

Predicción de los precios del fondo FAANG mediante la aplicación de modelos ARIMA, ARCH
y GARCH

JAVIER ALEXANDER ROMÁN ORDÓÑEZ

Trabajo de Grado para Optar al Título de Especialista en Estadística

Director:

Giampaolo Orlandoni Merli

Doctor en Estadística

Universidad Industrial de Santander

Facultad de Ciencias

Escuela de Matemáticas

Especialización en Estadística

Bucaramanga

2019

Contenido

	Pág.
Introducción	17
1. Antecedentes	20
2. Objetivos	24
2.1 Objetivo General.....	24
2.2 Objetivos Específicos.....	24
3 Marco Teórico.....	25
3.1 Bolsa de Valores.....	25
3.2 Índice Bursátil.....	25
3.3 Las Acciones.....	26
3.4 Retorno de una Acción.....	28
3.5 Predicciones en Bolsa de Valores.....	29
3.6 Series Temporales.....	30
3.7 Proceso Estocástico.....	30
3.8 Proceso Estocástico de Raíz Unitaria.....	32
3.9 Pruebas de Estacionariedad.....	33
3.9.1 Análisis gráfico.....	33
3.9.2 Función de autocorrelación y correlograma.....	33
3.9.3 Prueba de raíz unitaria.....	34
3.9 Procesos Autorregresivos.....	35
3.10Proceso de Media Móvil.....	36

3.11 Proceso Autoregresivo de Promedios Móviles (ARMA) y Procesos Autoregresivos Integrados De Medias Móviles (ARIMA)	37
3.12 Metodología Box – Jenkins	38
3.14 Volatilidad	39
3.15 Modelos ARCH y GARCH	39
3.15.1 Modelo ARCH	40
3.15.2 Modelo GARCH	41
3.15.3 Identificación de efectos ARCH	42
4. Resultados y Discusión	42
4.1 Contexto	42
4.1.1 Las FAANG	46
4.2 Descripción de la Muestra	49
4.3 Análisis Descriptivo y Clásico de las Series de Tiempo FAANG	50
4.3.1 Facebook	50
4.3.1.1 Análisis descriptivo y contextual	50
4.3.1.2 Componentes	51
4.3.1.3 Suavizamiento exponencial: Holt-Winters	53
4.3.2 Amazon	54
4.3.2.1 Análisis descriptivo y contextual	54
4.3.2.2 Componentes	55
4.3.2.3 Suavizamiento exponencial: Holt-Winters	57
4.3.3 Apple	58
4.3.3.1 Análisis descriptivo y contextual	58

4.3.3.2 Componentes.....	59
4.3.3.3 Suavizamiento exponencial: Holt-Winters.	61
4.3.4 Netflix	62
4.3.4.1 Análisis descriptivo y contextual.....	62
4.3.4.2 Componentes.....	63
4.3.4.3 Suavizamiento exponencial: Holt-Winters.	65
4.3.5 Google.....	66
4.3.5.1 Análisis descriptivo y contextual.....	66
4.3.5.2 Componentes.....	67
4.3.5.3 Suavizamiento exponencial: Holt-Winters	69
4.4 Modelos ARIMA	70
4.4.1 Transformación de las Series de Tiempo de la Cotizaciones de las Acciones de las FAANG	70
4.4.1.1 Facebook.....	70
4.4.1.2 Amazon.....	73
4.4.1.3 Apple.....	75
4.4.1.4 Netflix.....	78
4.4.1.5 Google.....	80
4.4.2 Metodología Box – Jenkins: Modelos ARIMA para las FAANG.....	83
4.4.2.1 Facebook.....	83
4.4.2.1.1 Identificación.....	83
4.4.2.1.2 Estimación.....	83
4.4.2.1.3 Diagnóstico.....	84

4.4.2.2 Amazon.....	87
4.4.2.2.1 Identificación..	87
4.4.2.2.2 Estimación.....	87
4.4.2.2.3 Diagnóstico.	88
4.4.2.3 Apple.....	90
4.4.2.3.1 Identificación.	90
4.4.2.3.2 Estimación.....	90
4.4.2.3.3 Diagnóstico.	91
4.4.2.4 Netflix	94
4.4.2.4.1 Identificación..	94
4.4.2.4.2 Estimación.....	94
4.4.2.4.3 Diagnóstico.	95
4.4.2.5 Google.....	97
4.4.2.5.1 Identificación.	97
4.4.2.5.2 Estimación.....	97
4.4.2.5.3 Diagnóstico.	98
4.5 Modelos ARCH y GARCH.....	101
4.5.1 Efectos ARCH en las series de tiempo de las FAANG.	101
4.5.2 Identificación del Modelo ARCH y GARCH.....	102
4.5.3 Estimación de los Modelos y Diagnóstico.....	103
4.5.3.1 Amazon.	103
4.5.3.2 Apple.....	104
4.5.3.3 Netflix.	106

4.6 Predicción de los Modelos Obtenidos	107
4.6.1 Facebook.....	107
4.6.2 Amazon.....	109
4.6.3 Apple.....	113
4.6.4 Netflix.....	115
4.6.5 Google.....	118
4.6.6 Predicción de los precios y errores de pronóstico.....	120
5. Conclusiones	122
Referencias Bibliográficas	126
Apéndices.....	130
Apéndice A. Script en R	130

Lista de Figuras

	Pág.
Figura 1. Cotización diaria del índice S&P500 para el periodo mayo 2014 – mayo 2019.....	43
Figura 2. Retornos diarios de los distintos sectores que conforman el índice S&P500 en los últimos 5 años.	45
Figura 3. Ranking de países por PIB frente al capital bursátil de las FAANG.....	47
Figura 4. Retornos diarios de las FAANG para el periodo mayo 2014 – mayo 2019.....	48
Figura 5. Cotización diaria de las acciones de Facebook y eventos claves de la guerra comercial entre Estados Unidos y China.	50
Figura 6. Componentes de la serie de las cotizaciones de las acciones de Facebook.....	52
Figura 7. Pronóstico de la cotización de las acciones de Facebook.....	53
Figura 8. Cotización diaria de las acciones de Amazon y eventos claves de la guerra comercial entre Estados Unidos y China.	54
Figura 9. Componentes de la serie de las cotizaciones de las acciones de Amazon.....	56
Figura 10. Pronóstico de la cotización de las acciones de Amazon.....	57
Figura 11. Cotización diaria de las acciones de Apple y eventos claves de la guerra comercial entre Estados Unidos y China.	58
Figura 12. Componentes de la serie de las cotizaciones de las acciones de Apple	60
Figura 13. Pronóstico de la cotización de las acciones de Apple	61

Figura 14. Cotización diaria de las acciones de Netflix y eventos claves de la guerra comercial entre Estados Unidos y China. 62

Figura 15. Componentes de la serie de las cotizaciones de las acciones de Netflix 64

Figura 16. Pronóstico de la cotización de las acciones de Netflix 65

Figura 17. Cotización diaria de las acciones de Google y eventos claves de la guerra comercial entre Estados Unidos y China. 66

Figura 18. Componentes de la serie de las cotizaciones de las acciones de Google 68

Figura 19. Pronóstico de la cotización de las acciones de Google 69

Figura 20. Función de autocorrelación simple y parcial para la serie logarítmica de Facebook .. 71

Figura 21. Retornos de las acciones de Facebook 72

Figura 22. Función de autocorrelación simple y parcial para la serie logarítmica de Amazon 73

Figura 23. Retornos de las acciones de Amazon 74

Figura 24. Función de autocorrelación simple y parcial para la serie logarítmica de Apple..... 75

Figura 25. Retornos de las acciones de Apple 77

Figura 26. Función de autocorrelación simple y parcial para la serie logarítmica de Netflix 78

Figura 27. Retornos de las acciones de Netflix..... 79

Figura 28. Función de autocorrelación simple y parcial para la serie logarítmica de Google..... 80

Figura 29. Retornos de las acciones de Google 82

Figura 30. Diagnóstico de los residuos para el modelo ARIMA de la empresa Facebook. 85

Figura 31. Diagnóstico de los residuos para el modelo ARIMA de la empresa Amazon. 88

Figura 32. Diagnóstico de los residuos para el modelo ARIMA de la empresa Apple. 92

Figura 33. Diagnóstico de los residuos para el modelo ARIMA de la empresa Netflix..... 95

Figura 34. Diagnóstico de los residuos para el modelo ARIMA de la empresa Google. 99

Figura 35. Predicción con serie de entrenamiento para los retornos de Facebook. 108

Figura 36. Predicción a 30 días de los retornos de las acciones de Facebook. 109

Figura 37. Predicción de los retornos y la volatilidad con datos de entrenamiento para Amazon
 110

Figura 38. Impacto de la volatilidad para la empresa Amazon..... 111

Figura 39. Predicción del retorno y la volatilidad de las acciones de Amazon 112

Figura 40. Predicción de los retornos y la volatilidad con datos de entrenamiento para Apple. 113

Figura 41. Impacto de la volatilidad para la empresa Apple 114

Figura 42. Predicción del retorno y la volatilidad de las acciones de Apple 115

Figura 43. Predicción de los retornos y la volatilidad con datos de entrenamiento para Netflix 116

Figura 44. Impacto de la volatilidad para la empresa Netflix..... 117

Figura 45. Predicción del retorno y la volatilidad de las acciones de Netflix 118

Figura 46. Predicción con serie de entrenamiento para los retornos de Google. 119

Figura 47. Predicción a 30 días de los retornos de las acciones de Google..... 120

Lista de Tablas

	Pág.
Tabla 1. Participación porcentual en el índice S&P500 por sectores	44
Tabla 2. Capital bursátil de las FAANG.....	46
Tabla 3. Características de la muestra.....	49
Tabla 4. Estimación del modelo ARIMA para la serie de retornos de Facebook.....	84
Tabla 5. Resultados del test Ljung – Box para los residuos de Facebook.....	86
Tabla 6. Resultados de la prueba de normalidad para los residuos de Facebook.....	86
Tabla 7. Estimación del modelo ARIMA para la serie de retornos de Amazon.....	87
Tabla 8. Resultados del test Ljung – Box para los residuos de Amazon.....	89
Tabla 9. Resultados de la prueba de normalidad para los residuos de Amazon.....	90
Tabla 10. Estimación del modelo ARIMA para la serie de retornos de Apple.....	91
Tabla 11. Resultados del test Ljung – Box para los residuos de Apple.....	93
Tabla 12. Resultados de la prueba de normalidad para los residuos de Apple.....	93
Tabla 13. Estimación del modelo ARIMA para la serie de retornos de Netflix.....	94
Tabla 14. Resultados del test Ljung – Box para los residuos de Netflix.....	96
Tabla 15. Resultados de la prueba de normalidad para los residuos de Netflix.....	97
Tabla 16. Estimación del modelo ARIMA para la serie de retornos de Google.....	98
Tabla 17. Resultados del test Ljung – Box para los residuos de Google.....	100

Tabla 18. Resultados de la prueba de normalidad para los residuos de Google.....	100
Tabla 19. Presencia de efectos ARCH.....	101
Tabla 20. Modelos ARCH y GARCH escogidos para las empresas Amazon, Apple y Netflix.	103
Tabla 21. Estimación del modelo GARCH para la serie de retornos de Amazon	103
Tabla 22. Resultados del test Ljung – Box para los residuos del modelo GARCH de Amazon	104
Tabla 23. Estimación del modelo GARCH para la serie de retornos de Apple.....	105
Tabla 24. Resultados del test Ljung – Box para los residuos del modelo GARCH de Apple	106
Tabla 25. Estimación del modelo ARCH para la serie de retornos de Netflix	106
Tabla 26. Resultados del test Ljung – Box para los residuos del modelo ARCH de Netflix	107
Tabla 27. Predicción a 10 días de la cotización de las acciones del fondo FAANG	121
Tabla 28. Ajuste de los distintos obtenidos	122

Lista de Apéndices

	Pág.
Apéndice A. Script en R	130

RESUMEN

TÍTULO: PREDICCIÓN DE LOS PRECIOS DEL FONDO FAANG MEDIANTE LA APLICACIÓN DE MODELOS ARIMA, ARCH Y GARCH.*

AUTOR: JAVIER ALEXANDER ROMÁN ORDÓÑEZ.**

PALABRAS CLAVES: Cotización, retorno, acciones, volatilidad, guerra comercial, predicción.

DESCRIPCIÓN:

La cotización en bolsa por parte de las empresas del fondo FAANG ha venido generando interés en inversionistas por el volumen diario de sus transacciones, la dimensión de su capital bursátil y sus atractivos rendimientos. Dada la importancia del fondo FAANG en el mercado de capitales el presente trabajo tiene como objeto predecir la cotización de sus acciones, para ello se estimaron modelos ARIMA, ARCH y GARCH sobre una muestra que incluye el precio de las acciones en el contexto de la actual guerra comercial entre Estados Unidos y China.

El estudio inició exponiendo la dinámica actual del mercado bursátil donde se desenvuelve el fondo FAANG en aspectos como: comportamiento en el mercado, importancia de su capital bursátil, su rentabilidad y su perspectiva en el corto plazo teniendo en cuenta el escenario de guerra comercial. Posteriormente se realizó un análisis clásico sobre cada una de las series de tiempo pero estas, al no presentar tendencia lineal ni polinómica limitó el resultado de las predicciones, por otro lado al aplicar la metodología Box – Jenkins se encontró que únicamente las series de las empresas Facebook y Google se ajustaron a los modelos ARIMA, mientras que las series de las empresas Amazon, Apple y Netflix presentaron clúster de volatilidad, en consecuencia para estas series se estimaron modelos ARCH y GARCH. Finalmente, las predicciones bajo los modelos obtenidos evidenciaron que se espera una cotización estable de las acciones para las empresas Facebook, Apple y Google, mientras que para las empresas Amazon y Netflix se espera un aumento en la volatilidad sumado a un aumento en la cotización de la acción.

* Trabajo de Grado.

** Facultad de Ciencias, Escuela de Matemáticas. Director: Giampaolo Orlandoni Merli. Doctor en Estadística.

ABSTRACT

TITLE: PREDICTION OF FAANG FUND PRICES THROUGH THE APPLICATION OF ARIMA, ARCH AND GARCH MODELS.*

AUTHOR: JAVIER ALEXANDER ROMÁN ORDÓÑEZ.**

KEYWORDS: Quotation, return, shares, volatility, trade war, prediction.

DESCRIPTION:

The stock market price of the companies of the FAANG fund has been generating interest in investors for the daily volume of their transactions, the size of their stock market capital and their attractive returns. Given the importance of the FAANG fund in the capital market, this work aims to predict the price of its shares, for this purpose ARIMA, ARCH and GARCH models were estimated on a sample that includes the price of the shares in the context of the current one trade war between the United States and China.

The study began by exposing the current dynamics of the stock market where the FAANG fund operates in aspects such as: market behavior, importance of its stock market capital, its profitability and its short-term outlook taking into account the commercial war scenario. Subsequently, a classic analysis was carried out on each of the time series but these, not presenting a linear or polynomial tendency, limited the result of the predictions, on the other hand when applying the Box - Jenkins methodology, it was found that only the series of the Facebook companies and Google adjusted to the ARIMA models, while the series of Amazon, Apple and Netflix companies presented a volatility cluster, therefore ARCH and GARCH models were estimated for these series. Finally, the predictions under the models obtained showed that a stable share price is expected for Facebook, Apple and Google, while for Amazon and Netflix companies an increase in volatility is expected, together with an increase in the price of the action.

* Degree Work

** Faculty of Sciences, School of Mathematics. Director: Giampaolo Orlandoni Merli. Doctor of Statistics.

Introducción

Las bolsas de valores son entidades privadas consideradas como un instrumento para valorar los retornos de la economía de un país, por lo general sus movimientos son un indicador de qué tan bien funciona una economía en particular, aunque en la actualidad ante una economía cada vez más globalizada el grado de correlación entre las bolsas es tan significativo que la caída o el alza de alguna de ellas alteran positiva o negativamente las bolsas de otros países. La actividad principal de la bolsa de valores es comprar y vender activos financieros, generalmente allí participan empresas que emiten acciones con el fin de capitalizarse, además existen individuos, empresas u organizaciones que disponen de un capital (ahorro) para invertir no solo en acciones de otras empresas, también lo hacen en bonos públicos y privados, certificados o títulos de participación entre otros instrumentos.

La aglomeración de empresas en torno a sectores específicos ha dado lugar al nacimiento de los índices bursátiles que no son más que un promedio calculado de precios de acciones seleccionadas que representan un mercado o un sector en concreto. Existe un índice prácticamente para cada sector, algunos agrupan a las empresas líderes del mercado mundial como por ejemplo el índice Dow Jones Industrial Average, el FTSE 100, el S&P500, entre otros. Dentro de todos estos índices el S&P500 es uno de los más importantes de los Estados Unidos y del mundo siendo el más representativo de la situación real del mercado, este índice se compone de la capitalización bursátil de 500 grandes empresas que capturan más del 80% de toda la capitalización del mercado de este país. Es en este contexto que las acciones FAANG (acrónimo de las 5 acciones del sector

tecnológico más famosas y de mayor importancia en el mundo: Facebook, Apple, Amazon, Netflix y Google) representando al sector de la tecnología tienen una participación importante en este índice (actualmente el sector tecnológico representa el 19,9% del índice S&P500), lo que implica que el comportamiento en bolsa de estas empresas puede llegar a definir en gran medida la evolución de los mercados en Estados Unidos.

Estados Unidos es considerado la primera economía mundial, por lo tanto, lo que suceda allí terminará por afectar los mercados globales ya que en una economía globalizada las bolsas de otros países de alguna manera están correlacionadas y porque el capital bursátil de las FAANG en su conjunto es igual de importante al PIB de países desarrollados. Frente a este último aspecto, para citar un ejemplo, el portal de internet “Yahoo Finanzas” (YAHOO FINANZAS, 2019) afirma que el capital bursátil de APPLE INC. a febrero del 2019 alcanzó los 918,94 mil millones de dólares casi 3 veces el PIB de Colombia que según cifras del Banco Mundial (BANCO MUNDIAL, 2019) para el 2018 alcanzó los 330,2 mil millones de dólares, es decir, se está ante megacorporaciones más poderosas en términos económicos que muchos países independientemente de su nivel de desarrollo. Estos resultados más rentabilidades en promedio del 280% en los últimos cuatro años, han atraído a los mayores gestores de fondos en EE. UU. y del mundo quienes han decidido participar en las acciones FAANG pues las consideran en crecimiento y con un fuerte impulso alcista, aunque la actual “guerra comercial” entre China y Estados Unidos puede llegar a generar un escenario de incertidumbre teniendo en cuenta que este último país ha tomado medidas sensibles en detrimento del sector tecnológico chino.

Con base en lo anterior, el presente trabajo tiene como objeto analizar el comportamiento de las acciones diarias de las FAANG y predecir tanto sus cotizaciones como sus retornos para el periodo 2014 – 2019 realizando pronósticos de validación para el periodo mayo - agosto del presente año, es decir, los resultados se compararán con datos reales con el fin de determinar la validez de los modelos y los posibles efectos de la guerra comercial entre Estados Unidos y China que se caracteriza por la puesta en práctica de acciones como la imposición de aranceles, reducción de cuotas de importación y “coerción legal”. Asimismo, se espera que cada modelo obtenido sea un insumo básico para los operadores Day Trading e inversionistas de mediano plazo que deseen conformar portafolios de inversiones.

Finalmente, el desarrollo del trabajo se llevó a cabo mediante series de tiempo estudiando su descomposición clásica e implementando la metodología Box – Jenkins para modelos autorregresivos integrados de media móvil (ARIMA). Por otro lado, las series son de carácter financiero y en su gran mayoría la varianza condicionada a la información pasada no es constante, esto implica introducir los modelos ARCH y GARCH con el fin de realizar pronósticos más precisos.

