarios.

Como complemento del ejercicio se desplegaron las funciones de autocorrelación y autocorrelación parcial para los residuales y residuales al cuadrado del modelo ajustado. Como se esperaba, no existe una correlación significativa entre los distintos rezagos de los residuales; lo cual es apoyado por las figuras D.26 y D.27, sin embargo el Test de McLeod-Li sugiere que existe una evidencia fuerte de que los residuales del modelo ajustado se encuentran correlacionados. La figura D.28 muestra como los valores p para diferentes rezagos a partir del segundo rezago se encuentran por debajo de límite 0,05. De manera




FIGURA D.18. ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Anual WTI)




FIGURA D.19. Test de McLeod.Li para los residuales del modelo ajustado (Serie Anual WTI)

similar a lo ocurrido en la serie mensual, se puede afirmar que un modelo GARCH es el apropiado para ajustar al conjunto de datos.

Por otra parte la figura D.29 (QQ -Plot) para diagnostico de normalidad sugiere la evidencia leve de normalidad en la serie, lo cual es reforzado por test no-paramétrico Jarque-Bera el cual arroja un valor p de $2.2e^{-16}$ y nos indica que no se puede rechazar la hipótesis nula la cual sugiere que los residuales se distribuyen normal.

Con el fin de concluir el ejercicio se desplegaron un conjunto de valores del estadístico AIC para distintos órdenes del modelo GARCH, pudiéndose concluir que el modelo GARCH(1,1) genera el valor más pequeño (-30632, 4). Con el fin de validar la elección se graficaron las funciones de autocorrelación y autocorrelación parcial de los residuales y residuales al cuadrado del modelo GARCH(1,1), los cuales se pueden evidenciar en las Figuras D.30 y D.31.




FIGURA D.20. QQ - Plot de los residuales correspondientes al modelo ajustado (Serie Anual WTI)




FIGURA D.21. Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Diaria WTI)

D.4. Identificación de modelos de contraste en la serie semanal

Se decidió entonces utilizar la transformación logarítmica, lo cual se sustenta en el análisis del gráfico de la función log-verosimil de Box y Cox (Ver D.32). Dado que $\lambda = 0$ cae dentro del intervalo de confianza al 95 %, se adopta la decisión de realizar ésta transformación. Similarmente a lo ocurrido en la serie de precios diarios se mantiene la hipótesis de que la serie diaria en su conjunto de validación es no estacionaria

En la figura D.33 se observa el comportamiento de la serie de tiempo transformada a través de la función logaritmo

Por otra parte el test de Dickey-Fuller aumentado (ADF) para probar la estacionariedad de la serie semanal transformada mediante la función logaritmo arroja un valor- p de




FIGURA D.22. Logaritmo de la serie de precios diaria del crudo WTI.




FIGURA D.23. Log-retornos de la serie de precios diarios del crudo WTI.

0,1525; lo cual sugiere la presencia de no estacionariedad en la serie. De manera similar a lo realizado con las series anteriores, se tomó la decisión de trabajar con la serie de log-retornos para la cual el test ADF arroja un valor- p de 0,01 menor a 0,05, lo cual sugiere la presencia de estacionariedad en la serie de log-retornos (Ver figura D.34).

En la identificación del modelo ARIMA, se realizaron los procedimientos necesarios con el fin de encontrar el orden (AR) y (MA) del modelo, por tal motivo se desplegaron las funciones de autocorrelación y autocorrelación parcial para la serie de tiempo diaria compuesta por el conjunto de entrenamiento. Como se observa en la figura D.35 se encuentran picos significantes en ambas funciones después del segundo rezago además el comportamiento de la PACF se asemeja al de un modelo ARMA(1,5), por lo cual se propone este último como el candidato a ser ajustado para la serie de frecuencia semanal.

Para finalizar el ejercicio se obtuvieron valores del estadístico AIC para distintos modelos ajustados; para lo anterior se variaron los parámetros p y q en el intervalo $[0, 5]$ buscándose el mayor valor del AIC. De la tabla D.4 se concluye que el modelo a retener para la serie de log-retornos de los precios semanales del crudo WTI es el ARMA(3,4), ya que aunque el ARMA(5,5) tiene mayor AIC también se asignó importancia a la parsimonia del modelo seleccionado.




FIGURA D.24. Funciones ACF y PACF de la serie de precios diarios del crudo WTI en el conjunto de entrenamiento.




FIGURA D.25. Residuales del modelo ajustado para la serie diaria de precios del crudo WTI

Orden (p, q)	(0,0)	(0,1)	(0,2)	(0,3)	(0,4)	(0,5)	(1,0)	(1,1)	(1,2)	(1,3)	(1,4)	(1,5)
AIC	-4469	-4480	-4482	-4489	-4494	-4493	-4478	-4484	-4482	-4491	-4500	-4491
Orden (p, q)	(2,0)	(2,1)	(2,2)	(2,3)	(2,4)	(2,5)	(3,0)	(3,1)	(3,2)	(3,3)	(3,4)	(3,5)
AIC	-4480	-4482	-4482	-4504	-4502	-4495	-4493	-4493	-4504	-4497	-4506	-4495
Orden (p, q)	(4,0)	(4,1)	(4,2)	(4,3)	(4,4)	(4,5)	(5,0)	(5,1)	(5,2)	(5,3)	(5,4)	(5,5)
AIC	-4494	-4492	-4497	-4495	-4507	-4506	-4492	-4497.2	-4495.03	-4493	-4499	-4508

TABLA D.4. Estadístico AIC para diferentes ordenes p y q (Serie Semanal WTI)

D.4.1. Análisis de Residuales y ajuste del modelo GARCH

Para la obtención del segundo modelo de contraste se obtuvo el gráfico de los residuales del modelo ARMA (3,4) ajustado para la serie de tiempo semanal del precio del crudo en el período de entrenamiento. Como conclusión de analizar la figura D.36 se puede afirmar que los residuales del modelo muestran un comportamiento aparentemente estacionario,




FIGURA D.26. ACF y PACF para los residuales del modelo ajustado (Serie Diaria WTI)




FIGURA D.27. ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Diaria WTI)

lo cual es confirmado por el test ADF el cual revela un valor- p de 0,01 por lo tanto no se puede afirmar que los residuales del modelo ajustado no sean estacionarios.

Como complemento se desplegaron las funciones de autocorrelación y autocorrelación parcial para los residuales y residuales al cuadrado del modelo ajustado. La acf y pacf sugieren la presencia de una correlación significativa entre los distintos rezagos de los residuales; lo cual es apoyado por las figuras D.37 y D.38, adicionalmente el Test de McLeod-Li sugiere que existe una evidencia fuerte de que los residuales del modelo ajustado se encuentran correlacionados. La figura D.39 muestra como los valores p para diferentes rezagos a partir del segundo rezago se encuentran por debajo de límite 0,05. De manera similar a lo ocurrido en la serie mensual, se puede afirmar que un modelo GARCH es el apropiado para ajustar al conjunto de datos.

Por otra parte la figura D.40 (QQ -Plot) para diagnostico de normalidad sugiere la evidencia leve de normalidad en la serie, lo cual es reforzado por test no-paramétrico Jarque-Bera el cual arroja un valor p de $2.2e^{-16}$ y nos indica que no se puede rechazar la hipótesis nula la cual sugiere que los residuales se distribuyen normal.