1. Antecedentes

Sobre los distintos métodos empleados para predecir índices bursátiles (García, Jalal, Garzón, & López, 2013) presentan una completa revisión bibliográfica de cómo a través de los últimos veinte años se han implementado distintos métodos enfocados en la predicción de índices bursátiles. En esta revisión se muestran una variedad de métodos lineales, no lineales, híbridos y aquellos que involucran variables macroeconómicas en las predicciones mostrando en esencia las limitaciones de cada método empleado. Específicamente frente a los modelos ARIMA, ARCH y GARCH afirman que no logran capturar características no lineales de las series financieras, en esa medida proponen la necesidad de combinar dichos métodos lineales con otros de carácter no lineal para crear modelos híbridos más robustos sin olvidar la inclusión de variables macroeconómicas en el modelo. Este trabajo es de gran utilidad ya que permite conocer las bondades y las limitaciones de los modelos a emplear en el estudio que se pretende desarrollar, incorporando puntos de vista alternos precisamente en el índice S&P500 del cual hacen parte las FAANG.

Frente a la aplicación de modelos ARIMA en el pronóstico de los precios de las acciones y sus rentabilidades (Trejos Carpintero, Nieto Salazar, & Carvajal Olaya, 2013), aplicaron un modelo ARIMA para predecir el precio de las acciones de la empresa cementera “Argos” en la Bolsa de Valores de Colombia. Primero realizaron un análisis descriptivo para revisar la estacionariedad de la serie, posteriormente al aplicar una diferencia pudieron obtener un modelo ARIMA (1,1,0) (0,0,1)₁₀, concluyendo que la serie de tiempo no sigue un proceso aleatorio a diferencia de lo expresado por la teoría de los mercados eficientes. En otra aplicación del modelo ARIMA (García

Díaz, 2014), realiza una comparación entre los modelos ARIMA y GARCH contra un modelo de Red Neuronal Artificial Autorregresiva para el pronóstico de la rentabilidad de las acciones de la empresa ISAGEN para el periodo de octubre del 2007 hasta mayo del 2011. Inicialmente el autor muestra un contexto de la cotización en bolsa y del sector energético en Colombia, llegando a la conclusión de que los mercados no tienen una caminata aleatoria pues se evidencia autocorrelación en las distintas series analizadas, posteriormente al encontrar el modelo ARIMA aplicó el multiplicador de Lagrange (Engle, 1982) en donde evidenció la presencia de heterocedasticidad lo que se tradujo en la elaboración de un modelo GARCH. Finalmente estructuró un modelo de red neuronal artificial con el fin de modelar sistemas no lineales y realizar las respectivas comparaciones entre modelos empleando los estadísticos de error de pronóstico: el Error Cuadrático Medio (RMSE), Error Medio Absoluto (MAE) y el Error Porcentual Absoluto (MAPE). En las comparaciones el autor encontró que el modelo de Red Neuronal Artificial (RNA) es levemente mejor que los modelos ARIMA y GARCH dando motivo a la realización de la prueba de Diebold y Mariano (Diebold & Mariano, 1995) para ver la capacidad predictiva de cada modelo encontrándose que no existen evidencias significativas que defina cuál fue el mejor modelo.

Los anteriores trabajos aparte de mostrar de forma explícita la metodología empleada para los modelos ARIMA ponen en evidencia ciertas falencias que están asociadas principalmente a la volatilidad de la gran mayoría de las series de carácter financiero, mostrando la necesidad de encontrar modelos que no cumplan con el supuesto de homocedasticidad en la varianza como la familia de modelos ARCH y en particular modelos más robustos como las redes neuronales artificiales.

En cuanto al uso de modelos con heterocedasticidad condicional autorregresiva y su generalización ARCH y GARCH respectivamente, empleados para predecir precios de acciones (Casas Monsegny & Cepeda, 2008) utilizan dichos modelos para predecir los precios de las acciones y sus retornos de la empresa GILLETTE, no sin antes especificar conceptos claves de aspectos financieros y una aclaración acerca de que la volatilidad puede estar influenciada por variables externas, además da un marco conceptual acerca de cada modelo y lo más importante: cómo detectar efectos ARCH. En este trabajo de acuerdo con los criterios de información de Akaike (AIC) y bayesiano (BIC) obtenidos en varios modelos formulados y las características propias de la serie asumen que el mejor modelo para predecir el precio de las acciones es el GARCH (1,2) mientras que para predecir los retornos el modelo más adecuado es el EGARCH (2,1).

Por otro lado (Ospina & Giraldo Sánchez, 2009), especifican que debido a la volatilidad de los mercados financieros se deben encontrar modelos idóneos que ayuden a solventar esta particularidad, para ello son de vital importancia los modelos GARCH. En este caso los autores utilizaron dicho modelo para predecir el Valor en Riesgo (VaR) de las acciones de mayor bursatilidad del mercado colombiano, lo primero que hicieron los autores fue identificar el posible modelo ARIMA, posteriormente para analizar si la serie presenta heterocedasticidad analizaron los residuos del modelo y además aplicaron el test de multiplicadores de Lagrange (Engle, 1982) encontrando heterocedasticidad, esta particularidad llevó a los autores a utilizar el modelo GARCH para analizar las acciones de compañías como: Éxito, Suramericana, Bancolombia, Chocolates, Fabricato e Inverargos. Finalmente, los autores concluyen que estas acciones se ven afectadas en

mayor proporción por noticias negativas ya que las caídas fuertes de los precios producen predicciones de mayor volatilidad.

Estos artículos revisten importancia para el presente trabajo ya que es una guía metodológica para el desarrollo del mismo, por otra parte, permiten identificar patrones de las series que terminan por definir previamente qué tipo de modelo escoger ante la particularidad de la serie.

2. Objetivos

2.1 Objetivo General

Pronosticar la cotización de las acciones del fondo FAANG con periodicidad diaria, mediante el análisis de las series temporales para el periodo 2014-2019 aplicando los modelos ARIMA, ARCH y GARCH que mejor ajusten.

2.2 Objetivos Específicos

- Contextualizar el comportamiento bursátil del fondo FAANG con el fin de conocer parte de su historia, comportamiento en bolsa de valores y sus perspectivas en el mediano plazo.
- Describir las series de tiempo del estudio a través del enfoque de descomposición clásica determinando sus componentes.
- Desarrollar la metodología Box – Jenkins buscando encontrar distintos modelos ARIMA que pronostiquen la cotización de las acciones del fondo FAANG.
- Realizar las pruebas respectivas a las series de tiempo en estudio para identificar posibles efectos ARCH.
- Obtener modelos ARCH y GARCH cuando exista heterocedasticidad condicional en la varianza de las series de tiempo buscando mejorar la predicción.
- Comparar los distintos modelos obtenidos bajo el criterio AIC y los estadísticos de error de pronóstico con el fin de escoger los modelos mejor ajustados.

- Elaborar los pronósticos de las series de tiempo con los modelos que mejor ajusten y compararlos con los resultados reales observando su capacidad predictiva, permitiendo de esta manera un mejor análisis frente al escenario de guerra comercial.

3 Marco Teórico

3.1 Bolsa de Valores

La bolsa de valores es un mercado organizado donde se tranzan acciones, obligaciones, títulos, etc., a estos elementos se les fija un precio público que se conoce normalmente como cambio o cotización. Su acción se lleva a cabo en un mercado organizado donde confluyen la oferta y demanda de valores negociables, cumpliendo funciones en el sistema financiero de un país como: canalizar el ahorro, función de liquidez, movilizar la propiedad, función de estimación ya que básicamente la bolsa de valores permite diagnosticar en qué estado se encuentra la economía de un país, función de aseguradora (no permite los fraudes), función informativa y protección del ahorro (Vallejo & Torres, 2012, pág. 11).

3.2 Índice Bursátil

En términos reales un índice bursátil *“es un indicador que muestra cómo evoluciona el precio de un conjunto de activos cotizados que poseen unas determinadas características. Se compone de un conjunto de instrumentos, acciones o deuda y busca capturar las características y los movimientos de valor de los activos que lo componen”* (Stevens, 2017). Los índices prácticamente

permiten: percibir cómo está la economía o mercado de un país, un sector específico o un grupo importante de empresas, además su desempeño permite la gestión de portafolios de inversión, administrar de alguna manera los riesgos de inversión y mostrar productos o información real sobre las empresas que lo componen. En el mundo existen distintos índices que alcanzan un carácter global ya sea por la dimensión del capital bursátil que manejan, por la presencia de las empresas en otros países o por simple correlación entre las bolsas mundiales. Precisamente el índice *S&P500* es uno de los más negociados en el mundo ya que hacen parte de él las 500 empresas más representativas de Estados Unidos que a su vez cotizan en la bolsa de Nueva York e incluso en otras bolsas del mundo.

3.3 Las Acciones

Una acción básicamente es un título emitido por algún tipo de sociedad que representa una fracción del valor del capital social. Las acciones son de varios tipos (Vallejo & Torres, 2012, pág. 49):

Acción Nominal. Es un valor inicial que tienen las acciones y se puede expresar mediante la siguiente ecuación:

$$VN = \frac{CS}{NA}$$

donde:

VN: Valor nominal de las acciones.

CS: Capital social de la empresa.

NA: Número de acciones.

Valor Teórico. Se refiere al valor contable cuya fuente es el Balance General, por lo tanto, es un valor que se actualiza a través del funcionamiento cotidiano de la empresa. El valor teórico se expresa de la siguiente manera:

$$VT = \frac{(C + R)}{NA}$$

donde:

VT: Valor teórico.

C: Capital de la empresa.

R: Reservas.

NA: Número de acciones.

Valor Histórico. Representa una referencia de ganancia o pérdida (plusvalía o minusvalía), ya que su valor se fija en el precio de compra de la acción para compararla con el precio de venta.

Valor Bursátil. Es el precio en el que la acción cotiza en bolsa, fijándose en la ley de oferta y demanda, pero se debe tener en cuenta que esta cotización depende múltiples factores tanto internos como externos a la empresa.

3.4 Retorno de una Acción

El retorno de una acción en el mercado de valores hace referencia a la relación que existe entre el beneficio de tipo económico por parte de la acción y lo que se invierte en ella enmarcado en un determinado periodo. Lo que espera el inversionista es que sus acciones generen utilidades a una determinada tasa y que, por supuesto dichas acciones se conviertan rápidamente en liquidez, pero en el mercado de valores esta esperanza está condicionada a un riesgo. En su forma más simple el retorno se expresa de la siguiente manera:

$$Re_t = \frac{Pr_t - Pr_{t-1}}{Pr_{t-1}} = \frac{Pr_t}{Pr_{t-1}} - 1$$

donde,

Re_t : Es el retorno de la acción en el periodo t

Pr_t : Es el precio de la acción en el periodo t

Pr_{t-1} : Es el precio de la acción en el periodo $t - 1$.

Mientras que el retorno logarítmico se define por la siguiente expresión:

$$re_t = \ln(Re_t + 1) = \ln\left(\frac{Pr_t}{Pr_{t-1}}\right)$$

Esta serie no tiene unidades, es estacionaria y además realiza el cálculo de un retorno para k periodos.

3.5 Predicciones en Bolsa de Valores

La predicción de las cotizaciones de las acciones en bolsa ha sido un verdadero desafío que ha llevado incluso a formular distintas teorías y métodos que han venido avanzando a la par de la revolución informática. Predecir una acción en términos reales significa ganancias, pero también la validación de los distintos modelos formulados que básicamente lo que hacen es reducir la incertidumbre, dentro de estos modelos se destacan: modelos autorregresivos, promedios móviles, regresión múltiple, redes neuronales artificiales, suavizado exponencial, métodos lineales, entre otros.

De acuerdo con (Alonso & García, 2009) los mejores modelos para predecir en la década de los 80 eran los modelos ARIMA, pero en los años 90 estos dieron paso a los modelos ARCH y GARCH que le dan más importancia a la volatilidad, posteriormente han surgido una serie de modelos derivados de ARIMA, ARCH y GARCH que llegan a suplir ciertas falencias particulares. La presente década está marcada por el involucramiento masivo de la tecnología informática dando paso al uso de algoritmos soportados en ordenadores de gran capacidad de procesamiento de datos como los utilizados en los mercados bursátiles de alta frecuencia (*High Frequency Trading, HFT*), estos sistemas buscan procesar datos masivos en tiempo real (Vegas Villalmanzo, 2016), utilizando por lo general modelos de minería de datos, así como las redes neuronales artificiales.

3.6 Series Temporales

Las series de tiempo son “el resultado de observar los valores de una variable a lo largo del tiempo en intervalos regulares” (Peña, 2010, pág. 21). Cada serie de tiempo según el análisis clásico está conformada por cuatro componentes: tendencia, estacionalidad, ciclo y aleatoriedad o error.

3.7 Proceso Estocástico

Un proceso se define como estocástico cuando la variable ordenada en el tiempo es aleatoria (Gujarati & Porter, 2009, pág. 740). Estas variables aleatorias pueden ser discretas o continuas, claramente los datos de series de tiempo financieras se recopilan a escalas tiempo periódicas por lo que se tratarían de variables aleatorias discretas en donde además el conjunto de valores observados representa una muestra. Los procesos estocásticos pueden ser estrictamente estacionarios, homogéneos y débilmente estacionarios, para este último caso su media y varianza son constantes en el tiempo y la covarianza entre dos periodos depende únicamente del rezago entre ellos y no del tiempo en que se calcula la covarianza, esto implica que la media, la varianza y la covarianza de una serie Y_t estaría dada por las siguientes expresiones:

$$\text{Media: } E(Y_t) = \mu$$

$$\text{Varianza: } \text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2$$

$$\text{Covarianza: } \gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$$

donde γ_k es la covarianza en el rezago k entre los valores Y_t y Y_{t+k} , estas series de tiempo tenderán a regresar a su media y las fluctuaciones alrededor de esta serán constantes.

Los procesos estocásticos también pueden ser no estacionarios en el que la media cambia con el tiempo o la varianza cambia con el tiempo, o ambas de forma simultánea cambian con el tiempo. Otro tipo de proceso estocástico es el llamado *ruido blanco* en el que la media es igual a cero, se tiene una varianza σ^2 constante y sin correlación, es decir, un proceso de *ruido blanco* tiene una distribución Independiente e Idénticamente Distribuida como una distribución Normal con media cero y varianza constante. Ahora bien, también existen los procesos estocásticos no estacionarios correspondientes al *modelo de caminata aleatoria*, nuevamente son ejemplos clásicos de este tipo de procesos las series del mercado de valores (Gujarati & Porter, 2009, pág. 741). Los procesos estocásticos no estacionarios son de dos tipos: *Sin deriva o con deriva*, cuando el proceso es sin deriva no se tienen términos constantes o intercepto, por lo tanto, si ε_t es el error tipo ruido blanco entonces la serie Y_t empezando en el tiempo 0 con valor Y_0 se puede expresar de la siguiente manera:

$$Y_t = Y_0 + \sum \varepsilon_t$$

Su valor esperado y varianza son:

$$E(Y_t) = E\left(Y_0 + \sum \varepsilon_t\right) = Y_0$$

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

Para el caso del proceso estocástico no estacionario con deriva la serie de tiempo Y_t se expresa de la siguiente manera:

$$Y_t = \delta + Y_{t-1} + \varepsilon_t$$

donde δ es el parámetro de la deriva, asimismo su esperanza y varianza se expresan de la siguiente manera:

$$E(Y_t) = Y_0 + t * \delta$$

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

En resumen, un modelo de caminata aleatoria con o sin deriva es un proceso estocástico no estacionario ya que la media como su varianza cambian con el tiempo.

3.8 Proceso Estocástico de Raíz Unitaria

Si se escribe la serie Y_t de la siguiente manera: $Y_t = \rho * Y_{t-1} + \mu_t$ donde $-1 \leq \rho \leq 1$, se puede decir que si $\rho = 1$ se está ante un modelo de caminata aleatoria sin deriva y ante un problema de raíz unitaria o sea un proceso no estacionario, ahora bien, si $|\rho| < 1$ la serie de tiempo Y_t es estacionaria (Gujarati & Porter, 2009, pág. 744).

3.9 Pruebas de Estacionariedad

Antes de realizar un análisis de una serie de tiempo que derive en algún pronóstico es necesario saber si esta es o no estacionaria y si no es estacionaria qué se debe hacer para convertirla en estacionaria. Para saber si una serie de tiempo es estacionaria existen muchos métodos entre los cuales se tienen:

3.9.1 Análisis gráfico. Es importante antes de cualquier estudio graficar la serie de tiempo, analizar su comportamiento y formalizar posibles hipótesis.

3.9.2 Función de autocorrelación y correlograma. La función de autocorrelación en el rezago k viene dada por: $\rho_k = \frac{\gamma_k}{\gamma_0}$,

donde:

γ_k : covarianza en el rezago k

γ_0 : varianza

Desde luego si $k = 0$ entonces $\rho = 1$ ya que la correlación de una observación consigo misma es naturalmente uno, por otro lado, si se realiza una gráfica de ρ_k contra k la gráfica obtenida corresponde al correlograma. Para identificar cuándo una serie es o no estacionaria es importante observar los coeficientes de autocorrelación después de varios rezagos, si estos coeficientes son relativamente altos se está ante una serie de tiempo no estacionaria, por el contrario si dichos

coeficientes son bajos se está ante la presencia de una serie estacionaria aunque se debe definir qué tantos rezagos se deben tener en cuenta para calcular la *Función de Autocorrelación Simple* (FAC) y después verificar si los coeficientes de autocorrelación son estadísticamente significativos en los rezagos escogidos, para mirar la significación de los coeficientes es de gran ayuda el estadístico de Ljung – Box (LB) que se reduce en la siguiente expresión (Ljung & Box, 1978):

$$LB = n(n + 2) \sum_{k=1}^m \left(\frac{\hat{\rho}_k^2}{n - k} \right) \sim \chi^2 m$$

En donde la hipótesis nula afirma que los datos se distribuyen de forma independiente frente a la hipótesis alternativa de que los datos no se distribuyen de forma independiente, además n es el tamaño de la muestra, $\hat{\rho}_k$ es la autocorrelación de la muestra en el retraso k y m es el número de retardos que se están probando. Este estadístico tiene una distribución χ^2 con m grados de libertad. Si se rechaza la hipótesis nula esto quiere decir que la serie es no estacionaria siguiendo un modelo de caminata aleatoria, por el contrario, si no se rechaza la hipótesis nula la serie de tiempo es estacionaria.

3.9.3 Prueba de raíz unitaria. Recordando que la siguiente expresión: $Y_t = \rho * Y_{t-1} + \varepsilon_t$ con $\rho = 1$ es un proceso de raíz unitaria además es un proceso estocástico no estacionario, al restar a ambos lados de la ecuación Y_{t-1} se obtiene lo siguiente:

$$Y_t - Y_{t-1} = \rho * Y_{t-1} - Y_{t-1} + \varepsilon_t$$

$$Y_t - Y_{t-1} = (\rho - 1)Y_{t-1} + \varepsilon_t$$

$$\Delta Y_t = \delta * Y_{t-1} + \varepsilon_t$$

La idea es probar la hipótesis nula de que $\delta = 0$ frente la hipótesis alternativa de que $\delta < 0$. Por lo tanto, si no se rechaza la hipótesis nula la serie de tiempo es una caminata aleatoria sin deriva lo que implica que no sea estacionaria. Para saber si el coeficiente δ es o no cero existe la prueba Dickey – Fuller (DF) donde el valor estimado de t del coeficiente de Y_{t-1} sigue el estadístico de τ (Dickey & Fuller, 1979).

3.9 Procesos Autorregresivos

Una serie Y_t sigue un proceso autorregresivo AR (p) si obedece a la siguiente expresión:

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

Si el orden es AR (1) se genera por la siguiente expresión:

$$Y_t = \delta + \phi_1 Y_{t-1} + \varepsilon_t$$

donde δ y $-1 < \phi_1 < 1$ son constantes que se deben determinar y ε_t es un componente de error que sigue un proceso de ruido blanco. Para que el proceso sea estacionario se debe cumplir que $-1 < \phi_1 < 1$ y que $E(Y_t)$ no dependa de t (Peña, 2010, pág. 116). La esperanza y la varianza vienen dadas por las siguientes expresiones:

$$E(Y_t) = \mu = \frac{\delta}{(1 - \phi_1)}$$

$$var(Y_t) = \sigma_y^2 = \frac{\sigma^2}{(1 - \phi_1^2)}$$

De igual manera su covarianza y su función de autocorrelación se expresan de la siguiente manera:

$$\gamma_k = \phi_1 \gamma_{k-1}$$

$$\gamma_0 = \sigma_y^2$$

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \phi_1 \rho_{k-1} = \phi_1^k$$

La función de autocorrelación implica que cuando k es grande y dependiendo del valor de ϕ entonces ρ_k tenderá a cero de forma casi instantánea, es decir decrece geométricamente hacia cero.

3.10 Proceso de Media Móvil

Si la serie de tiempo Y_t es la suma de una constante más un promedio de los términos de error pasado y presente se está ante un proceso de media móvil, es decir, se le agregan dependencias al proceso de ruido blanco (Peña, 2010, pág. 150). En términos generales un proceso de media móvil de orden q viene dado por la expresión:

$$Y_t = \delta + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Un proceso de media móvil de orden 1 MA (1) estaría dado por la siguiente expresión:

$$Y_t = \delta + \varepsilon_t + \theta_1 \varepsilon_{t-1}$$

Como el término de error es un proceso de ruido blanco la varianza viene dada por:

$$\sigma_y^2 = \sigma^2 * (1 + \theta^2)$$

Lo que implica que la varianza del proceso σ_y^2 es siempre mayor a la varianza de la nueva información (innovaciones) σ^2 e incluso es mucho mayor si θ^2 asume valores altos.

3.11 Proceso Autoregresivo de Promedios Móviles (ARMA) y Procesos Autoregresivos Integrados De Medias Móviles (ARIMA)

En términos reales es más probable que la serie Y_t tenga características de AR y de MA por lo que un modelo ARMA (1,1) vendría dado por la siguiente expresión:

$$Y_t = \delta + \phi_1 Y_{t-1} + \mu_t + \theta_1 \varepsilon_{t-1}$$

Su notación general es ARMA (p, q), es decir, existen p términos autorregresivos y q términos de promedios móviles. Es importante señalar que hasta el momento se ha hecho referencia a series débilmente estacionarias, pero la realidad es que muchas series no lo son, lo relevante es que con

anterioridad se mostró que al aplicar diferencias a las series débilmente no estacionarias estas se convierten en series estacionarias. En general si a un modelo ARMA (p,q) se le aplican d diferencias para transformarlas en estacionarias se estaría ante un modelo ARIMA (p,d,q) que presenta la siguiente expresión:

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_{t-1} - \sum_{i=1}^q \theta_i \mu_{t-1} + \varepsilon_t$$

donde, d hace referencia al número de diferencias necesarias para convertir la serie en estacionaria.

Ahora bien, si la serie Y_t tiene un componente estacional se estaría ante un modelo SARIMA $(p,d,q)(P,D,Q)$ donde las letras P, D, y Q son los componentes autorregresivos, las diferencias aplicadas y las medias móviles en la parte estacional de la serie de tiempo analizada.

3.12 Metodología Box – Jenkins

El objetivo de la metodología es lograr identificar, estimar, verificar y pronosticar el mejor modelo estadístico que pueda ser interpretado como generador de la información de la muestra para predicciones. Según (Gujarati & Porter, 2009) la metodología consta de los siguientes pasos: (a) identificar el modelo, es decir, conocer los valores p , d y q apoyándose básicamente en la función de correlación simple y parcial además de los correlogramas; (b) Estimar o calcular los parámetros del modelo por lo general empleando los mínimos cuadrados simples, aunque este paso básicamente lo incluyen las rutinas de cualquier software estadístico; (c) Diagnosticar el modelo

obtenido realizando las pruebas de ajuste. Básicamente de lo que se trata esta etapa es analizar los residuos del modelo que deben tener un proceso de ruido blanco; (d) Realizar los pronósticos requeridos basado en el modelo obtenido a través de las fases anteriores, de igual manera se debe realizar una evaluación de la capacidad predictiva del modelo y realizar las conclusiones pertinentes.

3.14 Volatilidad

La volatilidad está relacionada con la velocidad del mercado, específicamente con los cambios en las cotizaciones de los activos financieros ante determinados hechos. Formalmente la volatilidad se define como *“la varianza de la serie de tiempo que se está considerando en el análisis, condicionada a la información pasada”* (Galán Figueroa, y otros, 2016). La volatilidad dependiendo del choque aleatorio generado por las noticias positivas y negativas puede ser simétrica o asimétrica, generalmente en el mercado financiero las noticias negativas tienen mayor peso que las noticias positivas generando choques aleatorios asimétricos que pueden ser capturados por un modelo exponencial generalizado (EGARCH) propuesto por (Nelson, 1991), por otro lado, los choques aleatorios simétricos se pueden capturar a través de modelos ARCH y GARCH.

3.15 Modelos ARCH y GARCH

Los modelos ARIMA requieren que su varianza condicional a sus valores pasados sea constante, para las series de tiempo de tipo financiero esta condición no necesariamente se cumple. Entre

tanto, es importante advertir que la varianza condicionada en últimas representa la incertidumbre de las predicciones y si no es constante los modelos ARIMA generarán pronósticos con serias deficiencias. Los modelos de varianza condicional heterocedástica o modelos de heterocedasticidad condicional (ARCH) suponen que la varianza condicional depende de observaciones anteriores, posteriormente (Bollerslev, 1986) generalizó dicho modelo incorporando términos de media móvil, este último modelo recibió en nombre de GARCH.

3.15.1 Modelo ARCH. Si se tiene la siguiente serie de tiempo autorregresiva AR(p):

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

donde la varianza actual depende de los rezagos de las innovaciones pasadas elevadas al cuadrado se obtiene lo siguiente:

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_p \varepsilon_{t-p}^2$$

Siendo h la varianza en el periodo t y α parámetro a estimar que deberá cumplir la siguiente restricción:

$$\alpha_0 > 0$$

$$\alpha_i \geq 0$$

$$\alpha_i > \alpha_j \text{ para } i > j$$

Esta restricción obedece a que la varianza debe ser positiva y que los sucesos más recientes tengan mayor efecto. Lo anterior garantiza además que si el término ε_{t-1}^2 es alto la varianza de la siguiente observación también lo será, por otro lado, como la media condicionada es cero es probable que aparezca un valor pequeño de ε_t^2 por lo que disminuirá la varianza condicionada de la siguiente observación (Peña, 2010, pág. 440).

3.15.2 Modelo GARCH. Como ya se mostró el modelo GARCH es una extensión del modelo ARCH en donde la varianza condicional no solamente depende de los cuadrados de las innovaciones pasadas, sino que además también depende de las varianzas condicionales de los periodos pasados, por lo tanto:

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-1}^2 + \sum_{j=1}^q \beta_j h_{t-1}$$

Con las siguientes restricciones:

$$\alpha_0 > 0$$

$$\alpha_i \geq 0$$

$$\beta_j \geq 0$$

Las restricciones al igual que el modelo ARCH obedecen a que la varianza debe ser positiva y que los sucesos más recientes deberán tener mayor efecto.

3.15.3 Identificación de efectos ARCH. Existen diversos métodos para identificar los efectos ARCH en una serie de tiempo, siempre es necesario revisar la serie de tiempo original, tratando de identificar posibles evidencias de dichos efectos. En los correlogramas se puede utilizar el estadístico de Ljung – Box al analizar los residuos del modelo, otro método propuesto por el mismo (Engle, 1982) son los multiplicadores de Lagrange, asumiendo como hipótesis nula que los coeficientes que acompañan a la varianza son iguales a cero contrastada con la hipótesis alternativa de que dichos coeficientes son distintos de cero.

4. Resultados y Discusión

4.1 Contexto

Las FAANG hacen parte del índice Standard & Poor's 500 (S&P500) que se compone por las principales 500 empresas que cotizan en la bolsa de Nueva York (Wall Street), es considerado como una representación de los sectores de la industria en los Estados Unidos y dada la correlación entre las bolsas de distintos países se considera influyente en la economía mundial. En cuanto a su desempeño durante las últimas dos décadas se destaca que ha obtenido numerosas puntuaciones máximas y mínimas, por ejemplo, en el año 2000 el índice alcanzó un récord de 1552,87 puntos justo antes de la explosión de la burbuja de Internet. Posteriormente sufrió una pérdida de más del 50% cotizando hacia el año 2001 – 2002 con 768,63 puntos (Déjà vu, 2018). Después de la crisis financiera del 2009 alcanzó un mínimo histórico de 676,53 puntos, aunque a partir del 2013 ha tenido una tendencia al alza jalonada por el sector tecnológico con leves correcciones que no han impedido alcanzar actualmente una cotización de 3000 puntos. (Figura 1).



Figura 1. Cotización diaria del índice S&P500 para el periodo mayo 2014 – mayo 2019. Adaptado de: YAHOO FINANZAS. (2019). Datos históricos del índice S&P500. Recuperado de: <https://es.finance.yahoo.com/quote/%5EGSPC/history?p=%5EGSPC>

Otra característica es que el S&P 500 está conformado por sectores cuyo porcentaje de participación en éste ha cambiado con el transcurrir del tiempo. La Tabla 1 muestra desde el año 1990 hasta la actualidad el ranking de los sectores en porcentaje de participación de acuerdo con el volumen de su capital bursátil, en la tabla se destaca la dinámica creciente del sector tecnológico que pasó de ser el penúltimo en participación con un 6,34% a ser el líder de los sectores con una participación actual del 19,9%.

Tabla 1

Participación porcentual en el índice S&P500 por sectores

SECTOR	1990	1995	2000	2002	2006	2008	2009	2015	2018
Tecnología	6,34	9,39	21,23	14,63	15,14	15,40	17,84	20,69	26,06
Financiera	7,39	13,14	17,34	20,46	22,27	12,97	8,58	16,47	16,90
Sanitaria	10,28	10,82	14,36	14,77	12,03	14,92	16,11	15,16	14,04
Consumo	13,00	12,97	10,28	13,26	10,62	8,39	8,31	12,89	13,06
Industria	13,70	12,63	10,57	11,50	10,84	11,06	9,46	10,05	9,93
Consumo básico	13,86	12,80	8,10	9,48	9,25	13,06	13,90	10,06	6,72
Energética	13,32	9,14	6,57	5,99	9,82	13,14	14,05	6,50	6,18
Materiales	7,20	6,05	2,30	2,82	2,96	2,97	3,18	2,76	2,65
Serv. Púb.	6,19	4,53	3,79	2,84	3,55	4,20	4,43	2,99	2,64
Telecomunicaciones	8,72	8,53	5,46	4,25	3,51	3,88	4,14	2,43	1,82

Nota: Adaptado de “Así ha cambiado el peso industrial del S&P500 en los últimos años”, de González R. 13 de junio, 2018. Recuperado de: <http://losmercadosfinancieros.es/asi-ha-cambiado-el-peso-industrial-del-sp-500-en-los-ultimos-anos.html>

Frente al retorno de las acciones en los últimos 5 años, el sector tecnológico es el más importante con resultados por encima del 100% a pesar de que no escapó a los retrocesos del mercado en los últimos meses del 2018 motivados tal vez por hechos concretos desencadenados por la “guerra comercial” entre Estados Unidos y China, al respecto la revista Dinero (REVISTA DINERO, 2019) muestra que el 8 de marzo del 2018 Estados Unidos anunció un incremento del 25% en los aranceles del acero y el aluminio, el 22 de marzo China les aplicó aranceles adicionales a 128 productos estadounidenses, el 3 de abril empezaron los ataques al sector tecnológico y en julio se empezó hablar de guerra comercial declarada. Sin embargo, para inicios del 2019 el sector de la

tecnología se ha reestructurado al alza con máximos históricos en mayo, coincidiendo con el veto a la empresa china HUAWEI.



Figura 2. Retornos diarios de los distintos sectores que conforman el índice S&P500 en los últimos

5 años. SECTOR SPDR ETFS. (2019). *Sector Tracker*. Recuperado de:

<https://www.sectorspdr.com/sectorspdr/tools/sector-tracker>

4.1.1 Las FAANG. Las FAANG hicieron su arribo en el NASDAQ en periodos distintos, la empresa Facebook es la que menos tiempo lleva cotizando en bolsa ya que su ingreso se presentó en mayo del 2012, por su parte Amazon incursionó en el año de 1997, Apple es la empresa más antigua cotizando en bolsa ingresando en diciembre de 1980, Netflix ingresó en 2002 y la empresa Google en agosto del 2004.

Las FAANG hacen parte del sector tecnológico del índice S&P500, este sector es considerado el más importante por su dinámica, rentabilidad en los últimos años y capital bursátil. Frente al capital bursátil de las FAANG de acuerdo con cifras entregadas por el portal de internet FINVIZ, en conjunto sumaban aproximadamente 3,3 billones de dólares.

Tabla 2

Capital bursátil de las FAANG

EMPRESA	CAPITAL BURSÁTIL (miles de millones de Dólares)
Apple Inc	918,94
Amazon.Com Inc	902,73
Alphabet Inc	824,96
Facebook	538,59
Netflix Inc	133,51
TOTAL	3318,73

Nota: Adaptado de “Screener Index S&P 500”. 13 de julio, 2019. Recuperado de: https://finviz.com/screener.ashx?v=111&f=idx_sp500

Este capital bursátil está por encima del PIB de países desarrollados, para ser más exactos en el hipotético caso de que las FAANG fueran un país serían la quinta economía mundial. De acuerdo con las cifras del Banco Mundial solamente países como Estados Unidos, China, Japón y Alemania tendrían un PIB en el 2018 por encima del capital bursátil de las FAANG.

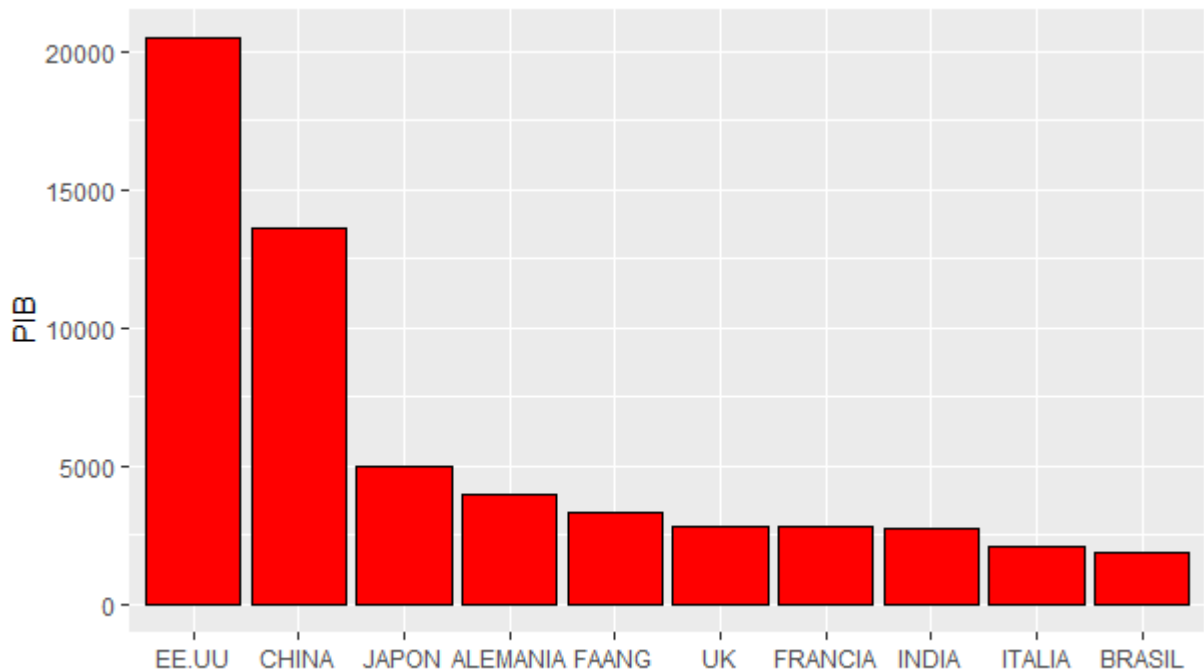


Figura 3. Ranking de países por PIB frente al capital bursátil de las FAANG.

Frente al retorno de las acciones de las FAANG en los últimos 4 años la acción menos rentable ha sido la de GOOGLE (Alphabet) con un 100%, mientras que la de mayor retorno ha sido la de NETFLIX pues pasó de cotizar por cada acción 45,79 dólares en el 2014 a los 378,67 dólares por acción en mayo del 2019, es decir, presenta una rentabilidad por encima del 600%. (Figura 4).




Figura 4. Retornos diarios de las FAANG para el periodo mayo 2014 – mayo 2019. Adaptado de: YAHOO FINANZAS. (2019). *Datos históricos del índice S&P500*. Recuperado de: <https://es.finance.yahoo.com/quote/%5EGSPC/history?p=%5EGSPC>

Ahora bien, estos comportamientos financieros generan todo tipo de especulaciones, ya que el sector tecnológico tiene un gran potencial de crecimiento pues todavía faltan por explotar aspectos como computación en la nube, redes sociales, comercio, inteligencia artificial, bigdata, entre otros, por el contrario, se puede estar ante una burbuja tecnológica con otro problema: el componente proteccionista, que se enmarca en la “guerra comercial” entre los Estados Unidos y China con la posibilidad de llegar a reconfigurar los mercados, haciendo que la incertidumbre se apropie del sector pues precisamente esta guerra está involucrando a las FAANG en un juego geopolítico con consecuencias imprevisibles en los mercados mundiales.

4.2 Descripción de la Muestra

La muestra se compone por la cotización diaria de la acción de cada una de las empresas FAANG expresadas en unidades de dólar (US\$) que cotizan en la bolsa de valores National Association of Securities Dealers Automated Quotation (NASDAQ) para un periodo de entrenamiento de 5 años (1258 cotizaciones) y un periodo de validación de aproximadamente 4 meses (82 cotizaciones). El periodo de entrenamiento incluye los hechos claves de la guerra comercial entre Estados Unidos y China además inicia en un momento donde todas las empresas FAANG presentan una clara tendencia al alza lo que garantiza hasta cierto punto uniformidad en el análisis. La tabla 3 muestra un resumen con las principales características de la muestra.

Tabla 3

Características de la muestra

	MUESTRA
Procedencia	Estados Unidos
Bolsa de valores	NASDAQ
Cotización	Acción en unidades de dólar (US\$)
Periodo	5 años
Frecuencia Anual	252
Periodo entrenamiento	7 de mayo del 2014 hasta el 6 de mayo del 2019
Total datos de entrenamiento	1258
Periodo validación	7 de mayo del 2019 hasta el 30 de agosto del 2019
Total datos para validar	82

4.3 Análisis Descriptivo y Clásico de las Series de Tiempo FAANG

4.3.1 Facebook

4.3.1.1 Análisis descriptivo y contextual. La figura 5 muestra la serie de la cotización de las acciones de la empresa Facebook perteneciente al periodo de entrenamiento.




Figura 5. Cotización diaria de las acciones de Facebook y eventos claves de la guerra comercial entre Estados Unidos y China. Adaptado de: YAHOO FINANZAS. (2019). *Datos históricos de Facebook*. Recuperado de: <https://es.finance.yahoo.com/quote/FB/history?p=FB>

De acuerdo con la figura 5 las acciones de Facebook muestran una clara tendencia al alza alcanzando el pico más alto (US\$ 217,5 por acción) en el mes de julio del 2018, a partir de ese punto máximo la cotización empezó a decaer mostrando signos de recuperación en los inicios del 2019. Las líneas rojas representan una serie de noticias importantes en torno a la guerra comercial entre Estados Unidos y China, precisamente la caída en el valor de las acciones corresponde a la aplicación de aranceles por parte de Estados Unidos a las importaciones chinas por un valor de US\$34.000 millones, la respuesta de Pekín fue simétrica. En los siguientes meses la confrontación se agudizó con nuevos aranceles de parte y parte hasta que los presidentes de ambos países decidieron en diciembre reunirse para pactar un acuerdo, precisamente un tiempo después de dicha reunión las acciones de Facebook comenzaron la cotización al alza.

En términos descriptivos existe una clara tendencia al alza donde se aprecia que la media cambia con el tiempo en consecuencia la serie no es estacionaria, no se aprecia un componente cíclico ni estacional, de igual manera parece ser que la serie no presenta heterocedasticidad.

4.3.1.2 Componentes. La figura 6 muestra los componentes de la serie de tiempo de la cotización de las acciones de Facebook.