FIGURA D.28. Test de McLeod.Li para los residuales del modelo ajustado (Serie Diaria WTI)




FIGURA D.29. QQ - Plot de los residuales correspondientes al modelo ajustado (Serie Diaria WTI)

Para finalizar el ejercicio se desplegaron un conjunto de valores del estadístico AIC para distintos órdenes del modelo GARCH, pudiéndose concluir que el modelo GARCH(3,1) genera el valor más pequeño (-4754.93). Con el fin de validar la elección se graficaron las funciones de autocorrelación y autocorrelación parcial de los residuales y residuales al cuadrado del modelo GARCH(3,1), los cuales se pueden evidenciar en las Figuras D.41 y D.42.




FIGURA D.30. ACF y PACF para los residuos del modelo GARCH(1,1) ajustado (Serie Diaria WTI)




FIGURA D.31. ACF y PACF para los residuos al cuadrado del modelo GARCH(1,1) ajustado (Serie Diaria WTI)




FIGURA D.32. Funciones de verosimilitud de Box y Cox para el período de entrenamiento (Serie Semanal WTI)




FIGURA D.33. Logaritmo de la serie de precios semanal del crudo WTI.




FIGURA D.34. Log-retornos de la serie de precios semanales del crudo WTI.




FIGURA D.35. Funciones ACF y PACF de la serie de precios semanales del crudo WTI en el conjunto de entrenamiento.




FIGURA D.36. Residuales del modelo ajustado para la serie semanal de precios del crudo WTI




FIGURA D.37. ACF y PACF para los residuales del modelo ajustado (Serie Semanal WTI)




FIGURA D.38. ACF y PACF para los residuales al cuadrado del modelo ajustado (Serie Semanal WTI)




FIGURA D.39. Test de McLeod.Li para los residuales del modelo ajustado (Serie Semanal WTI)




FIGURA D.40. QQ - Plot de los residuales correspondientes al modelo ajustado (Serie Semanal WTI)




FIGURA D.41. ACF y PACF para los residuales del modelo GARCH(3,1) ajustado (Serie Semanal WTI)




FIGURA D.42. ACF y PACF para los residuales al cuadrado del modelo GARCH(3,1) ajustado (Serie Semanal WTI)

Desarrollos Teóricos Complementarios

E.1. Pronostico y Medidas de Error de Pronóstico

Definición A.1 (Error Medio). Este calcula la diferencia entre cada valor pronosticado y cada valor observado y como paso final promedia estas diferencias. La interpretación de este estadístico es el promedio de los errores del modelo. Si Y_j representa el valor observado de la serie en el momento j , el error medio sigue la siguiente fórmula:

$$ME = \frac{1}{n} \sum_{j=1}^n (\hat{Y}_t(j) - Y_j) \quad (\text{E.1})$$

Definición A.2 (Error Cuadrático Medio). Este calcula la diferencia al cuadrado entre cada valor pronosticado y cada valor observado, finalmente promedia estas diferencias. Es posible interpretar este estadístico literalmente como el promedio de los errores al cuadrado. Si Y_j representa el valor observado de la serie en el momento j , el error cuadrático medio sigue la siguiente fórmula:

$$MSE = \frac{1}{n} \sum_{j=1}^n ((\hat{Y}_t(j) - Y_j)^2) \quad (\text{E.2})$$

Definición A.3 (Error Absoluto Medio). Este calcula el promedio del valor absoluto de la diferencia entre cada valor pronosticado y cada valor observado en lugar de las diferencias al cuadrado. La formula es la siguiente:

$$MAE = \frac{1}{n} \sum_{j=1}^n (|\hat{Y}_t(j) - Y_j|) \quad (\text{E.3})$$

Definición A.4 (Raíz del Error Cuadrático Medio). De forma similar el MSE este estadístico calcula la diferencia al cuadrado entre cada valor pronosticado y cada valor observado, finalmente promedia estas diferencias y adicionalmente aplica el operador raíz cuadrada a este resultado. Se interpreta este estadístico como la raíz cuadrada del promedio

de los errores al cuadrado. Si Y_j representa el valor observado de la serie en el momento j , la raíz cuadrada del error cuadrático medio sigue la siguiente fórmula:

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n ((\hat{Y}_t(j) - Y_j)^2)} \quad (\text{E.4})$$

Definición A.5 (Error Porcentual Medio). Este estadístico calcula las diferencias porcentuales del valor observado y el valor pronosticado, como paso final promedia estas diferencias porcentuales. Si Y_j representa el valor observado de la serie en el momento j , el error porcentual medio sigue la siguiente fórmula:

$$MPE = \frac{100}{n} \sum_{j=1}^n \frac{(\hat{Y}_t(j) - Y_j)}{Y_j} \quad (\text{E.5})$$

Definición A.6 (Error Porcentual Absoluto Medio). Este estadístico calcula las diferencias porcentuales del valor observado y el valor pronosticado en valor absoluto, finalmente promedia estas diferencias. El estadístico se representa mediante la siguiente fórmula:

$$MAPE = \frac{1}{n} \sum_{j=1}^n \left| \frac{(\hat{Y}_t(j) - Y_j)}{Y_j} \right| \quad (\text{E.6})$$

Definición A.7 (Error Medio Absoluto Escalado). Esta medida de error de pronostico es conocida como generalización aplicable la cual soluciona los distintos problemas que se pueden observar en otros estadísticos utilizados en la medición del desempeño de modelos de pronóstico Hyndman & Koehler (2006). La formula es la siguiente:

$$MASE = \frac{1}{n} \sum_{j=1}^n \left(\frac{|e_j|}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|} \right) = \frac{\sum_{j=1}^n |e_j|}{\frac{n}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|} \quad (\text{E.7})$$

Definición A.8 (n pronósticos hacia adelante). Un paso adelante en el pronóstico de Y_{t+1} basado en un modelo *ARMA – GARCH* se define como:

$$\hat{Y}_t(1) = E(Y_{t+1}|Y_t, Y_{t-1}, \dots) = \phi_0 + \sum_{i=1}^p \phi_i Y_{t+1-i} + \sum_{j=1}^q \theta_j \epsilon_{t+1-j} \quad (\text{E.8})$$

, donde ϵ sigue el modelo declarado *GARCH*. De manera recursiva se puede definir el el pronostico n hacia adelante como $\hat{Y}_t(n)$.

E.2. Acercamiento de Box y Jenkins

E.2.1. ARIMA

Durante el desarrollo del trabajo final se explora la metodología ARIMA de Box y Jenkins propuesta por Box & Jenkins (1990), para la construcción de un modelo de series de tiempo univariado. Esta es una de las formas más comunes de formular un modelo de pronóstico para una serie de tiempo univariada como es el caso de la serie de precios de mercado del crudo WTI para cada uno de las frecuencias planteadas. Con el fin de entender en que consiste la metodología, en primer lugar se introduce al modelo ARMA y consecutivamente se define el modelo ARIMA.

Definición A.9 (ARMA). Un arma (Autoregressive Moving Average Model) (p, q) ajustado a una serie de tiempo Y_t tiene la siguiente forma:

$$Y_t = \phi_0 + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t \quad (\text{E.9})$$

1. p hace referencia al número de términos autorregresivos.
2. q hace referencia al número de rezagos del termino error.
3. ϕ corresponden a los coeficientes de los términos autorregresivos.
4. θ corresponden a los coeficientes de los términos del promedio móvil.

Definición A.10 (Ruido Blanco). El término ϵ_t definido anteriormente es un proceso de ruido blanco, lo cual significa que éste es una secuencia de variables las cuales tienen una media cero, varianza σ^2 y correlación cruzada a lo largo del tiempo igual a cero, es decir, $E(\epsilon_u, \epsilon_v) = 0$ para $u \neq v$. Adicionalmente los ϵ_t son independientes e idénticamente distribuidos.

Un modelo ARIMA es una extensión de la clase ARMA.

Definición A.11 (ARIMA). Se dice que una serie de tiempo Y_t conlleva un formato ARIMA (Autoregressive Integrated Moving Average) si $\nabla^d Y_t$ es un proceso ARMA estacionario, donde d hace referencias que se realizan sobre la serie original.

Sin embargo en la realidad, es común en series de tiempo financieras modelar el logaritmo de los retornos en lugar de los precios. Lo anterior se define como la diferencia entre los precios actuales y previos. Para determinar en que momento una transformación logarítmica es necesaria, buscando objetivos tales como la estabilización de la varianza y un conjunto de datos más gausinamente distribuidos, se tiene el siguiente procedimiento:

Definición A.12 (Transformación de Box-Cox). Para cada y , se puede convertir y en $y^{(\lambda)}$ utilizando la transformación de Box-Cox, donde

$$\frac{y^{(\lambda)} - 1}{\lambda}, \quad \text{si } \lambda \neq 0 \quad (\text{E.10})$$

$$\log(y), \quad \text{si } \lambda = 0 \quad (\text{E.11})$$

De acuerdo con lo anterior, es posible graficar, con respecto a un intervalo de confianza del 95 %, el logaritmo de la función de verosimilitud para los valores factibles de λ

En la metodología planteada por Box-Jenkins, es necesario garantizar la estacionariedad de la serie tanto en media como en varianza. Lo anterior se puede conseguir diferenciando la serie en multiples ocasiones (como máximo dos veces por lo general). El test de Dickey & Fuller (1979) aumentado puede ser utilizado con el fin de diagnosticar si la serie transformada es estacionaria. Este proporciona una metodología alternativa para verificar la estacionariedad de la serie en lugar de observar el gráfico de la serie en si mismo.

Definición A.13 (Test de Dickey - Fuller Aumentado). Este test ayuda a verificar si la serie de tiempo tiene una raíz unitaria. Si la tiene, se considera que la serie no es estacionaria. La hipótesis nula en el test plantea que la serie de tiempo no es estacionaria.

Después de realizados los anteriores test, se deben graficar la funciones de autocorrelación y autocorrelación parcial para distintos rezagos de la serie con el fin de definir los ordenes de p y q en el modelo. Los patrones buscados se resumen en la siguiente tabla

TABLA E.1. Resultados de las funciones de autocorrelación y autocorrelación parcial

	AR(p)	MA(q)	ARMA(p,q)
ACF	Colas caídas	Cortes a partir del rezago q	Colas caídas
PACF	Cortes a partir del rezago p	Colas caídas	Colas caídas

En distintas ocasiones, puede existir más de un candidato potencial a modelo final. In este caso es necesario utilizar un acercamiento alternativo basado en un criterio de información para seleccionar el modelo más apropiado. Una posibilidad está en utilizar el criterio de información Akaike (1974).

Definición A.14 (AIC). El AIC Mide que tan bien se ajusta el modelo ajustado en relación con otros modelos, éste se calcula mediante la siguiente expresión:

$$AIC(p, q) = -2 \log(L) + 2(p + q) \tag{E.12}$$

donde L es el máximo de la función de verosimilitud del modelo ARMA(p,q) y $p + q$ es el total parámetros en éste. El modelo que se debe seleccionar bajo este acercamiento es aquel con el menor valor de AIC. Además se desea que $p + q$ sea lo menor posible y L lo suficientemente grande. En otras palabras, el criterio de información AIC recoge tanto la bondad de ajuste como lo parsimonioso del modelo.

Una vez especificado el modelo, se emplea el método de estimación de máxima verosimilitud con el fin de estimar los coeficientes tanto de la parte autorregresiva como de promedios móviles. Finalmente, se realiza el diagnóstico modelo para ver si el modelo estimado es consistente con las especificaciones de un proceso estacionario de series de tiempo. Gráficamente para realizar un diagnóstico adecuado se utiliza el siguiente gráfico:

Definición A.15 (QQ Plot). Este gráfico hace referencia a u gráfico de cuantiles de los residuales contra los cuantiles de una distribución normal. En el gráfico existe una línea QQ la cual representa el emparejamiento perfecto entre los residuales y la distribución normal. Si los residuales del modelo siguen una distribución normal, se

observarán los cuantiles de éstos sobre la línea trazada.

Adicionalmente se pueden implementar pruebas no paramédicas de diagnóstico como el test de MacLeod-Li y el test de Jarque-Bera sobre los residuales del modelo.

Definición A.16 (Test de MacLeod - Li). El Test de MacLeod - Li se encuentra basado en el análisis de una muestra de las autocorrelaciones de la serie de tiempo elevada al cuadrado McLeod (1983). El test tiene la siguiente forma:

H_0 : *Los residuales son independientes* Vs H_1 : *Los residuales son dependientes*

$$L = (n^2 + 2n) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n - k} \quad (\text{E.13})$$

$$\hat{\rho}_k = \frac{\sum_{t=k+1}^n (\epsilon_t^2 - \hat{\sigma}_n^2)(\epsilon_{t-k}^2 - \hat{\sigma}_n^2)}{\sum_{t=1}^n (\epsilon_t^2 - \hat{\sigma}_n^2)}, \quad \hat{\sigma}_n^2 = \frac{\sum_{t=1}^n \epsilon_t^2}{n}$$

Teniendo en cuenta que Y_t es una serie de tiempo con observaciones independientes e idénticamente distribuidas, el estadístico L sigue una distribución asintótica $\chi^2(K)$. Si el test es aplicado a los residuales de un modelo ARIMA ajustado y el valor p obtenido está por debajo de 0.05, tenemos fuerte evidencia para rechazar la hipótesis nula.

Definición A.17 (Test de Jarque - Bera). El Test Jarque - Bera se encuentra basado en el análisis distribuciones del estadístico L Jarque & Bera (1980).

H_0 : ϵ_t *se distribuye normal* Vs H_1 : ϵ_t *no se distribuye normal*

$$L = \frac{n}{6} (S^2 + 0.25(K - 3)^2), \quad (\text{E.14})$$

donde n es el número de observaciones, S es el coeficiente de apuntamiento de la muestra y K la curtosis. Si las observaciones provienen de una distribución normal, el estadístico L sigue una distribución $\chi^2(2)$ asintótica.

Si los residuales violan los supuestos necesarios, se hace necesario modelar los residuales utilizando un modelo *GARCH* (Generalised Autoregressive Conditional Heteroskedasticity).