Figura 6. Componentes de la serie de las cotizaciones de las acciones de Facebook

Como se definió previamente la serie presenta una tendencia creciente hasta alcanzar su punto máximo, punto en el cual la tendencia empieza a decaer, de igual manera se identifica un componente estacional donde al inicio de cada año la cotización de la acción de Facebook presenta un aumento en su valor hasta mitad de año, punto en el cual la cotización muestra un descenso en su valor. Por último, el componente aleatorio hasta mitad del año 2018 presentó valores en torno a cero, pero después los valores del componente aleatorio cambiaron su comportamiento motivado tal vez por los efectos de la guerra económica entre Estados Unidos y China.

Frente al tipo de descomposición, la serie se asemeja a un modelo aditivo ya que la magnitud de las fluctuaciones estacionales no varía al hacerlo la tendencia, en consecuencia, la serie asume los valores de acuerdo con la suma de sus componentes.

4.3.1.3 Suavizamiento exponencial: Holt-Winters. La serie de tiempo de la cotización de las acciones de Facebook presenta tendencia y estacionalidad por lo que se recomienda la suavización exponencial Holt – Winters con sus respectivos parámetros. La predicción con este método se realizó con un intervalo de confianza del 95%, los parámetros Alfa, Beta y Gamma fueron estimados por el programa estadístico R versión 3.6.1 y se tomaron 30 días para pronosticar. La figura 7 muestra los resultados:




Figura 7. Pronóstico de la cotización de las acciones de Facebook.

Dado que las fluctuaciones causadas por el componente estacional se incorporan en la tendencia hace que esta última presente un mejor ajuste. El comportamiento del pronóstico muestra que la cotización permanecerá estable en los siguientes 30 días.

4.3.2 Amazon

4.3.2.1 Análisis descriptivo y contextual. La figura 8 muestra la serie de la cotización de las acciones de la empresa Amazon perteneciente al periodo de entrenamiento.



Figura 8. Cotización diaria de las acciones de Amazon y eventos claves de la guerra comercial entre Estados Unidos y China. Adaptado de: YAHOO FINANZAS. (2019). *Datos históricos de Amazon*. Recuperado de: <https://es.finance.yahoo.com/quote/AMZN/history?p=AMZN>

La figura 8 muestra que la cotización de las acciones de Amazon presenta una clara tendencia al alza alcanzando el pico más alto (US\$ 2039,5 por acción) en el mes de septiembre del 2018, a partir de ese punto máximo la cotización se mantuvo hasta diciembre y empezó a decaer hasta fin de año. Para principios del 2019 mostró caídas y recuperaciones hasta que su cotización alcanzó un valor similar de principios del 2018, a partir de esa caída la cotización de la acción empezó su recuperación. Respecto a la posible influencia de la guerra comercial entre Estados Unidos y China en el valor de la cotización, se debe recordar que en abril del 2018 hubo amenazas mutuas sobre la imposición de aranceles lo que tal vez desencadenó una caída en el valor de las acciones, sin embargo, a pesar de agudizarse la “guerra comercial” las acciones mostraron una clara recuperación hasta diciembre, mes en el cual los presidentes de ambas naciones decidieron implementar una tregua coincidiendo con la caída en su cotización.

En términos descriptivos existe una clara tendencia al alza con una caída coyuntural, en consecuencia, la media cambia con el tiempo y la serie se puede definir como no estacionaria, por otro lado, no se aprecia un componente cíclico ni estacional pero posiblemente presencia de heterocedasticidad a partir del año 2018.

4.3.2.2 Componentes. La figura 9 muestra los componentes de la serie de tiempo de la cotización de las acciones de Amazon.




Figura 9. Componentes de la serie de las cotizaciones de las acciones de Amazon

Las acciones de Amazon muestran una tendencia no tan pronunciada al alza incluso su caída en diciembre pasa desapercibida, de igual manera se identifica un componente estacional donde al inicio de cada año la cotización de la acción de viene en caída y se recupera cada inicio de año hasta el tercer trimestre donde se presentan caídas en su valor. Por último, el componente aleatorio hasta inicios del año 2018 presentó valores en torno a cero (excepto en el 2016), pero después los valores del componente aleatorio cambiaron su comportamiento motivado tal vez por los efectos de la guerra económica entre Estados Unidos y China.

Frente al tipo de descomposición, la serie se asemeja a un modelo aditivo ya que la magnitud de las fluctuaciones estacionales no varía al hacerlo la tendencia, en consecuencia, la serie asume los valores de acuerdo con la suma de sus componentes.

4.3.2.3 Suavizamiento exponencial: Holt-Winters. La serie de tiempo de la cotización de las acciones de Amazon presenta tendencia y estacionalidad por lo que se recomienda la suavización exponencial Holt – Winters con sus respectivos parámetros. La predicción con este método se realizó con un intervalo de confianza del 95%, los parámetros Alfa, Beta y Gamma fueron estimados por el programa estadístico R 3.6.1 y se tomaron 30 días para pronosticar. La figura 10 muestra los resultados:



Figura 10. Pronóstico de la cotización de las acciones de Amazon

En este caso a pesar de que las fluctuaciones causadas por el componente estacional que se incorporan en la tendencia parece que la predicción no sigue el comportamiento de la tendencia. En conclusión, la cotización de las acciones de Amazon según la predicción se estabilizará.

4.3.3 Apple

4.3.3.1 Análisis descriptivo y contextual. La figura 11 muestra la serie de la cotización de las acciones de la empresa Apple perteneciente al periodo de entrenamiento.



Figura 11. Cotización diaria de las acciones de Apple y eventos claves de la guerra comercial entre Estados Unidos y China. Adaptado de: YAHOO FINANZAS. (2019). *Datos históricos de Apple.*

Recuperado de: <https://es.finance.yahoo.com/quote/AAPL/history?p=AAPL>

Las acciones de Apple muestran una tendencia al alza que alcanzó el pico más alto (US\$ 230,28 por acción) en el mes de diciembre del 2018, a partir de ese punto máximo la cotización empezó a decaer mostrando signos de recuperación en los inicios del 2019. El valor de las acciones de Apple en los inicios de la guerra comercial presentó comportamientos al parecer reactivos de acuerdo con los acontecimientos, ahora bien, después de declarada la guerra comercial el valor de las acciones de Apple tuvo una tendencia al alza hasta diciembre del 2018 cuando se pactó una tregua entre los presidentes de China y Estados Unidos.

En cuanto a la descripción de la serie se aprecia que la media cambia con el tiempo mostrando que no es estacionaria, puede que exista un componente cíclico que comprende los periodos de mediados del 2014 hasta mitad del 2016, otro posible ciclo va desde mitad del 2016 hasta diciembre del 2018. Finalmente, se aprecia un componente estacional con la posible presencia de heterocedasticidad.

4.3.3.2 Componentes. La figura 12 muestra los componentes de la serie de tiempo de la cotización de las acciones de Apple.




Figura 12. Componentes de la serie de las cotizaciones de las acciones de Apple

Las acciones de Apple muestran una tendencia al parecer cíclica, de igual manera se identifica un componente estacional donde al inicio de cada año la cotización de la acción de Apple viene en caída y se recupera cada inicio de año hasta el tercer trimestre donde se presentan caídas en su valor. Por último, el componente aleatorio hasta inicios del año 2018 presentó valores en torno a cero, pero después los valores del componente aleatorio cambiaron su comportamiento.

Frente al tipo de descomposición, la serie se asemeja a un modelo aditivo ya que la magnitud de las fluctuaciones estacionales no varía al hacerlo la tendencia, en consecuencia, la serie asume los valores de acuerdo con la suma de sus componentes.

4.3.3.3 Suavizamiento exponencial: Holt-Winters. La serie de tiempo de la cotización de las acciones de Apple presenta tendencia y estacionalidad por lo que se recomienda la suavización exponencial Holt – Winters con sus respectivos parámetros. La predicción con este método se realizó con un intervalo de confianza del 95%, los parámetros Alfa, Beta y Gamma fueron estimados por el programa estadístico R y se tomaron 30 días para pronosticar. La figura 13 muestra los resultados:



Figura 13. Pronóstico de la cotización de las acciones de Apple

Las fluctuaciones causadas por el componente estacional se incorporan en la tendencia hace que esta última presente un mejor ajuste. El comportamiento del pronóstico muestra que la tendencia si bien siguió al alza su pendiente difiere levemente de la tendencia basada en los datos reales, en consecuencia, se puede concluir que el valor de las acciones de Apple continúa al alza.

4.3.4 Netflix

4.3.4.1 Análisis descriptivo y contextual. La figura 14 muestra la serie de la cotización de las acciones de la empresa Netflix perteneciente al periodo de entrenamiento.



Figura 14. Cotización diaria de las acciones de Netflix y eventos claves de la guerra comercial entre Estados Unidos y China. Adaptado de: YAHOO FINANZAS. (2019). *Datos históricos de Netflix.* Recuperado de: <https://es.finance.yahoo.com/quote/NFLX/history?p=NFLX>

Las acciones de Netflix muestran una tendencia al alza que alcanzó el pico más alto (US\$ 418,97 por acción) a finales del mes de agosto del 2018, a partir de ese punto máximo la cotización empezó a caer hasta finales del mes de septiembre donde nuevamente se mantiene al alza hasta

diciembre en donde se registra una caída de su cotización hasta principios del año 2019, a partir de ese último instante comienza nuevamente la acción a aumentar su valor. Respecto a la guerra comercial el valor de las acciones de Netflix no tuvo inconvenientes, pero a partir de la intensificación del conflicto comercial cuando ambas naciones se impusieron mutuamente aranceles por un valor de US\$16.000 millones su valor tuvo un descenso, aunque dicha tendencia entra en contradicción por los eventos sucedidos a finales de septiembre en donde Estados Unidos impuso a China aranceles por US\$200.000 millones mientras que China le impuso a su rival US\$60.000 millones en aranceles, pese a esta agudización del conflicto comercial las acciones de Netflix volvieron al alza hasta diciembre cuando ambas naciones decidieron acordar una tregua.

En términos descriptivos existe una clara tendencia al alza con una caída coyuntural, en consecuencia, la media cambia con el tiempo y la serie se puede definir como no estacionaria, por otro lado, no se aprecia un componente cíclico ni estacional, aunque parece ser que la serie presenta heterocedasticidad en sus últimos periodos.

4.3.4.2 Componentes. La figura 15 muestra los componentes de la serie de tiempo de la cotización de las acciones de Netflix.

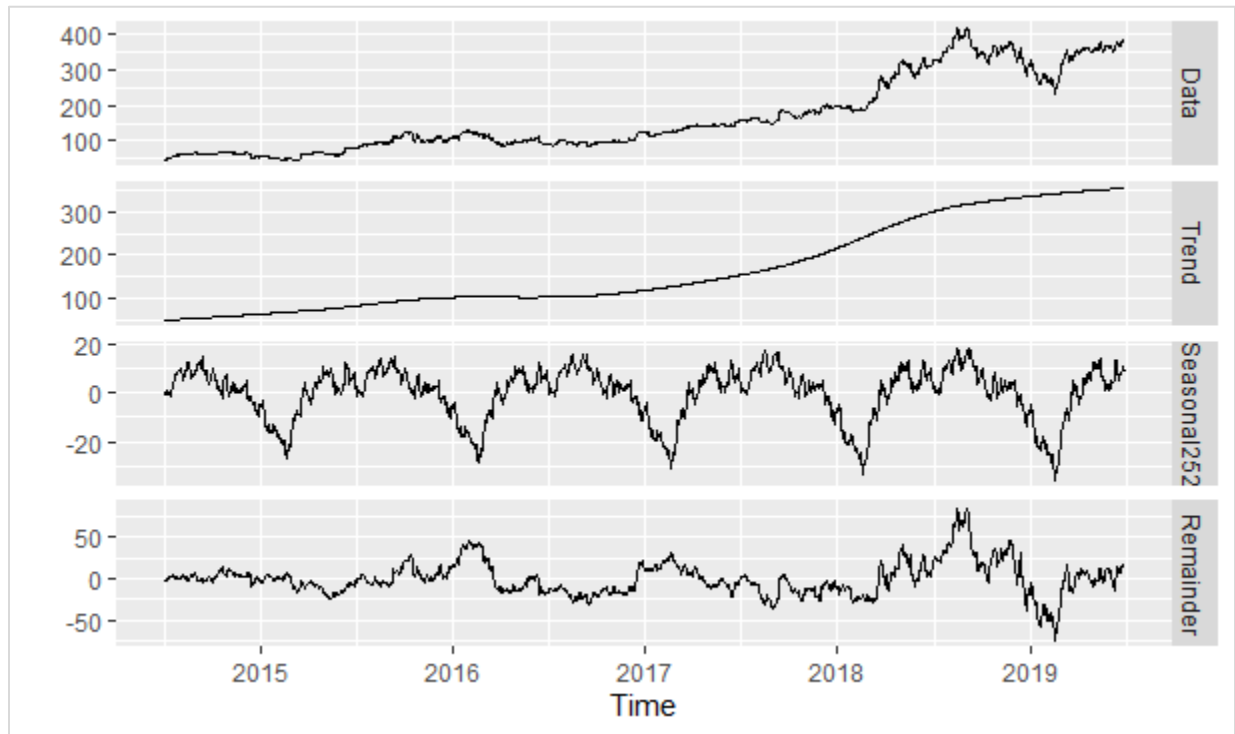


Figura 15. Componentes de la serie de las cotizaciones de las acciones de Netflix

Las acciones de Netflix muestran una tendencia no tan pronunciada al alza, de igual manera se identifica un componente estacional donde al final de cada año la cotización de la acción de Netflix viene en caída y se recupera cada inicio de año hasta el primer trimestre donde se mantiene hasta el final del tercer trimestre. Por último, el componente aleatorio se caracteriza por tener periodos irregulares, este comportamiento se agudiza en los inicios del año 2018 manteniéndose por un periodo de un año.

Frente al tipo de descomposición, la serie se asemeja a un modelo aditivo ya que la magnitud de las fluctuaciones estacionales no varía al hacerlo la tendencia, en consecuencia, la serie asume los valores de acuerdo con la suma de sus componentes.

4.3.4.3 Suavizamiento exponencial: Holt-Winters. La serie de tiempo de la cotización de las acciones de Netflix presenta tendencia y estacionalidad por lo que se recomienda la suavización exponencial Holt – Winters con sus respectivos parámetros. La predicción con este método se realizó con un intervalo de confianza del 95%, los parámetros Alfa, Beta y Gamma fueron estimados por el programa estadístico R y se tomaron 30 días para pronosticar. La figura 16 muestra los resultados:




Figura 16. Pronóstico de la cotización de las acciones de Netflix

En este caso a pesar de que las fluctuaciones causadas por el componente estacional se incorporan en la tendencia parece que la predicción no sigue el comportamiento de la tendencia. En conclusión, la cotización de las acciones de Netflix según la predicción en los próximo 30 días será estable.

4.3.5 Google

4.3.5.1 Análisis descriptivo y contextual. La figura 17 muestra la serie de la cotización de las acciones de la empresa Google perteneciente al periodo de entrenamiento.



Figura 17. Cotización diaria de las acciones de Google y eventos claves de la guerra comercial entre Estados Unidos y China. Adaptado de: YAHOO FINANZAS. (2019). *Datos históricos de Google*. Recuperado de: <https://es.finance.yahoo.com/quote/GOOG/history?p=GOOG>

Las acciones de Google muestran una tendencia al alza desde mediados del año 2015 alcanzando el pico más alto (US\$ 1296,2 por acción) en el mes de abril del 2019, aunque para finales del mes de agosto de 2018 alcanzó hasta el momento la mejor cotización, en este punto su

cotización empezó a caer hasta principios del año 2019. Al iniciar la guerra comercial entre China y Estados Unidos hasta el mes de julio la tendencia tuvo un comportamiento irregular, para esta fecha se empezó hablar de guerra comercial abierta y el valor de las acciones empezaron a una tendencia al alza hasta finales del mes de agosto cuando empezó la escalada de imposición de aranceles por cada una de las partes en conflicto. Una vez ambas naciones acordaron una tregua en diciembre del 2018 las acciones retomaron el alza a principios del siguiente año.

En términos descriptivos existe una clara tendencia al alza donde se aprecia que la media cambia con el tiempo en consecuencia la serie no es estacionaria, no se aprecia un componente cíclico ni estacional claramente, de igual manera parece ser que la serie presenta en periodos puntuales heterocedasticidad.

4.3.5.2 Componentes. La figura 18 muestra los componentes de la serie de tiempo de la cotización de las acciones de Google.




Figura 18. Componentes de la serie de las cotizaciones de las acciones de Google

Las acciones de Google muestran una tendencia estable en sus extremos, de igual manera se identifica un componente estacional marcado por múltiples irregularidades, mientras que el componente aleatorio se caracteriza por presentar irregularidad en todo el periodo de análisis.

Frente al tipo de descomposición, la serie se asemeja a un modelo aditivo ya que la magnitud de las fluctuaciones estacionales no varía al hacerlo la tendencia, en consecuencia, la serie asume los valores de acuerdo con la suma de sus componentes.

4.3.5.3 Suavizamiento exponencial: Holt-Winters. La serie de tiempo de la cotización de las acciones de Google presenta tendencia y estacionalidad por lo que se recomienda la suavización exponencial Holt – Winters con sus respectivos parámetros. La predicción con este método se realizó con un intervalo de confianza del 95%, los parámetros Alfa, Beta y Gamma fueron estimados por el programa estadístico R y se tomaron 30 días para pronosticar. La figura 19 muestra los resultados:




Figura 19. Pronóstico de la cotización de las acciones de Google

En este caso a pesar de que las fluctuaciones causadas por el componente estacional se incorporan en la tendencia la predicción no sigue el comportamiento de la tendencia. En el último instante se presentó una baja en la cotización y la predicción mantiene un precio estable. En

conclusión, la cotización de las acciones de Google según la predicción en los próximos 30 días será estable.

4.4 Modelos ARIMA

Antes de implementar la metodología Box – Jenkins para cada una de las series de las acciones FAANG es importante estabilizar sus varianzas y aplicar las diferencias necesarias para convertirlas en estacionarias. El objetivo es encontrar el modelo ARIMA que mejor ajuste, previamente se ha mostrado que las series pertenecientes a las empresas FAANG no son estacionarias ni en media ni en varianza, si a cada una de las series se les transforma mediante el logaritmo neperiano y además se les aplica una diferencia se obtiene una serie estacionaria que coincide con los retornos logarítmicos de las acciones de cualquier activo financiero, en adelante los análisis se basaron en la serie de los retornos logarítmicos de las acciones del fondo FAANG.

4.4.1 Transformación de las Series de Tiempo de la Cotizaciones de las Acciones de las FAANG

4.4.1.1 Facebook. Al realizar la transformación Box – Cox se estimó un valor lambda de: 0,0095, por lo que se recomienda transformar la serie original aplicando el logaritmo natural. Antes de aplicar la diferencia respectiva a la serie transformada es importante echar un vistazo a los correlogramas derivados de las funciones de correlación simple (FAC) y correlación parcial (FACP).




Figura 20. Función de autocorrelación simple y parcial para la serie logarítmica de Facebook

El gráfico superior de la figura 20 muestra la serie del valor de las acciones de Facebook transformadas por el logaritmo natural. Abajo a la izquierda el correlograma de FAC que decrece lenta y linealmente hasta el rezago 400 que se supone es estadísticamente diferente de cero y abajo a la derecha el correlograma de FACP después del primer rezago se encontró un único valor significativo muy cercana a la observación 200. Dada las características presentadas por los correlogramas se puede concluir que la serie es no estacionaria por lo que es necesario diferenciarla. Para este caso al aplicar la primera diferencia y realizarle la prueba Dickey – Fuller se obtuvo que con un valor de significancia del 5% se rechaza la hipótesis nula de que la serie del valor de las acciones de Facebook transformada por logaritmo natural y con una diferencia aplicada (serie de retornos) sea *no estacionaria* ya que el valor P obtenido es de 0,01. La figura 21 muestra

la gráfica del logaritmo de la serie del valor de las acciones de Facebook que al aplicarle la primera diferencia se convierte automáticamente en la serie de los retornos de sus acciones:




Figura 21. Retornos de las acciones de Facebook

La serie de la figura 21 muestra que la media converge en cero mostrando estacionariedad en media, en términos generales no se detectan clúster de varianza, aunque la volatilidad a partir del año 2018 se torna más inestable, lo que sugiere que las decisiones tomadas en el marco de la guerra comercial están afectando los retornos de las acciones de la empresa Facebook.