E.2.2. Modelando los Residuales

El análisis de los residuales de series de tiempo financieras, modelos GARCH (Generalised Autoregressive Conditional Heteroskedasticity), propuestos por Bollerslev (1986), son ampliamente utilizados para especificar y modelar innovaciones, es decir, las diferencias entre el valor ajustado del modelo propuesto y los valores observados. Los modelos GARCH tienen la capacidad para modelar el fenómeno de clustering de volatilidad presente comúnmente en las series de tiempo financieras. Los modelos GARCH

evolucionaron a partir del modelo ARCH (Autoregressive Conditional Heteroskedasticity) , propuesto por Engle (1982), el cual asume que la varianza de la innovación actual depende de los errores de periodos anteriores.

Definición A.18 (ARCH). Los modelos ARCH(q), donde q hace referencia al orden de las innovaciones previas utilizadas en el modelo, se encuentran descritos por la siguiente expresión:

$$\epsilon_t = \sigma_t z_t, \text{ con } z_t \text{ ruido blanco,}$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2, \omega > 0, \alpha_i \geq 0, i > 0 \quad (\text{E.15})$$

Definición A.19 (GARCH). Por otra parte, el modelo GARCH asume el hecho de que la varianza condicional de los residuales siguen un modelo ARMA. En este caso, un modelo GARCH(p,q), con p y q los órdenes del modelo GARCH y ARCH respectivamente, tiene la siguiente estructura:

$$\epsilon_t = \sigma_t z_t, \text{ con } z_t \text{ ruido blanco,}$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \epsilon_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2, \omega > 0, \alpha_i \geq 0, \beta_i \geq 0, i > 0 \quad (\text{E.16})$$

Con el fin de garantizar estacionariedad se impone la restricción $\sum_{i=1}^q \alpha_i + \sum_{i=1}^p \beta_i < 1$. Como se puede observar en la ecuación (E.16) el modelo GARCH se convierte en ARCH cuando $p = 0$.

APÉNDICE F

Código R

F.1. Fuentes de Información

#La data fue descarga de manera completa del siguiente enlace http://www.eia.gov/dnav/pet/pet_pri_spt_s1_d.htm perteneciente a U.S Energy information administration.

```
#####Cargue de Serie Mensual#####
```

```
Serie_Mensual<-ts(data=c(22.93,15.46,12.61,12.84,15.38,13.43,11.59, ...),
start=1986,frequency=12)
plot(Serie_Mensual,xlab = "Fecha",ylab = "Precio de Mercado (USD)",
type = "l",lty=1, lwd = 2, col=1)
grid()
```

```
##### Cargue de Serie Anual#####
```

```
Serie_Anual<-ts(data=c(15.05,19.2,15.97,19.64,24.53,21.54,20.58,18.43,17.2,
18.43,22.12,20.61,14.42,19.34,30.38,25.98,26.18,31.08,41.51,56.64,66.05,
72.34,99.67,61.95,79.48,94.88,94.05,97.98,93.25),start=1986,frequency=1)
plot(Serie_Anual,xlab = "Fecha",ylab = "Precio de Mercado (USD)",type = "l"
,lty=1, lwd = 2, col=1)
grid()
```

```
##### Cargue de Serie Diaria#####
```

```
seriediaria <- read.csv("~/Desktop/DATA/seriediaria.csv", sep=";", dec=",")
dates<-as.POSIXct(strptime(seriediaria[,1],format="%Y-%m-%d"))
library("xts", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/Resour
ces/library")
Serie_Diaria <- xts(seriediaria[,c(2)], order.by=dates)
plot(Serie_Diaria,xlab = "Fecha",ylab = "Precio de Mercado (USD)")
```

```
##### Cargue de Serie Semanal#####

seriesemanal <- read.csv("~/Desktop/DATA/seriesemanal.csv", sep=";", dec=",")
dates1<-as.POSIXct(strptime(seriesemanal[,1],format="%Y-%m-%d"))
Serie_Semanal <- xts(seriesemanal[,c(2)], order.by=dates1)
plot(Serie_Semanal,xlab = "Fecha",ylab = "Precio de Mercado (USD)")
```

F.2. Implementación ARNN

```
##### Carga de Paquetes#####

library("forecast", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("timeSeries", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("xts", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("PerformanceAnalytics", lib.loc="/Library/Frameworks/R.framework/
Versions/3.1/Resources/library")
library("fTrading", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("TSA", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("MASS", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("FitAR", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("fGarch", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")
library("reporttools", lib.loc="/Library/Frameworks/R.framework/Versions/3.1/
Resources/library")

#####Codigo de Serie Mensual#####

#Proporcion de entrenamiento sobre la informacion

alpha<-2/3
numero_rezagos<-2
numero_capas<-3
#Inicializacion de Matriz de resultados
resultados<-matrix(, nrow = ((numero_rezagos-1)*numero_capas), ncol = 16)

#Se toma la primeros alpha puntos de la serie para el proceso de entrenamiento
x <- ts(Serie_Mensual[1:as.integer(alpha * length(Serie_Mensual))],s=1986,f=12)

for(i in 2:numero_rezagos){
```

```

for(j in 1:numero_capas){
  Se ajusta una ARNN a los datos de entrenamiento
  entrenamiento <- arnn(x=x, lags=1:i, isMLP=FALSE, H=j, w.max=1e-3,
    restarts=10, seed = 1234, lambda=0, optim.control=list(maxit=200))

  #Informacion del modelo ajustado, estimacion de parametros de la red,
  criterios de informacion, estimacion de la varianza y criterios de
  informacion

  resumen<-summary(entrenamiento)
  entrenamiento$IC[1]

  # Medidas de error dentro de la muestra

  accin<-accuracy(entrenamiento)

  # Medidas de error fuera de la muestra

  fuerademuestra<- arnn(x = Serie_Mensual, model = entrenamiento)

  accout<-accuracy(fitted(fuerademuestra)[as.integer(alpha * length(
    Serie_Mensual))+1:length(Serie_Mensual)], Serie_Mensual[as.integer
    (alpha * length(Serie_Mensual)) +1:length(Serie_Mensual)])

  w=numero_capas*(i-2)+j
  resultados[w,1]<-accin[1]
resultados[w,2]<-accin[2]
  resultados[w,3]<-accin[3]
  resultados[w,4]<-accin[4]
  resultados[w,5]<-accin[5]
  resultados[w,6]<-accin[6]
  resultados[w,7]<-accin[7]
  resultados[w,8]<-accout[1]
  resultados[w,9]<-accout[2]
  resultados[w,10]<-accout[3]
  resultados[w,11]<-accout[4]
  resultados[w,12]<-accout[5]
  resultados[w,13]<-entrenamiento$IC[1]
  resultados[w,14]<-entrenamiento$IC[2]
  resultados[w,15]<-entrenamiento$IC[3]
  resultados[w,16]<-entrenamiento$IC[4]
}
}

#Exportacion de Resultdos
#write.csv(resultados, "Rmensual.csv")

#Grafica de la serie y ajuste del modelo en la muestra de entrenamiento