4.4.1.2 Amazon. La transformación Box – Cox para el caso de la empresa Amazon se estimó en un valor lambda de: 0,05914314, se recomienda transformar la serie original aplicando el logaritmo natural. Es importante antes de aplicar las diferencias respectivas a la serie transformada echar un vistazo a los correlogramas FAC y FACP.




Figura 22. Función de autocorrelación simple y parcial para la serie logarítmica de Amazon

La figura 22 muestra en la parte superior la serie del valor de las acciones de Amazon transformadas por el logaritmo natural. Abajo a la izquierda el correlograma de FAC que decrece lenta y linealmente hasta el rezago 400 (similar al FAC de la empresa Facebook) que se supone es estadísticamente diferente de cero y abajo a la derecha el correlograma de FACP después del primer rezago no se encontró otro valor significativo. Dada las características presentadas por los correlogramas se puede concluir que la serie es no estacionaria por lo que es necesario

diferenciarla. Para este caso al aplicar la primera diferencia y realizarle la prueba Dickey – Fuller se obtuvo que con un valor de significancia del 5% se rechaza la hipótesis nula de que la serie del valor de las acciones de Amazon transformada por logaritmo natural y con una diferencia aplicada (serie de retornos) sea *no estacionaria* ya que el valor P obtenido de 0,01 es menor a la significancia asignada. La figura 23 muestra la gráfica del logaritmo de la serie del valor de las acciones de Amazon que al aplicarle la primera diferencia se convierte automáticamente en la serie de los retornos de sus acciones:




Figura 23. Retornos de las acciones de Amazon

La serie de los retornos de las acciones de Amazon mostrada en la figura 23 presenta estacionariedad en media que converge en cero, sin embargo, se detectan clúster de volatilidad, lo

que hace que el retorno de las acciones de Amazon sea sensible ante eventos de intervención. Una posible intervención se deduce de la guerra comercial entre Estados Unidos y China ya que a partir del 2018 la volatilidad se hace más fuerte lo que sugiere cierta sensibilidad de los retornos frente a las acciones que están tomando los dos países.

4.4.1.3 Apple. La transformación Box – Cox para el caso de la empresa Apple se estimó en un valor lambda de 0,3233149, en este caso la transformación recomendada puede ser la raíz cuadrada o el logaritmo natural, por conveniencia se transformó la serie original aplicando el logaritmo natural. Posterior a la transformación de la serie con el fin de estabilizar la varianza se deberá eliminar la tendencia aplicando las diferencias respectivas, pero antes es importante echar un vistazo a los correlogramas FAC y FACP.




Figura 24. Función de autocorrelación simple y parcial para la serie logarítmica de Apple

La figura 24 muestra en la parte superior la serie del valor de las acciones de Apple transformadas por el logaritmo natural. Abajo a la izquierda el correlograma de FAC que decrece lenta y linealmente hasta el rezago 400 (similar al FAC de la empresa Facebook y Amazon) que se supone es estadísticamente diferente de cero y abajo a la derecha el correlograma de FACP después del primer rezago no se encontró otro valor significativo. Dada las características presentadas por los correlogramas se puede concluir que la serie es no estacionaria por lo que es necesario diferenciarla. Para este caso al aplicar la primera diferencia y realizarle la prueba Dickey – Fuller se obtuvo que con un valor de significancia del 5% se rechaza la hipótesis nula de que la serie del valor de las acciones de Apple transformada por logaritmo natural y con una diferencia aplicada (serie de retornos) sea no estacionaria ya que el valor P obtenido de 0,01 es menor a la significancia asignada. La figura 25 muestra la gráfica del logaritmo de la serie del valor de las acciones de Apple que al aplicarle la primera diferencia se convierte automáticamente en la serie de los retornos de sus acciones.




Figura 25. Retornos de las acciones de Apple

La serie de retornos de las acciones de Apple mostrada en la figura 25 presenta estacionariedad en media que converge en cero, sin embargo, posee múltiples clúster de volatilidad lo que sugiere que la cotización de la acción está expuesta a la intervención, evidentemente a partir del año 2018 la volatilidad se hace más notoria hacia eventos negativos, por lo que se sugiere que la guerra comercial o las decisiones en torno a esta están afectando de forma significativa los retornos de las acciones de Apple.

4.4.1.4 Netflix. Sobre la transformación Box – Cox para el caso de la empresa Netflix se estimó en un valor lambda de $-0,2511296$ en este caso la transformación recomendada puede ser elevar la serie a una potencia racional negativa o el logaritmo natural, por conveniencia se transformó la serie original aplicando el logaritmo natural. Posterior a la transformación de la serie con el fin de estabilizar la varianza se deberá eliminar la tendencia aplicando las diferencias respectivas, pero antes es importante echar un vistazo a los correlogramas FAC y FACP.

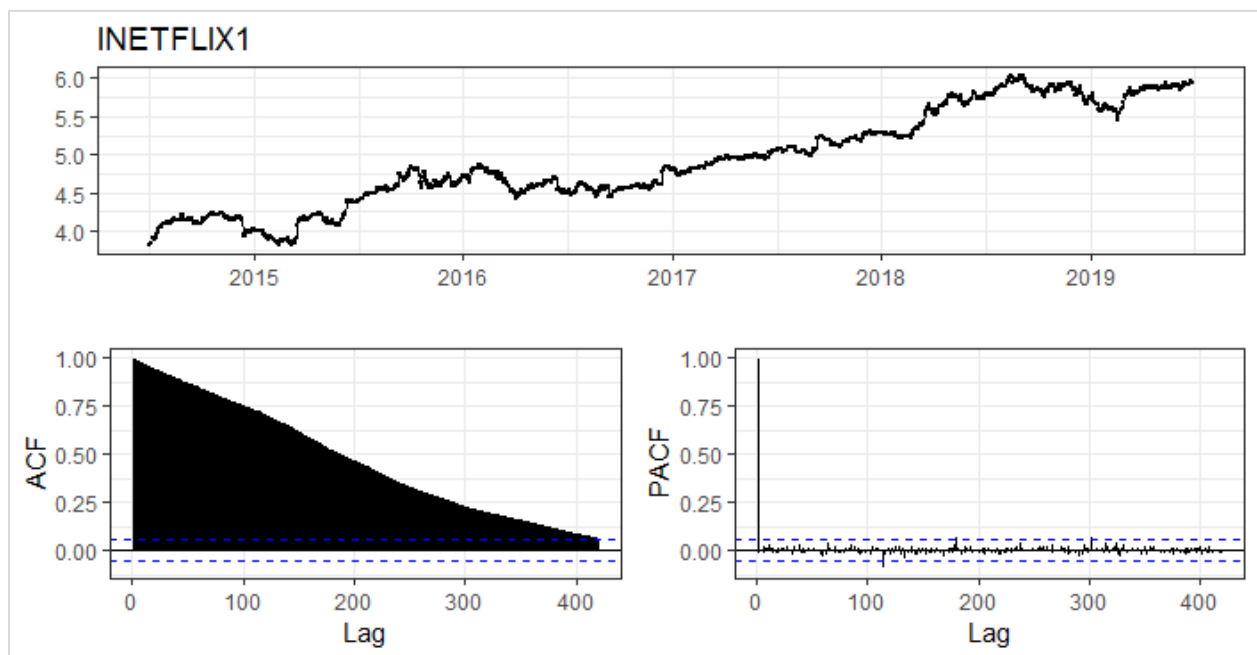


Figura 26. Función de autocorrelación simple y parcial para la serie logarítmica de Netflix

La figura 26 muestra en la parte superior la serie del valor de las acciones de Netflix transformadas por el logaritmo natural. Abajo a la izquierda el correlograma de FAC que decrece lenta y linealmente hasta el rezago 400 (similar al FAC de la empresa Apple) que se supone es estadísticamente diferente de cero y abajo a la derecha el correlograma de FACP después del

primer rezago se encontraron tres rezagos significativos. Dada las características presentadas por los correlogramas se puede concluir que la serie es no estacionaria por lo que es necesario diferenciarla. Para este caso al aplicar la primera diferencia y realizarle la prueba Dickey – Fuller se obtuvo que con un valor de significancia del 5% se rechaza la hipótesis nula de que la serie del valor de las acciones de Netflix transformada por logaritmo natural y con una diferencia aplicada (serie de retornos) sea *no estacionaria* ya que el valor P obtenido de 0,01 es menor a la significancia asignada. La figura 27 muestra la gráfica del logaritmo de la serie del valor de las acciones de Netflix que al aplicarle la primera diferencia se convierte automáticamente en la serie de los retornos de sus acciones:




Figura 27. Retornos de las acciones de Netflix

La serie de los retornos de las acciones de Netflix mostrada en la figura 27 es estacionaria en media que converge en cero y presenta múltiples valores que se pueden considerar atípicos. Otro aspecto importante es que la serie presenta clúster de volatilidad especialmente a partir del año 2018 pero se debe advertir que la volatilidad no es tan marcada como la cotización de las acciones de Amazon y Apple.

4.4.1.5 Google. La transformación Box – Cox para el caso de la empresa Google se estimó en un valor lambda de: 1,136386, se recomienda transformar la serie original elevándola al cuadrado, sin embargo, para efectos del estudio se aplicó el logaritmo neperiano. Es importante antes de aplicar las diferencias respectivas a la serie transformada echar un vistazo a los correlogramas FAC y FACP.

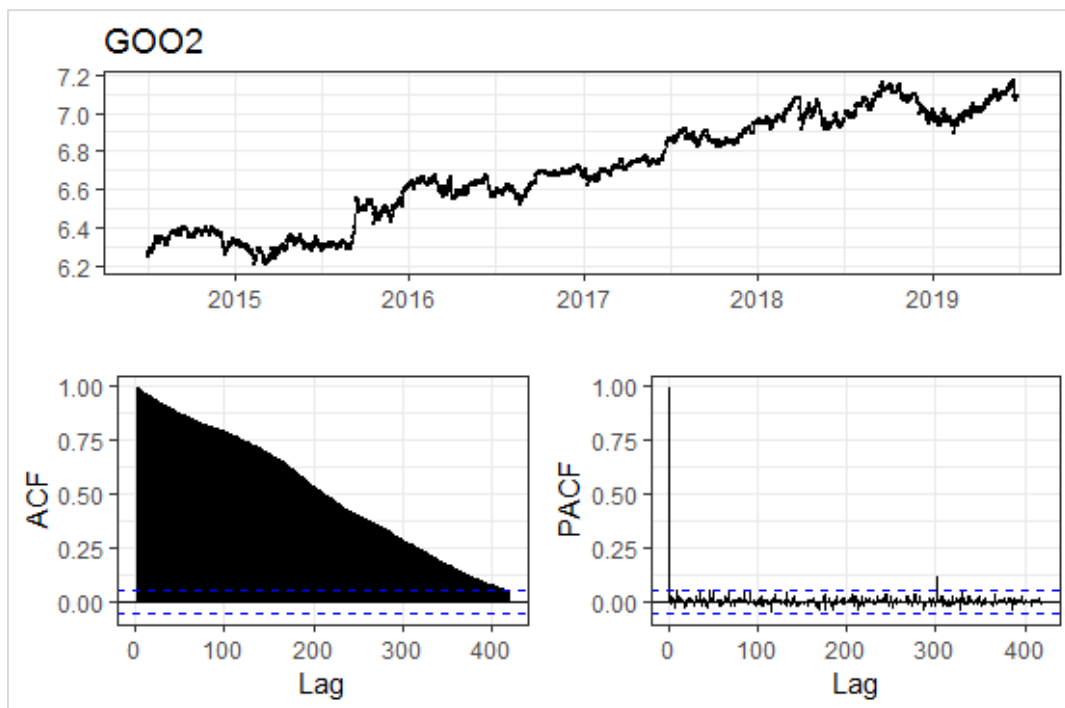


Figura 28. Función de autocorrelación simple y parcial para la serie logarítmica de Google

La figura 28 muestra en la parte superior la serie del valor de las acciones de Google transformadas elevándolas al cuadrado. Abajo a la izquierda el correlograma de FAC que decrece de forma levemente senoidal hasta el rezago 400 que se supone es estadísticamente diferente de cero y abajo a la derecha el correlograma de FACP después del primer rezago se encontraron varios de estos en el límite de las bandas de significancia. Dada las características presentadas por los correlogramas se puede concluir que la serie es no estacionaria por lo que es necesario diferenciarla. Para este caso al aplicar la primera diferencia y realizarle la prueba Dickey – Fuller se obtuvo que con un valor de significancia del 5% se rechaza la hipótesis nula de que la serie del valor de las acciones de Google transformada por la potencia al cuadrado y con una diferencia aplicada (serie de retornos) sea *no estacionaria* ya que el valor P obtenido de 0,01 es menor a la significancia asignada. La figura 29 muestra la gráfica del logaritmo de la serie del valor de las acciones Google que al aplicarle la primera diferencia se convierte automáticamente en la serie de los retornos de sus acciones:




Figura 29. Retornos de las acciones de Google

La serie de los retornos de las acciones de Google mostrada en la figura 29 presenta estacionariedad en media que converge en cero, presenta agrupamiento de volatilidad especialmente a partir del año 2018 en adelante, comportamiento que probablemente esté relacionado con las decisiones que están tomando los dos países involucrados en la guerra comercial.

4.4.2 Metodología Box – Jenkins: Modelos ARIMA para las FAANG. Antes de desarrollar la metodología Box – Jenkins para cada una de las series FAANG es importante advertir lo siguiente: (a) Para cada serie se identificaron, estimaron y diagnosticaron varios modelos escogiendo el más idóneo de acuerdo con el criterio de información AIC; (b) El proceso que se mostrará para cada serie será el del modelo escogido; (c) En cuanto al diagnóstico, se requieren comprobar que se cumplen las hipótesis básicas de los residuos: media marginal igual a cero, varianza marginal constante, falta de correlación para cualquier retardo y distribución normal (Peña, 2010, pág. 321).

4.4.2.1 Facebook

4.4.2.1.1 Identificación. Con base en los correlogramas de la figura 20 el FAC sugiere un AR ya que existen múltiples coeficientes distintos de cero con un decrecimiento lento y lineal, el FACP decrece de forma abrupta y solamente existen 2 retardos significativos el primero y otro cercano al retardo 200, por otro lado, los correlogramas no presentan patrones estacionales por lo que se sugirieron los siguientes modelos: ARIMA (1,1,0) y ARIMA (2,1,2). Finalmente, después de estimar y diagnosticar cada modelo se escogió el modelo ARIMA (2,1,2) al cual se le aplicó la metodología Box – Jenkins.

4.4.2.1.2 Estimación. Una vez identificado el modelo ARIMA (2,1,2) se proceden a estimar los parámetros utilizando el software R versión 3.6.1 obteniendo los siguientes resultados:

Tabla 4

Estimación del modelo ARIMA para la serie de retornos de Facebook

```

Call:
arima(x = a, order = c(2, 1, 2))

Coefficients:
      ar1      ar2      ma1      ma2
-0.8736 -0.0055 -0.1198 -0.8802
s.e.    0.1211  0.0284  0.1179  0.1179

sigma^2 estimated as 0.0003235:  log likelihood = 3261,  aic = -6511.99
    
```

Los coeficientes del modelo autorregresivo y de medias móviles resultaron ser significativos, en este caso el modelo tendría la siguiente estructura:

$$Y_t = -0,8736Y_{t-1} - 0,0055Y_{t-2} - 0,1198\varepsilon_{t-1} - 0,8802\varepsilon_{t-2} + \varepsilon$$

donde Y_t sería la cotización de la acción de Facebook en un tiempo t .

4.4.2.1.3 *Diagnóstico*. La figura 30 muestra el gráfico de los residuos estandarizados con sus respectivos correlogramas:




Figura 30. Diagnóstico de los residuos para el modelo ARIMA de la empresa Facebook.

De acuerdo con la figura 30 se puede concluir lo siguiente:

- Los residuos estandarizados parecen tener una media de cero, aunque es importante destacar la presencia de valores atípicos que por lo general terminan por generar problemas en la distribución normal.
- Los residuos no parecen seguir un patrón específico por lo que se suponen independientes.
- Los correlogramas simple y parcial muestran que se dejó información por fuera del modelo, es decir, los residuos al parecer no son completamente aleatorios, aunque se debe advertir estos no pasan el 5% de los 400 residuos analizados ni estos en su gran mayoría se encuentran cercanos a los límites de significancia.

Ahora bien, realizando el test de Ljung – Box se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,9961 es mayor al nivel de significancia designado.

Tabla 5

Resultados del test Ljung – Box para los residuos de Facebook

```
Box-Ljung test
data: r1
x-squared = 328.79, df = 400, p-value = 0.9961
```

Finalmente se realiza la prueba Shapiro – Wilk de normalidad para los residuos del modelo, obteniendo los siguientes resultados:

Tabla 6

Resultados de la prueba de normalidad para los residuos de Facebook

```
shapiro-wilk normality test
data: r1
W = 0.88341, p-value < 2.2e-16
```

Es decir, que con un nivel de significancia del 5% se rechaza la hipótesis nula de que los residuos tienen una distribución normal, si bien es cierto se está violando el supuesto de normalidad se debe clarificar que este supuesto no es central, aunque si conveniente ya que este resultado indica que posiblemente se esté dejando por fuera información sin modelar.

4.4.2.2 Amazon

4.4.2.2.1 *Identificación.* Los correlogramas de la figura 22 son similares a la de la empresa Facebook, en el caso de la empresa Amazon el FAC sugiere un AR ya que existen múltiples coeficientes distintos de cero con un decrecimiento lento y lineal, por otro lado, el FACP decrece de forma abrupta después del primer rezago sin mostrar más rezagos significativos. Para este caso se sugirieron los modelos: ARIMA (1,1,0) y ARIMA (2,1,2); después de realizar la estimación y diagnóstico a cada uno se optó por el modelo ARIMA (2,1,2), por lo tanto, sobre el modelo escogido se muestra la aplicación de la metodología Box – Jenkins.

4.4.2.2.2 *Estimación.* Una vez identificado el modelo ARIMA (2,1,2) se proceden a estimar los parámetros utilizando el software R versión 3.6.1 obteniendo los siguientes resultados:

Tabla 7

Estimación del modelo ARIMA para la serie de retornos de Amazon

```

call:
arima(x = cc, order = c(2, 1, 2))

Coefficients:
      ar1      ar2      ma1      ma2
-0.8839 -0.0048 -0.0998 -0.9001
s.e.    0.0868  0.0293  0.0821  0.0821

sigma^2 estimated as 0.0003564:  log likelihood = 3200.18,  aic = -6390.36
    
```

Los coeficientes del modelo autorregresivo y de medias móviles resultaron ser significativos, en este caso el modelo tendría la siguiente estructura:

$$Y_t = -0,8839Y_{t-1} - 0,0048Y_{t-2} - 0,0998\varepsilon_{t-1} - 0,9001\varepsilon_{t-2} + \varepsilon$$

donde Y_t sería la cotización de la acción de Amazon en un tiempo t .

4.4.2.2.3 *Diagnóstico*. La figura 31 muestra el gráfico de los residuos estandarizados con sus respectivos correlogramas.




Figura 31. Diagnóstico de los residuos para el modelo ARIMA de la empresa Amazon.

De acuerdo con la figura 31 se puede concluir lo siguiente:

- Los residuos estandarizados parecen tener una media de cero, aunque es importante destacar la presencia de valores atípicos que por lo general terminan por generar problemas en la distribución normal.
- Los residuos no parecen seguir un patrón específico por lo que se suponen independientes.
- La varianza parece ser no homogénea en ciertos periodos probablemente si se elevan al cuadrado se obtenga correlación serial lo que implica efectos ARCH.
- Los correlogramas simple y parcial muestran la presencia de un número considerable de residuos significativos, pero están por debajo del 5% de los 400 rezagos analizados, además en su gran mayoría los residuos no están próximos a los límites de significancia.

Ahora bien, realizando el test de Ljung – Box se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,9712 es mayor al nivel de significancia designado.

Tabla 8

Resultados del test Ljung – Box para los residuos de Amazon

Box-Ljung test

```
data: r2  
X-squared = 348.07, df = 400, p-value = 0.9712
```

Finalmente se realiza la prueba Shapiro – Wilk de normalidad para los residuos del modelo, obteniendo los siguientes resultados:

Tabla 9

Resultados de la prueba de normalidad para los residuos de Amazon

shapiro-wilk normality test

```
data: r2  
W = 0.89789, p-value < 2.2e-16
```

Es decir, que con un nivel de significancia del 5% se rechaza la hipótesis nula de que los residuos tienen una distribución normal, si bien es cierto se está violando el supuesto de normalidad se debe clarificar que este supuesto no es central, aunque si conveniente ya que este resultado indica que posiblemente se esté dejando por fuera información sin modelar.

4.4.2.3 Apple

4.4.2.3.1 Identificación. Los correlogramas de la figura 24 el FAC sugiere un AR ya que existen múltiples coeficientes distintos de cero con un decrecimiento lento casi lineal, por otro lado, el FACP decrece de forma abrupta después del primer rezago sin mostrar más rezagos significativos. En este caso se propone el modelo ARIMA (1,1,2) sobre el cual se aplicará la metodología Box – Jenkins.

4.4.2.3.2 Estimación. Una vez identificado el modelo ARIMA (1,1,2) se proceden a estimar los parámetros utilizando el software R versión 3.6.1 obteniendo los siguientes resultados:

Tabla 10

Estimación del modelo ARIMA para la serie de retornos de Apple

```

Call:
arima(x = e, order = c(1, 1, 2))

Coefficients:
      ar1      ma1      ma2
-0.1639 -0.8196 -0.1804
s.e.    1.3154  1.3447  1.3447

sigma^2 estimated as 0.0002346:  log likelihood = 3462.96,  aic = -6917.92
    
```

El coeficiente del modelo autorregresivo y los coeficientes de las medias móviles resultaron ser significativos, en este caso el modelo tendría la siguiente estructura:

$$Y_t = -0.1639Y_{t-1} - 0,8196\varepsilon_{t-1} - 0,1804\varepsilon_{t-2} + \varepsilon$$

donde Y_t sería la cotización de la acción de Apple en un tiempo t .

4.4.2.3.3 *Diagnóstico*. La figura 32 muestra el gráfico de los residuos estandarizados con sus respectivos correlogramas.




Figura 32. Diagnóstico de los residuos para el modelo ARIMA de la empresa Apple.

De acuerdo con la figura 32 se puede concluir lo siguiente:

- Los residuos estandarizados parecen tener una media de cero.
- Los residuos no parecen seguir un patrón específico por lo que se suponen independientes.
- La varianza no es homogénea en ciertos periodos principalmente a finales del 2018 y principios del 2019, probablemente si se elevan al cuadrado los errores se obtenga correlación serial lo que implica efectos ARCH.
- Los correlogramas simple y parcial muestran un comportamiento similar al ruido blanco, aunque existe un número de residuos significativos que no representan problemas si se tiene en cuenta que son en cantidad inferiores al 5% de los 400 residuos analizados.

Ahora bien, realizando el test de Ljung – Box se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,9889 es mayor al nivel de significancia designado.

Tabla 11

Resultados del test Ljung – Box para los residuos de Apple

```
Box-Ljung test
data: r3
X-squared = 338.15, df = 400, p-value = 0.9889
```

Finalmente se realiza la prueba Shapiro – Wilk de normalidad para los residuos del modelo, obteniendo los siguientes resultados:

Tabla 12

Resultados de la prueba de normalidad para los residuos de Apple

```
shapiro-wilk normality test
data: r3
W = 0.94734, p-value < 2.2e-16
```

Es decir, que con un nivel de significancia del 5% se rechaza la hipótesis nula de que los residuos tienen una distribución normal, este resultado indica que posiblemente se esté dejando por fuera información sin modelar.

4.4.2.4 Netflix

4.4.2.4.1 *Identificación.* Los correlogramas de la figura 26 para el caso de la empresa Netflix muestran que la FAC sugiere un AR ya que existen múltiples coeficientes distintos de cero con un decrecimiento lento y lineal, por otro lado, el FACP decrece de forma abrupta después del primer rezago mostrando la existencia de 3 rezagos significativos. Para este caso se identificaron los modelos ARIMA (1,1,0) y ARIMA (2,1,2); después de realizar la estimación y diagnóstico a cada uno se optó por el modelo ARIMA (2,1,2), por lo tanto, sobre el modelo escogido se muestra la aplicación de la metodología Box – Jenkins.

4.4.2.4.2 *Estimación.* Una vez identificado el modelo ARIMA (2,1,2) se proceden a estimar los parámetros utilizando el software R versión 3.6.1 obteniendo los siguientes resultados:

Tabla 13

Estimación del modelo ARIMA para la serie de retornos de Netflix

```
call:
arima(x = g, order = c(2, 1, 2))

Coefficients:
      ar1      ar2      ma1      ma2
-0.8227  0.0310 -0.1488 -0.8512
s.e.    0.5417  0.0292  0.5408  0.5408

sigma^2 estimated as 0.0006986:  log likelihood = 2777.61,  aic = -5545.22
```

Los coeficientes del modelo autorregresivo y de medias móviles resultaron ser significativos, en este caso el modelo tendría la siguiente estructura:

$$Y_t = -0,8227Y_{t-1} - 0,031Y_{t-2} - 0,1488\varepsilon_{t-1} - 0,8512\varepsilon_{t-2} + \varepsilon$$

donde Y_t sería la cotización de la acción de Netflix en un tiempo t .

4.4.2.4.3 *Diagnóstico*. La figura 33 muestra el gráfico de los residuos estandarizados con sus respectivos correlogramas.




Figura 33. Diagnóstico de los residuos para el modelo ARIMA de la empresa Netflix.

De acuerdo con la figura 33 se puede concluir lo siguiente:

- Los residuos estandarizados parecen tener una media de cero.
- Los residuos no parecen seguir un patrón específico por lo que se suponen independientes.

- La varianza no es homogénea en ciertos periodos probablemente si se elevan al cuadrado se obtenga correlación serial lo que implica efectos ARCH.
- Los correlogramas simple y parcial muestran que existe presencia de un número poco considerable de residuos significativos teniendo en cuenta la cantidad de residuos analizados. Eso sí preocupa que esos residuos significativos tiendan a estar agrupados, lo que sugiere en los errores todavía exista información que el modelo no pudo recuperar.

Ahora bien, realizando el test de Ljung – Box se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,9913 es mayor al nivel de significancia designado.

Tabla 14

Resultados del test Ljung – Box para los residuos de Netflix

Box-Ljung test

```
data: r4  
X-squared = 335.84, df = 400, p-value = 0.9913
```

Finalmente se realiza la prueba Shapiro – Wilk de normalidad para los residuos del modelo, obteniendo los siguientes resultados:

Tabla 15

Resultados de la prueba de normalidad para los residuos de Netflix

shapiro-wilk normality test

```
data: r4  
w = 0.89788, p-value < 2.2e-16
```

Es decir, que con un nivel de significancia del 5% se rechaza la hipótesis nula de que los residuos tienen una distribución normal, este resultado indica que posiblemente se esté dejando por fuera información sin modelar.

4.4.2.5 Google

4.4.2.5.1 Identificación. Los correlogramas de la figura 28 muestran que el FAC sugiere un ARMA ya que existen múltiples coeficientes distintos de cero con un decrecimiento lento casi lineal, por otro lado, el FACP decrece de forma abrupta después del primer rezago, aunque posteriormente se encuentran más rezagos significativos. Después de verificar varios modelos se decidió identificar el modelo ARIMA (2,1,2) sobre el cual se aplicará la metodología Box – Jenkins.

4.4.2.5.2 Estimación. Una vez identificado el modelo ARIMA (2,1,2) se proceden a estimar los parámetros utilizando el software R versión 3.6.1 obteniendo los siguientes resultados:

Tabla 16

Estimación del modelo ARIMA para la serie de retornos de Google

```
Call:
arima(x = i, order = c(2, 1, 2))

Coefficients:
      ar1      ar2      ma1      ma2
 -0.8002  0.0262 -0.1563 -0.8437
s.e.    0.3290  0.0372  0.3271  0.3271

sigma^2 estimated as 0.0002127:  log likelihood = 3524.33,  aic = -7038.67
```

Los coeficientes del modelo autorregresivo y de medias móviles resultaron ser significativos, en este caso el modelo tendría la siguiente estructura:

$$Y_t = -0,8002Y_{t-1} + 0,0262Y_{t-2} - 0,1563\varepsilon_{t-1} - 0,8437\varepsilon_{t-2} + \varepsilon$$

donde Y_t sería la cotización de la acción de Google en un tiempo t .

4.4.2.5.3 *Diagnóstico*. La figura 34 muestra el gráfico de los residuos estandarizados con sus respectivos correlogramas.




Figura 34. Diagnóstico de los residuos para el modelo ARIMA de la empresa Google.

De acuerdo con la figura 34 se puede concluir lo siguiente:

- Los residuos estandarizados parecen tener una media de cero.
- Los residuos no parecen seguir un patrón específico por lo que se suponen independientes.
- La varianza parece ser no homogénea desde el año 2018, probablemente si se elevan al cuadrado los errores se obtenga correlación serial lo que implica efectos ARCH.
- Los correlogramas simple y parcial muestran que existe una considerable cantidad de residuos significativos, esa cantidad es aproximada al 5% de los 400 residuos analizados lo que implica un gran riesgo de encontrar todavía información valiosa en los residuos y que el modelo no tuvo en cuenta. Otro aspecto preocupante es que dichos residuos significativos tienden a estar agrupados lo que refuerza la tesis de que el modelo no recoge a plenitud la información.

Ahora bien, realizando el test de Ljung – Box se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,6636 es mayor al nivel de significancia designado.

Tabla 17

Resultados del test Ljung – Box para los residuos de Google

```
Box-Ljung test
data: r5
X-squared = 387.52, df = 400, p-value = 0.6636
```

Finalmente se realiza la prueba Shapiro – Wilk de normalidad para los residuos del modelo, obteniendo los siguientes resultados:

Tabla 18

Resultados de la prueba de normalidad para los residuos de Google

```
shapiro-wilk normality test
data: r5
W = 0.92604, p-value < 2.2e-16
```

Es decir, que con un nivel de significancia del 5% se rechaza la hipótesis nula de que los residuos tienen una distribución normal, este resultado indica que posiblemente se esté dejando por fuera información sin modelar.

4.5 Modelos ARCH y GARCH

4.5.1 Efectos ARCH en las series de tiempo de las FAANG. Previamente al analizar la serie de retornos y en el análisis de residuos de los modelos ARIMA para cada una de las FAANG se habló del no cumplimiento de la hipótesis de normalidad en los residuos y de la presencia de periodos de alta volatilidad alternados con periodos estables, estas características son fuertes evidencias de presencia de efectos ARCH. Para detectar los efectos ARCH en cada serie se utilizó el estadístico de Ljung – Box en los correlogramas de los residuos al cuadrado, en donde con un nivel de significancia del 5% se plantea la hipótesis nula de que los residuos al cuadrado siguen un proceso de ruido blanco contrastada contra la hipótesis alternativa de que los residuos no siguen un proceso de ruido blanco en consecuencia están correlacionados. Los resultados para cada empresa se muestran en la tabla 19:

Tabla 19

Presencia de efectos ARCH

EMPRESA	ESTADÍSTICO	GRADOS DE LIBERTAD	VALOR P	EFFECTOS ARCH
Facebook	174,58	400	1	No
Amazon	506,97	400	0,00022	Sí
Apple	508,23	400	0,00019	Sí
Netflix	488,24	400	0,001646	Sí
Google	206.55	400	1	No

Con base en los resultados expuestos en la tabla 19 se sugiere mantener los modelos ARIMA estimados para la serie de los retornos de las empresas Facebook y Google, mientras que para los retornos de las otras empresas (Amazon, Apple y Netflix) es necesario incorporar modelos que describan la volatilidad. En conclusión, si la volatilidad muestra qué tan rápidos ajustan los precios ante determinados hechos, se puede decir que las empresas Facebook y Google son más estables mientras que las restantes empresas son sensibles ante hechos como la guerra comercial.

4.5.2 Identificación del Modelo ARCH y GARCH¹. Al elevar al cuadrado cada uno de los residuos de los modelos ARIMA obtenidos anteriormente se construyen los correlogramas y aplicando la misma metodología se obtienen los modelos ARCH y GARCH, sin embargo, es difícil determinar los valores p y q por lo que es recomendable realizar distintas combinaciones de valores p y q escogiendo el que obtenga el menor valor del criterio de información AIC. Para el presente estudio las combinaciones partirán asignando un valor máximo de orden 9 tanto para p como para q , la tabla 20 muestra los modelos escogidos ARCH y GARCH para cada una de las series de los retornos de las FAANG que presentaron efectos ARCH con el respectivo criterio de información AIC.

¹ Teniendo en cuenta que si existe la presencia de efectos ARCH en una serie la estimación de los parámetros del modelo ARIMA son ineficientes pues se debe cumplir la homocedasticidad en los errores. En consecuencia, para las series de retornos de Amazon, Apple y Netflix se replanteó el modelo que explique su media con base en la presencia de volatilidad.

Tabla 20

Modelos ARCH y GARCH escogidos para las empresas Amazon, Apple y Netflix

EMPRESA	MODELO	AIC
Amazon	Garch (2,2)	-6524,03
Apple	Garch (1,1)	-7053,74
Netflix	Arch (3)	-5584,2

4.5.3 Estimación de los Modelos y Diagnóstico. Una vez identificados cada uno de los modelos ARCH y GARCH para las series de tiempo de los retornos de las acciones de Amazon, Apple y Netflix se procede a estimar los parámetros verificando el cumplimiento de la varianza positiva y la condición de estacionariedad. Utilizando el software R versión 3.6.1 se obtuvieron los siguientes resultados:

4.5.3.1 Amazon. La estimación del modelo GARCH se realizó a través del software R versión 3.6.1. Los resultados se muestran en la tabla 21.

Tabla 21

Estimación del modelo GARCH para la serie de retornos de Amazon

```
Call:
garch(x = c, order = c(2, 2), trace = F)

Model:
GARCH(2,2)

Residuals:
    Min       1Q   Median       3Q      Max
-6.10053 -0.37869  0.07935  0.60000  8.41385

Coefficient(s):
      Estimate Std. Error  t value Pr(>|t|)
a0 6.740e-05  7.640e-06  8.822 < 2e-16 ***
a1 3.960e-02  1.432e-02  2.765  0.00569 **
a2 2.008e-01  2.453e-02  8.189 2.22e-16 ***
b1 3.230e-08  4.024e-02  0.000  1.00000
b2 5.942e-01  3.758e-02 15.809 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Solamente el coeficiente β_1 resultó ser no significativo, en este caso el modelo tendría la siguiente estructura:

$$h_t = 6,74 * 10^{-5} + 3,96 * 10^{-2} \varepsilon_{t-1}^2 + 2,008 * 10^{-1} \varepsilon_{t-2}^2 + 5,942 * 10^{-1} h_{t-2}$$

donde h_t sería la varianza de la cotización de la acción de Amazon en un tiempo t .

Respecto al diagnóstico al realizar el test de Ljung – Box se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,8469 es mayor al nivel de significancia designado.

Tabla 22

Resultados del test Ljung – Box para los residuos del modelo GARCH de Amazon

Box-Ljung test

```
data: Squared.Residuals  
x-squared = 0.037281, df = 1, p-value = 0.8469
```

4.5.3.2 Apple. La estimación del modelo GARCH se realizó a través del software R versión

3.6.1. Los resultados se muestran en la tabla 23.

Tabla 23

Estimación del modelo GARCH para la serie de retornos de Apple

```

Call:
garch(x = e, order = c(1, 1), trace = F)

Model:
GARCH(1,1)

Residuals:
    Min       1Q   Median       3Q      Max
-5.10451 -0.42922  0.05924  0.58478  5.41949

Coefficient(s):
      Estimate Std. Error t value Pr(>|t|)
a0 1.775e-05  3.179e-06   5.584 2.35e-08 ***
a1 9.665e-02  1.814e-02   5.328 9.92e-08 ***
b1 8.286e-01  2.754e-02  30.091 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
    
```

Los coeficientes resultaron ser significativos, en este caso el modelo tendría la siguiente estructura:

$$h_t = 1,775 * 10^{-5} + 9,665 * 10^{-2} \varepsilon_{t-1}^2 + 8,286 * 10^{-1} h_{t-1}$$

donde h_t sería la varianza de la cotización de la acción de Apple en un tiempo t .

Respecto al diagnóstico al realizar el test de Ljung – Box se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,9871 es mayor al nivel de significancia designado.

Tabla 24

Resultados del test Ljung – Box para los residuos del modelo GARCH de Apple

```
Box-Ljung test
data: Squared.Residuals
X-squared = 0.00026251, df = 1, p-value = 0.9871
```

4.5.3.3 Netflix. La estimación del modelo ARCH se realizó a través del software R versión

3.6.1. Los resultados se muestran en la tabla 25.

Tabla 25

Estimación del modelo ARCH para la serie de retornos de Netflix

```
Call:
garch(x = g, order = c(0, 3), trace = F)

Model:
GARCH(0,3)

Residuals:
    Min       1Q   Median       3Q      Max
-7.6676 -0.4044  0.0232  0.5257  7.6598

Coefficient(s):
      Estimate Std. Error t value Pr(>|t|)
a0 4.703e-04  1.506e-05  31.217 < 2e-16 ***
a1 8.609e-02  2.479e-02   3.472 0.000516 ***
a2 3.959e-02  1.893e-02   2.092 0.036457 *
a3 3.217e-01  2.455e-02  13.105 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Todos los coeficientes resultaron ser significativos, en este caso el modelo tendría la siguiente estructura:

$$h_t = 4,703 * 10^{-4} + 8,609 * 10^{-2} \varepsilon_{t-1}^2 + 3,959 * 10^{-2} \varepsilon_{t-2}^2 + 3,217 * 10^{-1} \varepsilon_{t-3}^2$$

donde h_t sería la varianza de la cotización de la acción de Netflix en un tiempo t .

La tabla 26 muestra los resultados del diagnóstico al realizar el test de Ljung – Box

Tabla 26

Resultados del test Ljung – Box para los residuos del modelo ARCH de Netflix

```
Box-Ljung test
data: Squared.Residuals
X-squared = 0.26971, df = 1, p-value = 0.6035
```

se confirma que con un nivel de significancia del 5% no se rechaza la hipótesis nula de que los residuos son independientes pues el valor P de 0,6035 es mayor al nivel de significancia designado.

4.6 Predicción de los Modelos Obtenidos

Cada uno de los modelos obtenidos: ARIMA, ARCH y GARCH para explicar y cotizar las acciones de cada una de las empresas pertenecientes a las FAANG se estimaron a partir de los datos de entrenamiento, es decir, aquellas series de tiempo que incluyen datos desde el 7 de mayo del 2014 hasta el 6 de mayo del 2019. La validación de los distintos modelos se realizó sobre los datos no usados que se enmarcan en el periodo que va desde el 7 de mayo del 2019 hasta el 30 de agosto del 2019.

4.6.1 Facebook. La figura 35 muestra la predicción de los retornos sobre los datos no evaluados, la línea roja hace referencia a los datos reales, mientras que la línea de color azul muestra el pronóstico del modelo ARIMA de entrenamiento.




Figura 35. Predicción con serie de entrenamiento para los retornos de Facebook.

A pesar de que no existe una coincidencia entre los valores pronosticados y los datos reales es importante resaltar que estos últimos están dentro del intervalo de confianza del pronóstico, además tanto el pronóstico como los datos reales convergen en cero. Teniendo en cuenta que el modelo funciona correctamente se procede a la predicción de los retornos para los próximos 30 días del mes de septiembre del 2019. Ver figura 36.




Figura 36. Predicción a 30 días de los retornos de las acciones de Facebook.

De acuerdo con la figura 36 para el mes de septiembre los retornos de las acciones de la empresa Facebook serán estables independientemente de las decisiones que se tomen en el marco de la guerra comercial entre Estado Unidos y China.

4.6.2 Amazon. La figura 37 muestra la predicción de la volatilidad y los retornos sobre los datos no evaluados, las líneas de color gris corresponden a los datos reales mientras las líneas de color azul y rojo representan la predicción de la volatilidad y los retornos respectivamente.