```

```

par(mfrow=c(1,2))
plot(Serie_Mensual)
lines(fitted(fuerademuestra), col = 'blue',lwd=0.4)
grid()

#Se generan 100 pronosticos hacia adelante cada uno a traves de una
muestra de 1000 observaciones.

forecast(entrenamiento, h=length(Serie_Mensual)-as.integer(alpha *
length(Serie_Mensual)), level=90, fan=FALSE, bootstrap=FALSE, seed=1234,
npaths=1000)

#Grafica de ajuste en los datos pronosticados

plot(forecast(entrenamiento, h=length(Serie_Mensual)-as.integer(alpha *
length(Serie_Mensual)), level=90, fan=FALSE, bootstrap=FALSE, seed=1234,
npaths=1000))
grid()

##### Codigo de Serie Anual#####

#Proporcion de entrenamiento sobre la informacion

alpha<-2/3
numero_rezagos<-3
numero_capas<-1

#Inicializacion de Matriz de resultados

resultadosanual<-matrix(, nrow = ((numero_rezagos-1)*numero_capas),
ncol = 16)

# Se toma la primeros alpha puntos de la serie para el proceso de
entrenamiento

x <- ts(Serie_Anual[1:as.integer(alpha * length(Serie_Anual))],s=1986,f=1)

for(i in 2:numero_rezagos){
  for(j in 1:numero_capas){

    #Se ajusta una ARNN a los datos de entrenamiento

    entrenamiento <- arnn(x=x, lags=1:i, isMLP=FALSE, H=j, w.max=1e-3,
      restarts=10, seed = 1234, lambda=0, optim.control=list(maxit=200))

    # Informacion del modelo ajustado, estimacion de parametros de la red,
    criterios de informacion, estimacion de la varianza y citerios de
    informacion
  }
}

```

```
summary(entrenamiento)

#Medidas de error dentro de la muestra

accin<-accuracy(entrenamiento)

#Medidas de error fuera de la muestra

fuera demu estra<- arnn(x = Serie_A nual, model = entrenamiento)

accout<-accuracy(fitted(fuera demu estra)[as.integer(alpha * length
(Serie_A nual))+1:length(Serie_A nual)], Serie_A nual[as.integer
(alpha * length(Serie_A nual))+1:length(Serie_A nual)])

w=numero_capas*(i-2)+j
resultadosanual[w,1]<-accin[1]
resultadosanual[w,2]<-accin[2]
resultadosanual[w,3]<-accin[3]
resultadosanual[w,4]<-accin[4]
resultadosanual[w,5]<-accin[5]
resultadosanual[w,6]<-accin[6]
resultadosanual[w,7]<-accin[7]
resultadosanual[w,8]<-accout[1]
resultadosanual[w,9]<-accout[2]
resultadosanual[w,10]<-accout[3]
resultadosanual[w,11]<-accout[4]
resultadosanual[w,12]<-accout[5]
resultadosanual[w,13]<-entrenamiento$IC[1]
resultadosanual[w,14]<-entrenamiento$IC[2]
resultadosanual[w,15]<-entrenamiento$IC[3]
resultadosanual[w,16]<-entrenamiento$IC[4]
}
}

#write.csv(resultadosanual, "Ranual2.csv")

# Grafica de la serie y ajuste del modelo en la muestra de entrenamiento
par(mfrow=c(1,2))
plot(Serie_A nual)
lines(fitted(fuera demu estra), col = 'blue')
grid()

#Se generan 100 pronosticos hacia adelante cada uno a traves de una
muestra de 1000 observaciones.

forecast(entrenamiento, h=length(Serie_A nual)-as.integer(alpha * length
(Serie_A nual)), level=90, fan=FALSE, bootstrap=FALSE, seed=1234,
npaths=1000)
```

```
#### Grafica de ajuste en los datos pronosticados
plot(forecast(entrenamiento, h=length(Serie_Anual)-as.integer(alpha *
length(Serie_Anual)), level=90, fan=FALSE, bootstrap=FALSE,
seed=1234, npaths=1000))
grid()

##### Codigo de Serie Diaria#####

#Proporcion de entrenamiento sobre la informacion

alpha<-7/8
numero_rezagos<-2
numero_capas<-2

#Inicializacion de Matriz de resultados

diarios<-matrix(, nrow = ((numero_rezagos-1)*numero_capas), ncol = 16)

#Se toma la primeros alpha puntos de la serie para el proceso de
entrenamiento

x<-ts(data=c(seriediaria[1:as.integer(alpha * length(Serie_Diaria )),2]),
start=1,frequency=1)

completa<-ts(data=c(seriediaria[,2]),start=1,frequency=1)

for(i in 2:numero_rezagos){
  for(j in 1:numero_capas){

    # Se ajusta una ARNN a los datos de entrenamiento

    entrenamiento<- arnn(x=x, lags=1:i, isMLP=FALSE, H=j, w.max=1e-3,
restarts=10, seed = 1234, lambda=0, optim.control=list(maxit=200))

    #Informacion del modelo ajustado, estimacion de parametros de la red,
criterios de informacion, estimacion de la varianza y criterios de
informacion

    # summary(entrenamiento)

    #Medidas de error dentro de la muestra
accin<-accuracy(entrenamiento)

    # Medidas de error fuera de la muestra

    fuerademuestra<- arnn(x = completa , model = entrenamiento)

    accout<-accuracy(fitted(fuerademuestra)[as.integer(alpha *
```

```

length(completa ))+1:length(completa )],completa[as.integer
(alpha * length(completa))+1:length(completa)])

        w=numero_capas*(i-2)+j
        diarios[w,1]<-accin[1]
        diarios[w,2]<-accin[2]
        diarios[w,3]<-accin[3]
        diarios[w,4]<-accin[4]
        diarios[w,5]<-accin[5]
        diarios[w,6]<-accin[6]
        diarios[w,7]<-accin[7]
        diarios[w,8]<-accout[1]
        diarios[w,9]<-accout[2]
        diarios[w,10]<-accout[3]
        diarios[w,11]<-accout[4]
        diarios[w,12]<-accout[5]
        diarios[w,13]<-entrenamiento$IC[1]
        diarios[w,14]<-entrenamiento$IC[2]
        diarios[w,15]<-entrenamiento$IC[3]
        diarios[w,16]<-entrenamiento$IC[4]
    }
}

#write.csv(diarios, "Rdiarios.csv")

# Grafica de la serie y ajuste del modelo en la muestra de entrenamiento

par(mfrow=c(1,2))
plot(completa)
lines(fitted(fuerademuera), col = 'blue',lwd=0.3)
grid()

#Se generan 100 pronosticos hacia adelante cada uno a traves de una
muestra de 1000 observaciones.

forecast(entrenamiento, h=length(completa)-as.integer(alpha * length
(completa)),level=90, fan=FALSE, bootstrap=FALSE, seed=1234,
npaths=1000)

# Grafica de ajuste en los datos pronosticados

plot(forecast(entrenamiento, h=length(completa)-as.integer(alpha *
length(completa)), level=90, fan=FALSE, bootstrap=FALSE, seed=1234,
npaths=1000))
grid()

##### Codigo de Serie Semanal#####

```

```
#Proporcion de entrenamiento sobre la informacion

alpha<-7/8
numero_rezagos<-2
numero_capas<-4

#Inicializacion de Matriz de resultados

semanal<-matrix(, nrow = ((numero_rezagos-1)*numero_capas), ncol = 16)

# Se toma la primeros alpha puntos de la serie para el proceso de
entrenamiento

x<-ts(data=c(seriesemanal [1:as.integer(alpha * length(Serie_Semanal)),2]),
start=1,frequency=1)

completasemanal<-ts(data=c(seriesemanal[,2]),start=1,frequency=1)

for(i in 2:numero_rezagos){
  for(j in 1:numero_capas){

    #Se ajusta una ARNN a los datos de entrenamiento

    entrenamiento<- arnn(x=x, lags=1:i, isMLP=FALSE, H=j, w.max=1e-3,
      restarts=10, seed = 1234, lambda=0, optim.control=list(maxit=200))

    #Informacion del modelo ajustado, estimacion de parametros de la red,
    criterios de informacion, estimacion de la varianza y criterios de
    informacion

    summary(entrenamiento)

    #Medidas de error dentro de la muestra

    accin<-accuracy(entrenamiento)

    #Medidas de error fuera de la muestra

    fuerademuestra<- arnn(x = completasemanal , model = entrenamiento)

    accout<-accuracy(fitted(fuerademuestra)[as.integer(alpha *
      length(completasemanal))+1:length(completasemanal)], completasemanal
      [as.integer(alpha * length(completasemanal))+1:length(completasemanal)])

    w=numero_capas*(i-2)+j
    semanal[w,1]<-accin[1]
    semanal[w,2]<-accin[2]
    semanal[w,3]<-accin[3]
```

```

semanal[w,4]<-accin[4]
semanal[w,5]<-accin[5]
semanal[w,6]<-accin[6]
semanal[w,7]<-accin[7]
semanal[w,8]<-accout[1]
semanal[w,9]<-accout[2]
semanal[w,10]<-accout[3]
semanal[w,11]<-accout[4]
semanal[w,12]<-accout[5]
semanal[w,13]<-entrenamiento$IC[1]
semanal[w,14]<-entrenamiento$IC[2]
semanal[w,15]<-entrenamiento$IC[3]
semanal[w,16]<-entrenamiento$IC[4]
}
}

#write.csv(semanal, "Rsemanal.csv")

# Grafica de la serie y ajuste del modelo en la muestra de entrenamiento

par(mfrow=c(1,2))
plot(completasemanal)
lines(fitted(fuerademuestra), col = 'blue',lwd=0.3)
grid()

#Se generan 100 pronosticos hacia adelante cada uno a trav??s de una muestra
de 1000 observaciones.

forecast(entrenamiento, h=length(completasemanal)-as.integer(alpha * length
(completasemanal)), level=90, fan=FALSE, bootstrap=FALSE, seed=1234,
npaths=1000)

#Grafica de ajuste en los datos pronosticados
plot(forecast(entrenamiento, h=length(completasemanal)-as.integer(alpha *
length(completasemanal)), level=90, fan=FALSE, bootstrap=FALSE,
seed=1234, npaths=1000))
grid()

```

F.3. Implementación de modelos ARIMA y GARCH

```

##### Carga de Librerias#####

library(TSA); library(MASS)
library(FitAR); library(tseries)
library(timeSeries); library(fGarch)
library(forecast); library(reporttools)

```

```
#####Código General#####  
  
#Parametric division  
  
alpha<-2/3  
  
data<-Serie_Mensual  
  
#Divide it into two training period or validation period  
  
oilspot.ts1<-ts(data[1:as.integer(alpha * length(data))])  
a<-as.integer(alpha * length(data))+1  
oilspot.ts2<-ts(data[a:length(data)])  
  
length(data)  
length(oilspot.ts1)  
  
#Set up realised values for validation  
  
realised.ts1<-diff(log(oilspot.ts1))  
realised.ts2<-diff(log(oilspot.ts2))  
  
realised.ts1;  
oilspot.ts1;  
summary(oilspot.ts1);  
head(oilspot.ts1);  
  
#BoxCox plots to show the need of log transformation  
  
par(mfrow=c(1,1))  
BoxCox.ts(oilspot.ts1);  
plot(log(data))  
grid()  
  
#ADF test indicating non-stationarity  
  
adf.test(log(oilspot.ts1))  
log.return1<-diff(log(oilspot.ts1))  
adf.test(log.return1)  
  
#log return plot  
  
plot(diff(log(data)))  
log.return1<-diff(log(oilspot.ts1))  
log.return1  
  
#ACF and PACF plots
```

```

par(mfrow=c(1,2));
acf(as.vector(log.return1),drop.lag.0=FALSE)
pacf(as.vector(log.return1))

auto.arima(log.return1, d=NA, D=NA, max.p=5, max.q=5,
           max.P=2, max.Q=2, max.order=5, max.d=2, max.D=1,
           start.p=2, start.q=2, start.P=1, start.Q=1,
           stationary=FALSE, seasonal=TRUE,
           ic=c("aicc","aic", "bic"), stepwise=TRUE, trace=FALSE,
           approximation=(length(x)>100 | frequency(x)>12), xreg=NULL,
           test=c("kpss","adf","pp"), seasonal.test=c("ocsb","ch"),
           allowdrift=TRUE, lambda=NULL, parallel=FALSE, num.cores=NULL)

#Write a function to compute AIC of various ARMA orders

AICfn<-function(N,K)
{
  for(i in 1:N)
  {for(j in 1:N)
  {
    print(AIC(arima(K,order=c(i-1,0,j-1))))
  }}
}

AICfn(3,log.return1)

#Models determined

model1<-arima(log.return1,order=c(2,0,2),include.mean=FALSE)
model1
model2<-arima(log.return1,order=c(0,0,1),include.mean=FALSE)
model2

#Residual analysis
par(mfrow=c(1,1))
plot(model1$resid);abline(h=0)
adf.test(model1$resid)

#Residual ACF and PACF plots
par(mfrow=c(1,2))
acf(as.vector(model1$resid),drop.lag.0=FALSE)
pacf(as.vector(model1$resid))
acf(as.vector(model1$resid^2),drop.lag.0=FALSE)
pacf(as.vector(model1$resid^2))

#Normality tests
par(mfrow=c(1,1))
qqnorm(residuals(model1)); qqline(residuals(model1))
qqnorm(residuals(model2)); qqline(residuals(model2))

```

```
jarque.bera.test(model1$resid)
#jarque.bera.test(model2$resid)

#Independence tests

McLeod.Li.test(,model1$resid,gof.lag=20)
#McLeod.Li.test(,model2$resid,gof.lag=20)

#Write a function to compute AICs of various GARCH orders
AICfn2<-function(N,K)
{
  for(i in 1:(N+1))
  { for(j in 1:N)
    {
      print(AIC(garch(residuals(K),order=c(i,j-1),trace=FALSE)))
    }
  }
}
AICfn2(3,model1);

#AICfn2(3,model2)

#GARCH model fitted
model.garch<-garch(model1$resid,order=c(1,1),trace=F)

model.garch.res<-resid(model.garch)[-1]
par(mfrow=c(1,2))
acf(model.garch.res,drop.lag.0=FALSE)
pacf(model.garch.res)
acf(model.garch.res^2,drop.lag.0=FALSE)
pacf(model.garch.res^2)
```