Figura 37. Predicción de los retornos y la volatilidad con datos de entrenamiento para Amazon

Si bien no existe coincidencia entre los datos reales y los pronósticos es importante mostrar que en el caso de la volatilidad el modelo de entrenamiento está acorde con el movimiento de la volatilidad real, es decir, el modelo fue capaz de predecir los clústeres de volatilidad. Frente a los retornos el modelo de entrenamiento trata de converger en cero al igual que los retornos reales, aunque es claro que no logra predecir satisfactoriamente valores extremos.

Antes de realizar el pronóstico la figura 38 muestra la curva de impacto que tiene el comportamiento de los retornos de Amazon frente a las noticias positivas y negativas.




Figura 38. Impacto de la volatilidad para la empresa Amazon

Se aprecia claramente que la volatilidad es simétrica en los retornos de las acciones de Amazon por lo que esta se ve afectada de forma equivalente ante noticias positivas y negativas, es decir, se espera que la cotización de la acción de Amazon sufra el mismo impacto en términos volatilidad ante noticias positivas y negativas. En esa medida la figura 39 muestra la predicción de los retornos y la volatilidad de la empresa Amazon para los primeros días 10 días del mes de septiembre del 2019.

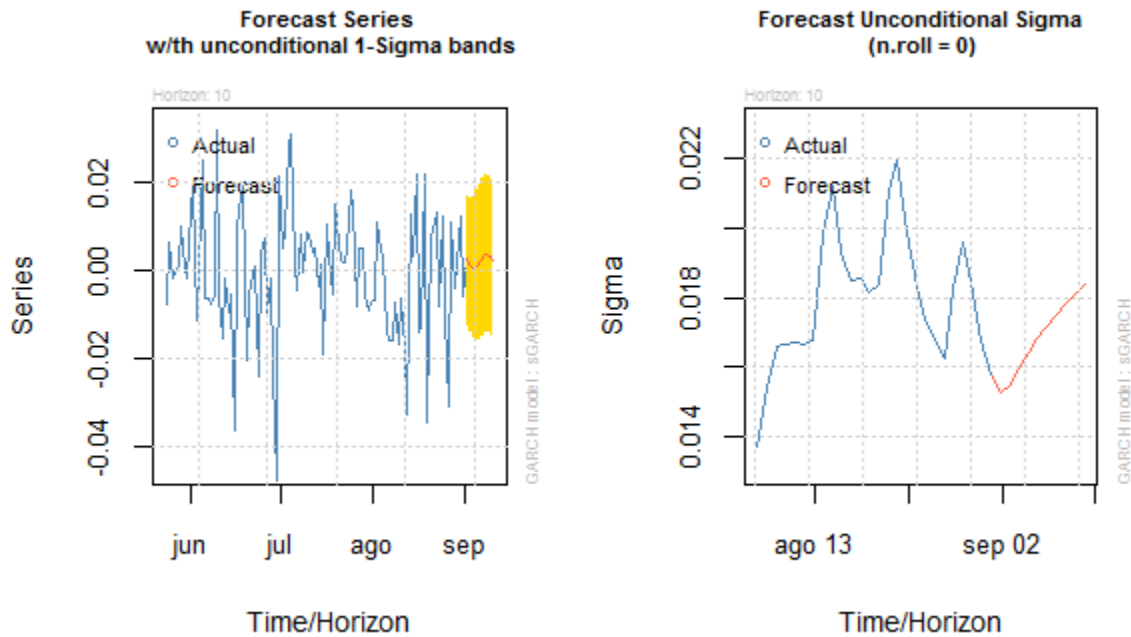


Figura 39. Predicción del retorno y la volatilidad de las acciones de Amazon

De acuerdo con la figura 39 se espera que para los próximos 10 días los retornos de las acciones de Amazon presenten un incremento en la volatilidad, además teniendo en cuenta que el impacto de las noticias positivas y negativas afectan de forma equivalente los retornos de la acción es importante para el tipo de operaciones Day Trading² estar a la expectativa de las decisiones inmediatas tomadas en el marco de la guerra comercial.

² Las operaciones Day Trading es un modelo de inversión en el corto plazo, se espera obtener beneficios con el alza o la baja de la cotización diaria. Incluso algunas operaciones se abren y cierran en minutos o segundos por lo que se considera una operación en tiempo real.

4.6.3 Apple. La figura 40 muestra la predicción de la volatilidad y los retornos sobre los datos no evaluados, las líneas de color gris corresponden a los datos reales mientras las líneas de color azul y rojo representan la predicción de la volatilidad y los retornos respectivamente.

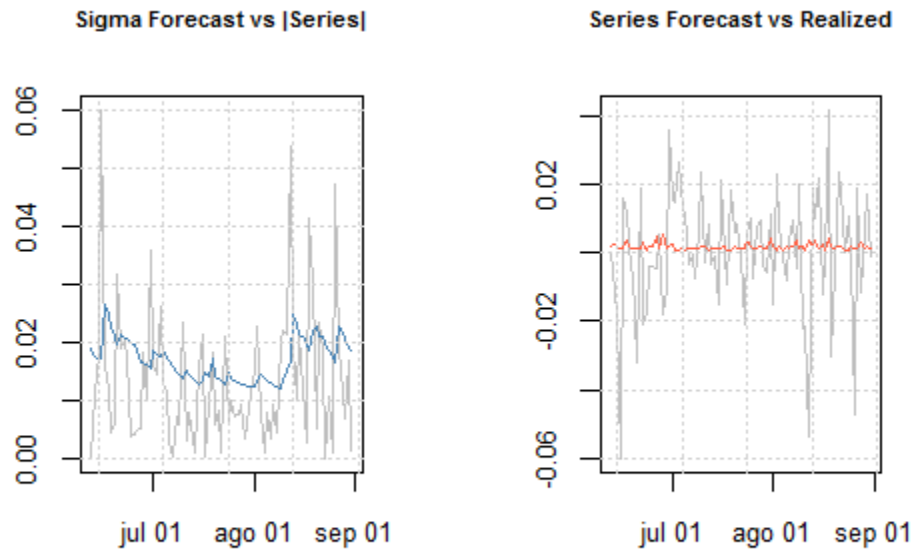


Figura 40. Predicción de los retornos y la volatilidad con datos de entrenamiento para Apple

Es evidente que no existe coincidencia entre los datos reales y los pronósticos, aunque en el caso de la volatilidad el modelo fue capaz de predecir los clústeres de volatilidad. Frente a los retornos el modelo de entrenamiento trata de converger en cero al igual que los retornos reales, aunque es claro que no logra predecir satisfactoriamente valores extremos.

Antes de realizar el pronóstico la figura 41 muestra la curva de impacto que tiene el comportamiento de los retornos de Apple frente a las noticias positivas y negativas.




Figura 41. Impacto de la volatilidad para la empresa Apple

De acuerdo con la figura 41 el impacto en los retornos de las acciones de Apple debido a las noticias positivas y negativas es equivalente. Finalmente, la figura 42 muestra la predicción de los retornos de las acciones de Apple y su volatilidad.

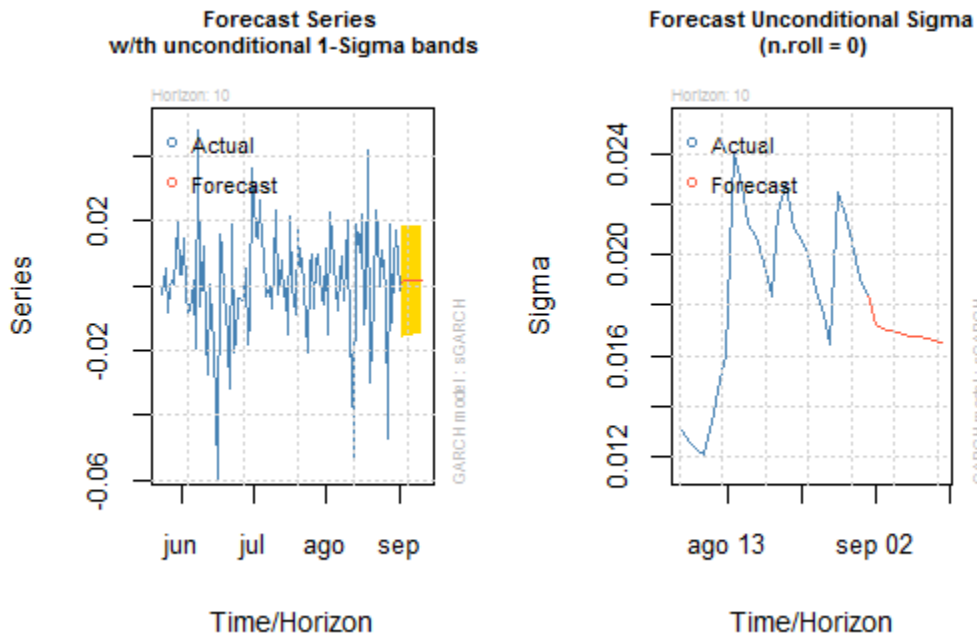


Figura 42. Predicción del retorno y la volatilidad de las acciones de Apple

De acuerdo con la figura 42 se espera que para los primeros 10 días de septiembre la volatilidad disminuya entrando en un proceso estable en los retornos de las acciones de Apple, esto implica que para las operaciones tipo Day Trading no se generen ganancias o pérdidas considerables.

4.6.4 Netflix. La figura 43 muestra la predicción de la volatilidad y los retornos sobre los datos no evaluados, las líneas de color gris corresponden a los datos reales mientras las líneas de color azul y rojo representan la predicción de la volatilidad y los retornos respectivamente.




Figura 43. Predicción de los retornos y la volatilidad con datos de entrenamiento para Netflix

No existe coincidencia entre los datos reales y los pronósticos, pero el modelo fue capaz de predecir los clústeres de volatilidad. Frente a los retornos el modelo de entrenamiento trata de converger en cero al igual que los retornos reales, aunque es claro que no logra predecir satisfactoriamente valores extremos.

Antes de realizar el pronóstico la figura 44 muestra la curva de impacto que tiene el comportamiento de los retornos de Netflix frente a las noticias positivas y negativas.




Figura 44. Impacto de la volatilidad para la empresa Netflix

Los retornos de las acciones de Netflix tienen un comportamiento similar a las empresas Amazon y Apple en lo referente al impacto de las noticias positivas y negativas, es decir, ante este tipo de noticias la volatilidad presenta los mismos patrones. Finalmente, la figura 45 muestra la predicción de los retornos de las acciones de Netflix y su volatilidad.




Figura 45. Predicción del retorno y la volatilidad de las acciones de Netflix

De acuerdo con la figura 45 se espera que para los primeros 10 días de septiembre la volatilidad aumente considerablemente ingresando a otro clúster de volatilidad, en consecuencia, los retornos tendrán altibajos que dinamizarán las operaciones tipo Day Trading en las que las personas dedicadas a este tipo de operación tendrán que estar a la expectativa de las decisiones inmediatas tomadas en el marco de la guerra comercial.

4.6.5 Google. La figura 46 muestra la predicción de los retornos sobre los datos no evaluados, la línea roja hace referencia a los datos reales, mientras que la línea de color azul muestra el pronóstico del modelo ARIMA de entrenamiento.




Figura 46. Predicción con serie de entrenamiento para los retornos de Google.

Es claro que no existe una coincidencia entre los valores pronosticados y los datos reales es importante resaltar que estos últimos en su mayoría se encuentran dentro del intervalo de confianza del pronóstico, además tanto el pronóstico como los datos reales convergen en cero. Teniendo en cuenta que el modelo funciona correctamente se procede a la predicción de los retornos para los próximos 30 días del mes de septiembre del 2019. Ver figura 47.




Figura 47. Predicción a 30 días de los retornos de las acciones de Google.

De acuerdo con la figura 47 para el mes de septiembre que los retornos de las acciones de la empresa Google sean estables independientemente de las decisiones que se tomen en el marco de la guerra comercial entre Estados Unidos y China.

4.6.6 Predicción de los precios y errores de pronóstico. A lo largo del estudio se trabajó con la serie de retornos de las acciones para cada una de las empresas pertenecientes al fondo FAANG, sin embargo, a través de la predicción de estos retornos se pueden de igual manera pronosticar los precios de las acciones. La tabla 27 muestra el pronóstico de los precios de las acciones de cada empresa del fondo FAANG.

Tabla 27

Predicción a 10 días de la cotización de las acciones del fondo FAANG

TIEMPO	FACEBOOK	AMAZON	APPLE	NETFLIX	GOOGLE
T+1	185,50	1778,00	208,70	294,30	1189,44
T+2	185,37	1785,00	208,70	294,70	1189,14
T+3	185,26	1787,00	208,70	295,00	1188,79
T+4	185,17	1794,00	208,70	295,50	1188,52
T+5	185,10	1796,00	208,70	295,80	1188,29
T+6	185,05	1803,00	208,70	296,20	1188,10
T+7	185,00	1805,00	208,70	296,50	1187,93
T+8	184,96	1812,00	208,70	296,90	1187,80
T+9	184,93	1815,00	208,70	297,30	1187,69
T+10	184,90	1821,00	208,70	297,60	1187,59

En términos generales la cotización de las acciones de las FAANG tiende a crecer o decrecer levemente. Particularmente la cotización de las acciones de Apple a pesar de presentar alta volatilidad durante el periodo de análisis permanecerá constante adentrándose probablemente en un periodo de calma; la cotización de las acciones de Facebook tenderá levemente a la baja, aunque en un mediano plazo el precio se estabilizará; al igual que Facebook la cotización de las acciones de la empresa Google tenderá a la baja con una perspectiva de estabilizar el precio; Amazon por el contrario tendrá incrementos significativos en la cotización de la acción acompañado de un incremento en la volatilidad; finalmente, la cotización de las acciones de la empresa Netflix tendrá un incremento acompañado por un periodo de volatilidad.

Frente a los errores del pronóstico la tabla 28 muestra para cada empresa de las FAANG el tipo de modelo aplicado, el error cuadrático medio (MSE), el error absoluto medio (MAE) y el valor del criterio de información Akaike.

Tabla 28

Ajuste de los distintos obtenidos

EMPRESA	MODELO	MSE	MAE	AIC
FACEBOOK	ARIMA (2,1,2)	0,0186957	0,01251	-6511,99
AMAZON	GARCH (2,2)	0,0002235	0,01108	-6524,03
APPLE	GARCH (1,1)	0,0003214	0,01349	-7053,74
NETFLIX	ARCH (3)	0,0004969	0,01668	-5584,2
GOOGLE	ARIMA (2,1,2)	0,014805	0,01027	-7038,67

El MSE maximiza el error, se espera que se castigue donde la diferencia entre el valor real y del pronóstico fue más alta, mientras que el MAE es un promedio entre las distintas diferencias entre el valor real y el pronóstico.

5. Conclusiones

Una guerra comercial busca en esencia restringir las exportaciones de un país para proteger la industria local lo que conlleva de forma inevitable a una reacción de la parte afectada. Ambas partes valiéndose de mecanismos como aranceles a los productos importados, subsidios a la producción nacional y reducción de cuotas de importación buscan presionar a la contraparte en busca de un acuerdo que satisfaga las necesidades proteccionistas; sin embargo, en la actual guerra

comercial entre Estados Unidos y China se ha visto otra serie de medidas más radicales como las sanciones, regulaciones, restricciones de flujo de capital y acciones fuera de toda lógica comercial, como la detención de la hija del fundador de la empresa Huawei, Meng Wanzhou, bajo sospechas de ayudar a Irán a evitar las sanciones.

En el desarrollo de la guerra comercial las acciones de las FAANG alcanzaron las cotizaciones más altas, sin embargo, a partir de ese punto estas tuvieron una tendencia a la baja hasta principios del 2019 cuando empezaron nuevamente un proceso al alza. En este periodo se evidenció gráficamente que cada una de las series de las cotizaciones de las acciones de las FAANG presentaron volatilidad, sin embargo, al analizar los residuos de todos los modelos ARIMA obtenidos las empresas Facebook y Google no presentaron efectos ARCH, aunque se debe advertir que la volatilidad depende también del tamaño de la muestra y del periodo analizado. Como consecuencia de este comportamiento después de analizar múltiples modelos y priorizarlos de acuerdo con el valor del criterio de información AIC, así como los errores de pronóstico, los modelos obtenidos para cada una de las series de retornos de las empresas FAANG fueron los siguientes:

- Facebook: modelo ARIMA (2,2)
- Amazon: En media modelo ARIMA (2,2) y volatilidad GARCH (2,2)
- Apple: En media modelo ARIMA (1,2) y volatilidad GARCH (1,1)
- Netflix: En media modelo ARIMA (2,2) y volatilidad ARCH (3)
- Google: En media modelo ARIMA (2,2)

Respecto a la validez de los modelos obtenidos las series de tiempo de las cotizaciones no presentaron tendencias lineales o polinómicas lo que terminó por limitar los análisis del tipo clásico, en consecuencia, fue necesario incorporar modelos ARIMA para las series de las empresas Facebook y Google, un modelo ARCH para la serie de la empresa Netflix y modelos GARCH para la serie de las empresas Amazon y Apple. A su vez los modelos con heterocedasticidad condicional tuvieron una volatilidad simétrica a pesar de que comúnmente las noticias negativas generan un clúster de volatilidad. Teniendo en cuenta este aspecto los modelos ARCH y GARCH ajustaron aceptablemente ya que son apropiados para modelar este tipo de volatilidad.

De acuerdo con los pronósticos se espera que las cotizaciones de las acciones de Google, Facebook y Apple se estabilicen, lo cual no es atractivo para los operadores Day Trading, mientras que la volatilidad de las empresas Amazon y Netflix aumentará al igual que su cotización. Si se cruzan los pronósticos con la actual guerra comercial se puede decir que la predicción de la cotización de las acciones de Facebook tiende a ser estable ya que esta empresa apenas tiene presencia en China y lo único que la afecta es la imposición de aranceles a la importación de tecnología; por su parte el pronóstico de la cotización de las acciones de Google es estable debido al levantamiento parcial del veto a Huawei, además es importante advertir que Google es la principal filial de la empresa Alphabet cuyo objeto social es bastante diverso y no se limita a servicios relacionados con Internet; por su parte Apple no se está viendo afectada ya que las medidas tomadas por las partes en conflicto la han mantenido parcialmente fuera de él, aunque existe un margen de incertidumbre pues Apple importa tecnología para fabricar sus productos en China. Amazon se ve afectado por los aranceles a los productos que importa desde China, es probable que para las festividades de fin de año los comerciantes aumenten los pedidos queriendo

evitar aún más el alza en los precios de los productos procedentes de China a riesgo de aumentar los costos de inventario y esto sin duda llegará a mejorar la perspectiva de la empresa Amazon, por lo menos a corto plazo. Finalmente, Netflix no depende del mercado chino, sin embargo, el hecho de que sus competidores inmediatos Amazon y Apple se estén viendo afectados por la guerra comercial hace que las perspectivas sean alentadoras.