Bibliografía

- Abosedra, S. (2005). Futures versus univariate forecast of crude oil prices, *OPEC Review* **29**(4): 231–241.
URL: <http://econpapers.repec.org/RePEc:bla:opecrv:v:29:y:2005:i:4:p:231-241>
- Agnolucci, P. (2009). Volatility in crude oil futures: A comparison of the predictive ability of garch and implied volatility models, *Energy Economics* **31**(2): 316–321.
URL: <http://EconPapers.repec.org/RePEc:eee:eneeco:v:31:y:2009:i:2:p:316-321>
- Ahmad, M. (2012). Modelling and forecasting oman crude oil prices using box-jenkins techniques, *International Journal of Trade and Global Markets* **5**(1): 24–30.
URL: <http://EconPapers.repec.org/RePEc:ids:ijtrgm:v:5:y:2012:i:1:p:24-30>
- Akaike, H. (1974). A new look at the statistical model identification, *Automatic Control, IEEE Transactions on* **19**(6): 716–723.
- Amin, M. & Gharacheh, E. (2007). A hybrid artificial intelligence approach to monthly forecasting of crude oil price time series, *The Proceedings of the 10th International Conference on Engineering Applications of Neural Networks* pp. 160–167.
- Bergmeir, C. (2011). Rsnns: Neural networks in r using the stuttgart neural network simulator, *R-CRAN*.
URL: <http://cran.r-project.org/web/packages/rsnns/>
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics* **31**(3): 307–327.
URL: <http://EconPapers.repec.org/RePEc:eee:econom:v:31:y:1986:i:3:p:307-327>
- Bopp, A. E. & Lady, G. M. (1991). A comparison of petroleum futures versus spot prices as predictors of prices in the future, *Energy Economics* **13**(4): 274–282.
URL: <http://econpapers.repec.org/RePEc:eee:eneeco:v:13:y:1991:i:4:p:274-282>
- Box, G. E. P. & Jenkins, G. (1990). *Time Series Analysis, Forecasting and Control*, Holden-Day, Incorporated.
- Cannon, A. (2010). Package monmlp: Monotone multi-layer perceptron neural network, *R-CRAN*.
URL: <http://cran.r-project.org/web/packages/monmlp/>
- Chinn, M., LeBlanc, M. & Coibion, O. (2005). The predictive content of energy futures: An update on petroleum, natural gas, heating oil and gasoline, *NBER Working Papers*

- 11033, National Bureau of Economic Research, Inc.
URL: <http://econpapers.repec.org/RePEc:nbr:nberwo:11033>
- Chow, T. (2002). Nonlinear autoregressive integrated neural network model for short-term load forecasting, *Generation Transmission and Distribution, IEE Proceedings* **143**(5): 500–506.
- Clewlow, L. & Strickland, C. (2000). *Energy derivatives: pricing and risk management*, Lacima Publications.
URL: <http://books.google.com/books?id=HRR2QgAACAAJ>
- Dees, S., Karadeloglou, P., Kaufmann, R. K. & Sanchez, M. (2007). Modelling the world oil market: Assessment of a quarterly econometric model, *Energy Policy* **35**(1): 178–191.
URL: <http://econpapers.repec.org/RePEc:eee:enepol:v:35:y:2007:i:1:p:178-191>
- Di Narzo, F., Aznarte, J. & Stigler, M. (2011). tsdyn: Nonlinear time series models with regime switching, *R-CRAN* .
URL: <http://cran.r-project.org/web/packages/tsDyn/>
- Dickey, D. & Fuller, W. (1979). Distribution of the estimators for autoregressive time series with a unit root, *JASA* **74**: 427–431.
- Engle, R. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation, *Econometrica* **50**(4): 987–1007.
URL: <http://EconPapers.repec.org/RePEc:ecm:emetrp:v:50:y:1982:i:4:p:987-1007>
- Engle, R. F. & Granger, C. W. J. (1987). Co-integration and error correction: Representation, estimation, and testing, *Econometrica* **55**(2): 251–76.
URL: <http://econpapers.repec.org/RePEc:ecm:emetrp:v:55:y:1987:i:2:p:251-76>
- Espinoza, A. V. P., Mere, J. B. O., de Pison, F. J. M. & Marcos, A. G. (2005). Tao-robust backpropagation learning algorithm, *Neural Networks* **18**(2): 191 – 204.
URL: <http://www.sciencedirect.com/science/article/pii/S0893608004002345>
- Fritsch, S. & Guenther, F. (2010). neuralnet: Training of neural networks, *R-CRAN* .
URL: <http://cran.r-project.org/web/packages/neuralnet/>
- Green, S. L. & Mork, K. A. (1991). Toward efficiency in the crude-oil market, *Journal of Applied Econometrics* **6**(1): 45–66.
URL: <http://econpapers.repec.org/RePEc:jae:japmet:v:6:y:1991:i:1:p:45-66>
- Gulen, S. G. (1998). Efficiency in the crude oil futures market, *Journal of Energy Finance & Development* **3**(1): 13–21.
URL: <http://econpapers.repec.org/RePEc:eee:jefdev:v:3:y:1998:i:1:p:13-21>
- Hyndman, R. J. & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for r, *Journal of Statistical Software* **27**(3): 1–24.
- Hyndman, R. & Koehler, A. B. (2006). Another look at measures of forecast accuracy, *International Journal of Forecasting* **22**(4): 679–688.
URL: <http://EconPapers.repec.org/RePEc:eee:intfor:v:22:y:2006:i:4:p:679-688>

- Ihaka, R. & Gentleman, R. (1996). R: A language for data analysis and graphics, *Journal of Computational and Graphical Statistics* **5**(3): pp. 299–314.
URL: <http://www.jstor.org/stable/1390807>
- IMF (2000). The impact of higher oil prices on the global economy, *Macroeconomics*, IMF.
URL: <http://www.imf.org/external/pubs/ft/oil/2000>
- Ising, A. (2006). Héylette geman: Commodities and commodity derivatives - modeling and pricing for agriculturals, metals and energy, *Financial Markets and Portfolio Management* **20**(3): 363–364.
URL: <http://ideas.repec.org/a/kap/fmktpm/v20y2006i3p363-364.html>
- Jalil, M. & Misas, M. (2007). Evaluación de pronósticos del tipo de cambio utilizando redes neuronales y funciones de pérdida asimétricas, *Revista Colombiana de Estadística* **30**(1): 143–161.
- Jarque, C. M. & Bera, A. K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals, *Economics Letters* **6**(3): 255–259.
URL: <http://EconPapers.repec.org/RePEc:eee:ecole:v:6:y:1980:i:3:p:255-259>
- Jiménez, J. R. P. (2010). El impacto de los precios del petróleo sobre el crecimiento económico en colombia, *Archivos de economía*, Departamento Nacional de Planeación.
URL: <http://econpapers.repec.org/RePEc:col:000118:008849>
- Kaboudan, M. A. (2001). Compumetric forecasting of crude oil prices, *Proceedings of the 2001 Congress on Evolutionary Computation CEC2001*, IEEE Press, COEX, World Trade Center, 159 Samseong-dong, Gangnam-gu, Seoul, Korea, pp. 283–287.
- Kaufmann, R. K. (1995). A model of the world oil market for project link integrating economics, geology and politics, *Economic Modelling* **12**(2): 165–178.
URL: <http://econpapers.repec.org/RePEc:eee:ecmode:v:12:y:1995:i:2:p:165-178>
- Kaufmann, R. K., Dees, S., Karadeloglou, P. & Sanchez, M. (2004). Does opec matter? an econometric analysis of oil prices, *The Energy Journal* **25**(4): 67–90.
URL: <http://econpapers.repec.org/RePEc:aen:journl:2004v25-04-a04>
- Khashei, M. & Bijari, M. (2011). A novel hybridization of artificial neural networks and arima models for time series forecasting, *Appl. Soft Comput.* pp. 2664–2675.
- Kisi, O. (2009). Neural network and wavelet conjunction model for modelling monthly level fluctuations in turkey, *Hydrological Processes* pp. 2081–2092.
- LeCun, Y., Bottou, G. & Muller, K. (1998). *Neural Networks - Tricks of the Trade*, Springer Lecture Notes in Computer Sciences.
URL: <http://dblp.uni-trier.de/db/series/lncs/lncs7700.html>
- Liu, J., Bai, Y. & Li, B. (2007). A new approach to forecast crude oil price based on fuzzy neural network, *Proceedings of the Fourth International Conference on Fuzzy Systems and Knowledge Discovery* pp. 273–277.
- McLeod, A. I. (1983). Diagnostic Checking ARMA Time Series Models Using Squared-Residual Autocorrelations, *J. Time Series Anal.* **4**: 269–273.

- Mirmirani, S. & Li, H. (2004). A comparison of var and neural networks with genetic algorithm in forecasting price of oil, *Advances in Econometrics* **19**: 203–223.
- Misas, M., Lpez, E., Arango, C. A. & Aguilera, J. N. H. (2003). La demanda de efectivo en colombia: Una caja negra a la luz de las redes neuronales, *Borradores de economia*, Banco de la Republica de Colombia.
URL: <http://econpapers.repec.org/RePEc:bdr:borrec:268>
- Mohammadi, H. & Su, L. (2010). International evidence on crude oil price dynamics: Applications of arima-garch models, *Energy Economics* **32**(5): 1001–1008.
URL: <http://EconPapers.repec.org/RePEc:eee:eneeco:v:32:y:2010:i:5:p:1001-1008>
- Moosa, I. A. & Al-Loughani, N. E. (1994). Unbiasedness and time varying risk premia in the crude oil futures market, *Energy Economics* **16**(2): 99–105.
URL: <http://econpapers.repec.org/RePEc:eee:eneeco:v:16:y:1994:i:2:p:99-105>
- Morana, C. (2001a). A semiparametric approach to short-term oil price forecasting, *Energy Economics* **23**(3): 325–338.
URL: <http://EconPapers.repec.org/RePEc:eee:eneeco:v:23:y:2001:i:3:p:325-338>
- Morana, C. (2001b). A semiparametric approach to short-term oil price forecasting, *Energy Economics* **23**(3): 325–338.
URL: <http://econpapers.repec.org/RePEc:eee:eneeco:v:23:y:2001:i:3:p:325-338>
- Moshiri, S. & Foroutan, F. (2006). Forecasting nonlinear crude oil futures prices, *The Energy Journal* **27**(4): 81–96.
URL: <http://econpapers.repec.org/RePEc:aen:journl:2006v27-04-a04>
- Pindyck, R. S. (1998). The long-run evolution of energy prices, *Working papers WP 4044-98.*, Massachusetts Institute of Technology (MIT), Sloan School of Management.
URL: <http://econpapers.repec.org/RePEc:mit:sloanp:2734>
- Plourde, A. & Watkins, G. (1998). Crude oil prices between 1985 and 1994: how volatile in relation to other commodities?, *Resource and Energy Economics* **20**(3): 245 – 262.
URL: <http://www.sciencedirect.com/science/article/pii/S0928765597000274>
- Radchenko, S. I. (2005). The long-run forecasting of energy prices using the model of shifting trend, *Econometrics*, EconWPA.
URL: <http://econpapers.repec.org/RePEc:wpa:wwpem:0502002>
- Rast, M. (2001). Fuzzy neural networks for modelling commodity markets, *The Proceedings of the Conference of the North American Fuzzy Information Processing Society* pp. 952–955.
- Ripley, B. (2011). Package nnet: Feed-forward neural networks and multinomial log-linear models, *R-CRAN*.
URL: <http://cran.r-project.org/web/packages/nnet/>
- Samii, V. (1992). Oil futures and spot markets, *OPEC Review* **4**(1): 409–417.
URL: <http://econpapers.repec.org/RePEc:eee:enepol:v:35:y:2007:i:1:p:178-191>
- Serletis, A. (1991). Rational expectations, risk and efficiency in energy futures markets, *Energy Economics* **13**(2): 111–115.
URL: <http://econpapers.repec.org/RePEc:eee:eneeco:v:13:y:1991:i:2:p:111-115>

- Swanson, N. R. & White, H. (1995). A model selection approach to real-time macroeconomic forecasting using linear models and artificial neural networks, *Macroeconomics, EconWPA*.
URL: <http://econpapers.repec.org/RePEc:wpa:uwpma:9503004>
- Velasquez, J. & Montoya, O. (2010). Es el proyecto r para la computacion estadistica apropiado para la inteligencia artificial, *Ingenieria y Competitividad* pp. 81–94.
- Wang, S. Y., Yu, L. & Lai, K. K. (2004). A novel hybrid ai system framework for crude oil price forecasting, *Lecture Notes in Computer Science* **3327**(1): 233–242.
- Xie, W., Yu, L., Xu, S. & Wang, S. (2006). A new method for crude oil price forecasting based on support vector machines, *Lecture notes in computer science* **3994**: 444–451.
- Ye, M., Zyren, J. & Shore, J. (2002). Forecasting crude oil spot price using oecd petroleum inventory levels, *International Advances in Economic Research* **8**: 324–334.
- Ye, M., Zyren, J. & Shore, J. (2005). A monthly crude oil spot price forecasting model using relative inventories, *International Journal of Forecasting* **21**(3): 491–501.
URL: <http://econpapers.repec.org/RePEc:eee:intfor:v:21:y:2005:i:3:p:491-501>
- Ye, M., Zyren, J. & Shore, J. (2007). Forecasting short-run crude oil price using high- and low-inventory variables, *Energy Policy* **34**(17): 2736–2743.
URL: <http://econpapers.repec.org/RePEc:eee:enepol:v:34:y:2006:i:17:p:2736-2743>
- Yoon, S.-M. & Kang, S. H. (2012). Modelling and forecasting the volatility of petroleum futures prices, *EcoMod2012 3944*, *EcoMod*.
URL: <http://EconPapers.repec.org/RePEc:ekd:002672:3944>
- Zeng, T. & Swanson, N. R. (1998). Predictive evaluation of econometric forecasting models in commodity futures markets, *Studies in Nonlinear Dynamics & Econometrics* **2**(4): 6.
URL: <http://ideas.repec.org/a/bpj/sndecm/v2y1998i4n6.html>
- Zhang, H. & Zhang, Z. (1999). Feedforward networks with monotone constraints, *International Joint Conference on Neural Networks* pp. 1820–1823.
- Zhang, Y.-J. & Wei, Y.-M. (2011). The dynamic influence of advanced stock market risk on international crude oil returns: an empirical analysis, *Quantitative Finance* **11**(7): 967–978.
URL: <http://EconPapers.repec.org/RePEc:taf:quantf:v:11:y:2011:i:7:p:967-978>