Referencias Bibliográficas

- Alonso, J. C., & García, J. C. (2009). ¿Qué tan buenos son los patrones del igbc para predecir su comportamiento? Una aplicación con datos de alta frecuencia. *Estudios Gerenciales*, 13-36.
- Banco Mundial. (2019). Obtenido de https://datos.bancomundial.org/indicador/NY.GDP.MKTP.CD?end=2018&locations=CO&name_desc=false&start=2017
- Bollerslev, T. (1986). Generalized Autorregresive Conditional Heteroscedasticity. *Journal of Econometrics*, 307-326.
- Casas Monsegny, M., & Cepeda, C. E. (2008). “Modelos ARCH, GARCH y EGARCH: aplicaciones a series financieras”. *Cuadernos de Economía*, 287-319.
- Déjà vu, M. (11 de 6 de 2018). *esBolsa*. Obtenido de <https://esbolsa.com/blog/bolsa-americana/que-es-el-sp-500/>
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*, 427-431.
- Diebold, F. X., & Mariano, R. S. (1995). Comparing Predictive Accuracy. *Journal of Business and Economic Statistics*, 253-265.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 987-1007.
- FINVIZ. (8 de 2019). *Screeener Index S&P 500*. Obtenido de https://finviz.com/screener.ashx?v=111&f=idx_sp500

- Galán Figueroa, J., Feregrino Feregrino, J., Ruíz Galindo, L. A., Quintana Romero, L., Mendoza González, M. Á., & Rosales, R. A. (2016). *Econometría Aplicada Utilizando R*. México D.F.: PAPIME-PE302513.
- García Díaz, C. M. (2014). Predicción Del Comportamiento De La Rentabilidad De La Acción De Isagen, A Patir De La Técnica De Redes Neuronales Artificiales. *Tesis Maestría*. Bogotá, Colombia: Universidad Pontificia Javeriana.
- García, M. C., Jalal, A. M., Garzón, L. A., & López, J. M. (2013). Métodos para predecir índices Bursátiles. *Ecos de Economía*, 51-82.
- González, R. (13 de 6 de 2018). *Los Mercados Financieros*. Obtenido de <http://losmercadosfinancieros.es/asi-ha-cambiado-el-peso-industrial-del-sp-500-en-los-ultimos-anos.html>
- Gujarati, D. N., & Porter, D. C. (2009). *Econometría*. México D.F.: McGraw-Hill/Irwin, Inc.
- Ljung, G. M., & Box, G. E. (1978). On a Measure of Lack of Fit in Time Series Models. *Biometrika*, 297-303.
- Nelson, D. B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*, 347-370.
- Ospina, D. F., & Giraldo Sánchez, D. A. (2009). Aplicación de los modelos GARCH a la estimación del VaR de acciones colombianas. *Soluciones de Postgrado EIA*, 11-24.
- Peña, D. (2010). *Análisis de series temporales*. Madrid: Alianza Editorial, S.A.
- REVISTA DINERO. (26 de 6 de 2019). *Diez fechas clave en la guerra comercial entre China y Estados Unidos*. Obtenido de Revista Dinero: <https://www.dinero.com/internacional/articulo/fechas-clave-en-la-guerra-comercial-entre-china-y-estados-unidos/273614>

- SECTOR SPDR ETFS. (8 de 2019). *Sector Tracker*. Obtenido de <https://www.sectorspdr.com/sectorspdr/tools/sector-tracker>
- Stevens, R. (9 de 10 de 2017). *Rankia*. Obtenido de <https://www.rankia.co/blog/analisis-colcap/3706870-que-son-para-sirven-indices-bursatiles>
- Trejos Carpintero, Á., Nieto Salazar, S., & Carvajal Olaya, P. (2013). Modelo De Predicción Del Precio De La Acción Ordinaria Cementos Argos. *Scientia et Technica*, 67-72.
- Vallejo, C., & Torres, Ó. (2012). En *Manual de la inversión en bolsa* (pág. 11). Madrid: INVERSOR EDICIONES, S.L.
- Vegas Villalmanzo, I. (2016). Predicción De Valores De Bolsa Mediante Minería De Datos Para Mercado De Alta Frecuencia. (*Tesis de pregrado*). Madrid, España: Universidad Politécnica de Madrid.
- YAHOO. (8 de 2019). *Datos históricos del índice S&P500*. Obtenido de <https://es.finance.yahoo.com/quote/%5EGSPC/history?p=%5EGSPC>
- YAHOO FINANZAS. (8 de 2019). *Datos Históricos*. Obtenido de <https://es.finance.yahoo.com/quote/%5EGSPC/history?p=%5EGSPC>
- YAHOO FINANZAS. (8 de 2019). *Datos históricos Amazon*. Obtenido de <https://es.finance.yahoo.com/quote/AMZN/history?p=AMZN>
- YAHOO FINANZAS. (Febrero de 2019). *Datos históricos Apple*. Obtenido de <https://es-us.finanzas.yahoo.com/quote/AAPL/history?period1=1544590800&period2=1550552400&interval=1d&filter=history&frequency=1d>
- YAHOO FINANZAS. (8 de 2019). *Datos históricos Facebook*. Obtenido de <https://es.finance.yahoo.com/quote/FB/history?p=FB>

YAHOO FINANZAS. (8 de 2019). *Datos históricos Google*. Obtenido de <https://es.finance.yahoo.com/quote/GOOG/history?p=GOOG>

YAHOO FINANZAS. (8 de 2019). *Datos históricos Netflix*. Obtenido de <https://es.finance.yahoo.com/quote/NFLX/history?p=NFLX>

Apéndices

Apéndice A. Script en R

```

#Librerías
library(ggplot2)
library(dplyr)
library(forecast)
library(tseries)
library(fBasics)
library(mFilter)
library(aTSA)
library(FinTS)
library(rugarch)

#####
##### Contexto #####
#####

#Serie de tiempo puntaje del S&P500
SYP <- faang2[,7]
SYP500 = ts (SYP, start = c(2014.5), frequency = 252)
autoplot(SYP500) +
  xlab ("") +
  ylab("Puntos")
#PIB por país y FAANG
pibyfaang$PAIS <- factor(pibyfaang$PAIS, levels =
c("EE.UU", "CHINA", "JAPON", "ALEMANIA", "FAANG",
"UK", "FRANCIA", "INDIA", "ITALIA", "BRASIL"))
ggplot (data=pibyfaang, aes(x=PAIS,y=PIB)) +
  geom_bar(stat="identity", fill="red", colour="black") +
  xlab ("") +
  ylab("PIB")
#Rentabilidad
ggplot(PRUEBA, aes(x = FECHA, y = RENTABILIDAD, colour = EMPRESA)) +
  geom_line(aes(color = EMPRESA), size = 1) +
  xlab ("") +
  ylab("Rentabilidad %")

```

```
#####
##### SERIES HASTA 31 DE AGOSTO #####
#####
```

```
F0 <- faang1[,2]
AM0 <- faang1[,3]
APP0 <- faang1[,4]
NET0 <- faang1[,5]
GOO0 <- faang1[,6]
```

```
#Transformar vector a serie de tiempo
FACEBOOK0 = ts (F0,start = c(2014.5), frequency = 252)
AMAZON0 = ts (AM0, start = c(2014.5), frequency = 252)
APPLE0 = ts (APP0, start = c(2014.5), frequency = 252)
NETFLIX0 = ts (NET0, start = c(2014.5), frequency = 252)
GOOGLE0 = ts (GOO0, start = c(2014.5), frequency = 252)
```

```
#####
##### SERIES A TRABAJAR: HASTA 7 DE MAYO DE 2019 #
#####
```

```
#Transformar vector a serie de tiempo
```

```
F1 <- faang2[,2]
AM1 <- faang2[,3]
APP1 <- faang2[,4]
NET1 <- faang2[,5]
GOO1 <- faang2[,6]
```

```
AMAZON1 = ts (AM1, start = c(2014.5), frequency = 252)
APPLE1 = ts (APP1, start = c(2014.5), frequency = 252)
NETFLIX1 = ts (NET1, start = c(2014.5), frequency = 252)
GOOGLE1 = ts (GOO1, start = c(2014.5), frequency = 252)
Facebook1 = ts (F1, start = c(2014.5), frequency = 252)
```

```
#####GRAFICOS DE LAS SERIES CON LAS FECHAS CRITICAS DE LA GUERRA
COMERCIAL#####
```

```
autoplot(Facebook1) +
  xlab ("") +
  ylab("Cotización (US$)") +
  geom_vline(xintercept=c(2018.3,2018.4,2018.5,2018.7,2018.8,2018.9,2018.12), color="red",
  linetype = 3)
```

```
summary(Facebook1)
```

```
autoplot(AMAZON1) +
  xlab("") +
  ylab("Cotización (US$)") +
  geom_vline(xintercept=c(2018.3,2018.4,2018.5,2018.7,2018.8,2018.9,2018.12), color="red",
  linetype = 3)
summary(AMAZON1)
```

```
autoplot(APPLE1) +
  xlab("") +
  ylab("Cotización (US$)") +
  geom_vline(xintercept=c(2018.3,2018.4,2018.5,2018.7,2018.8,2018.9,2018.12), color="red",
  linetype = 3)
summary(APPLE1)
```

```
autoplot(NETFLIX1) +
  xlab("") +
  ylab("Cotización (US$)") +
  geom_vline(xintercept=c(2018.3,2018.4,2018.5,2018.7,2018.8,2018.9,2018.12), color="red",
  linetype = 3)
summary(NETFLIX1)
```

```
autoplot(GOOGLE1) +
  xlab("") +
  ylab("Cotización (US$)") +
  geom_vline(xintercept=c(2018.3,2018.4,2018.5,2018.7,2018.8,2018.9,2018.12), color="red",
  linetype = 3)
summary(GOOGLE1)
```

```
#####
##### ANÁLISIS CLÁSICO #####
#####
```

```
###Descomposición (mstl de la libreria forecast)#####
```

```
mstl(Facebook1) %>% autoplot(facet=TRUE) #Sin transformaci?n de datos (lambda=0)
mstl(Facebook1, lambda='auto') %>% autoplot(facet=TRUE) # transformacion de datos
mstl(AMAZON1) %>% autoplot(facet=TRUE) #Sin transformaci?n de datos (lambda=0)
mstl(AMAZON1, lambda='auto') %>% autoplot(facet=TRUE) # transformacion de datos
mstl(APPLE1) %>% autoplot(facet=TRUE) #Sin transformaci?n de datos (lambda=0)
```

```
mstl(APPLE1, lambda='auto') %>% autoplot(facet=TRUE) # transformacion de datos
mstl(NETFLIX1) %>% autoplot(facet=TRUE) #Sin transformaci?n de datos (lambda=0)
mstl(NETFLIX1, lambda='auto') %>% autoplot(facet=TRUE) # transformacion de datos
mstl(GOOGLE1) %>% autoplot(facet=TRUE) #Sin transformaci?n de datos (lambda=0)
mstl(GOOGLE1, lambda='auto') %>% autoplot(facet=TRUE) # transformacion de datos
```

##MODELO HOLT-WINTERS##

#Facebook#

```
Facebook2 <- holt(Facebook1, h=30, damped = T, level= 95, fan=F, initial="optimal", alpha =
NULL, beta = NULL, gamma = NULL, phi = NULL, exponential=T )
autoplot(Facebook2) +
  autolayer(Facebook2, series="Pronóstico", PI=F) +
  xlab("") + ylab("Cotización (US$)") +
  guides(colour=guide_legend(title="Forecast"))
summary(Facebook2)
```

#AMAZON#

```
AMAZON2 <- holt(AMAZON1, h=30, damped = T, level= 95, fan=F, initial="optimal", alpha =
NULL, beta = NULL, gamma = NULL, phi = NULL, exponential=T )
autoplot(AMAZON2) +
  autolayer(AMAZON2, series="Pronóstico", PI=F) +
  xlab("") + ylab("Cotización (US$)") +
  guides(colour=guide_legend(title="Forecast"))
summary(AMAZON2)
```

#APPLE

```
APPLE2 <- holt(APPLE1, h=30, damped = T, level= 95, fan=F, initial="optimal", alpha = NULL,
beta = NULL, gamma = NULL, phi = NULL, exponential=T )
autoplot(APPLE2) +
  autolayer(APPLE2, series="Pronóstico", PI=F) +
  xlab("") + ylab("Cotización (US$)") +
  guides(colour=guide_legend(title="Forecast"))
summary(APPLE2)
```

#NETFLIX

```
NETFLIX2 <- holt(NETFLIX1, h=30, damped = T, level= 95, fan=F, initial="optimal", alpha =
NULL, beta = NULL, gamma = NULL, phi = NULL, exponential=T )
autoplot(NETFLIX2) +
  autolayer(NETFLIX2, series="Pronóstico", PI=F) +
  xlab("") + ylab("Cotización (US$)") +
```

```

    guides(colour=guide_legend(title="Forecast"))
summary(NETFLIX2)

```

```

#GOOGLE

```

```

GOOGLE2 <- holt(GOOGLE1, h=30, damped = T, level= 95, fan=F, initial="optimal", alpha =
NULL, beta = NULL, gamma = NULL, phi = NULL, exponential=T )
autoplot(GOOGLE2) +
  autolayer(GOOGLE2, series="Pronóstico", PI=F) +
  xlab("") + ylab("Cotización (US$)") +
  guides(colour=guide_legend(title="Forecast"))
summary(GOOGLE2)

```

```

#####
##### ARIMA #####
#####

```

```

#####
###Transformación Box-Cox#####
#####

```

```

#Facebook
(lambdaF <- BoxCox.lambda(Facebook1))
autoplot(BoxCox(Facebook1,lambdaF))
#Amazon
(lambdaAm <- BoxCox.lambda(AMAZON1))
autoplot(BoxCox(AMAZON1,lambdaAm))
#Apple
(lambdaAp <- BoxCox.lambda(APPLE1))
autoplot(BoxCox(APPLE1,lambdaAp))
#Netflix
(lambdaN <- BoxCox.lambda(NETFLIX1))
autoplot(BoxCox(NETFLIX1,lambdaN))
#Google
(lambdaG <- BoxCox.lambda(GOOGLE1))
autoplot(BoxCox(GOOGLE1,lambdaG))

```

```

#####
##IDENTIFICACIÓN
#####

```

```

##SERIES COMPLETAS
IFACEBOOK0=log(FACEBOOK0)
a1 <- diff(IFACEBOOK0)

```

```
lAMAZON0=log(AMAZON0)
cc1 <- diff(lAMAZON0)

lAPPLE0=log(APPLE0)
e1 <- diff(lAPPLE0)

lNETFLIX0=log(NETFLIX0)
g1 <- diff(lNETFLIX0)

lGOOGLE0=log(GOOGLE0)
ii1 <- diff(lGOOGLE0)
#####

#Facebook
#1.1 Diferencia del logaritmo
IFacebook1=log(Facebook1)
ggtsdisplay(IFacebook1, plot.type="partial", theme=theme_bw())
a <- diff(IFacebook1)
autoplot(a) +
  xlab("") +
  ylab("Retorno")

b <- adf.test(a, alternative = "stationary")
b

#AMAZON
#1.1 Diferencia del logaritmo
lAMAZON1=log(AMAZON1)
ggtsdisplay(lAMAZON1, plot.type="partial", theme=theme_bw())
cc <- diff(lAMAZON1)
autoplot(cc) +
  xlab("") +
  ylab("Retorno")

library(tseries)
d <- adf.test(c, alternative = "stationary")
d

#APPLE
#1.1 Diferencia del logaritmo
lAPPLE1=log(APPLE1)
```

```
ggtsdisplay(IAPPLE1, plot.type="partial", theme=theme_bw())
e <- diff(IAPPLE1)
autoplot(e) +
  xlab("") +
  ylab("Retorno")
```

```
f <- adf.test(e, alternative = "stationary")
f
```

#NETFLIX

```
#1.1 Diferencia del logaritmo
INETFLIX1=log(NETFLIX1)
ggtsdisplay(INETFLIX1, plot.type="partial", theme=theme_bw())
g <- diff(INETFLIX1)
autoplot(g) +
  xlab("") +
  ylab("Retorno")
```

```
h <- adf.test(g, alternative = "stationary")
h
```

#GOOGLE

```
#1.1 Diferencia del logaritmo
GOO2 = log(GOOGLE1)
ggtsdisplay(GOO2, plot.type="partial", theme=theme_bw())
ii <- diff(GOO2)
autoplot(ii) +
  xlab("") +
  ylab("Retorno")
```

```
j <- adf.test(i, alternative = "stationary")
j
```

```
#####
#2. Estimación
#####
```

#Facebook

```
M0 = arima(a, order = c(2,1,2))
summary (M0)

#Amazon

M1 = arima(cc, order = c(2,1,2))
summary (M1)

#APPLE

M2 <- arima(e, order = c(1,1,2))
summary (M2)

#NETFLIX

M3 <- arima(g, order = c(2,1,2))
summary (M3)

#GOOGLE

M4 = arima(i,order=c(2,1,2))
summary (M4)

#####
#3. DiagnÓstico
#####

##Facebook

#con fBasics
library(fBasics)
tsdiag(M0)
r1=residuals(M0)
cpgram(r1)

Box.test(r1,400,type="L")
shapiro.test(r1)

ggtsdisplay(r1, plot.type="partial", theme=theme_bw())
```

```
#Amazon

#con fBasics
library(fBasics)
tsdiag(M1)
r2=residuals(M1)
cpgram(r2)

Box.test(r2,400,type="L")
shapiro.test(r2)

ggtsdisplay(r2, plot.type="partial", theme=theme_bw())

hist(r2)

#Apple

#con fBasics
library(fBasics)
tsdiag(M2)
r3=residuals(M2)
cpgram(r3)

Box.test(r3,400,type="L")
shapiro.test(r3)

ggtsdisplay(r3, plot.type="partial", theme=theme_bw())

hist(r3)

##Netflix

#con fBasics
library(fBasics)
tsdiag(M3)
r4=residuals(M3)
cpgram(r4)

Box.test(r4,400,type="L")
shapiro.test(r4)
```

```
ggtsdisplay(r4, plot.type="partial", theme=theme_bw())  
hist(r4)
```

```
##Google
```

```
#con fBasics  
library(fBasics)  
tsdiag(M4)  
r5=residuals(M4)  
cpgram(r5)
```

```
Box.test(r5,400,type="L")  
shapiro.test(r5)
```

```
ggtsdisplay(r5, plot.type="partial", theme=theme_bw())
```

```
hist(r5)
```

```
#####
```

```
# 4. PREDICCIÓN RETORNOS ARIMA
```

```
#####
```

```
#Facebook
```

```
#Entrenamiento  
Y1=window(a1,end=2019.5); start(Y1); end(Y1)  
Y1  
y1.19= Arima(Y1,order=c(2,0,2),lambda="auto")  
y1.19  
E1<- forecast::forecast(y1.19, h=84, level = 95)
```

```
E1a<-plot(forecast::forecast(y1.19, h=85, level = 95), ylab = "Retorno")  
lines(cc1, col="red")  
autoplot (E1a, confint=F)
```

```
autoplot(E1) +  
  xlab ("") +
```

```

ylab("Cotizaci?n") +
ggtitle("Entrenamiento") +
theme(plot.title = element_text(hjust = 0.5) +
      theme_bw())

#Con datos no usados
y1.19a = Arima(window(cc1, start = c(2014.5)),model=y1.19)
y1.19a
plot(forecast::forecast(y1.19a,h=30))
EV <- forecast::forecast(y1.19a,h=30)
autoplot(EV) +
  xlab("") +
  ylab("Retorno")

accuracy(y1.19)
accuracy(y1.19a)

#Google

#Entrenamiento
Y5=window(ii1,end=2019.5); start(Y5); end(Y5)
Y5
y5.19= Arima(Y5,order=c(2,1,2),lambda="auto")
y5.19
E5<- forecast::forecast(y5.19,h=84, level = 95)

E5a<-plot(forecast::forecast(y5.19,h=85, level = 95), main="Entrenamiento", ylab =
"Rendimiento")
lines(ii1, col="red")
autoplot (E5a, confint=F)

autoplot(E5) +
  xlab("") +
  ylab("Rendimiento") +
  ggtitle("Entrenamiento") +
  theme(plot.title = element_text(hjust = 0.5) +
        theme_bw())

#Con datos no usados
y5.19a = Arima(window(ii1, start = c(2014.5)),model=y5.19)
y5.19a
plot(forecast::forecast(y5.19a,h=30))
EV5 <- forecast::forecast(y5.19a,h=30)
autoplot(EV5) +

```

```

xlab("") +
ylab("Rendimiento")

accuracy(y5.19)
accuracy(y5.19a)

#####
#####ARCHyGARCH#####
#####

#####
##### PRUEB DE EFECTOS ARCH Y LOS CORRELOGRAMAS FAC y FACP ##
#####

#Facebook

r1a <- (r1)^2

ggtsdisplay(r1a, plot.type="partial", theme=theme_bw())
Box.test(r1a,400,type="L")

#Amazon

r2a <- (r2)^2
Box.test(r2a,400,type="L")
ggtsdisplay(r2a, plot.type="partial", theme=theme_bw())

#Apple

r3a <- (r3)^2
Box.test(r3a,400,type="L")
ggtsdisplay(r3a, plot.type="partial", theme=theme_bw())

#NEtflix

r4a <- (r4)^2
Box.test(r4a,400,type="L")
ggtsdisplay(r4a, plot.type="partial", theme=theme_bw())

#Google

r5a <- (r5)^2
Box.test(r5a,400,type="L")

```

```
ggtsdisplay(r5a, plot.type="partial", theme=theme_bw())
```

```
#####  
##### IDENTIFICACIÓN #####  
#####
```

```
##### AMAZON #####
```

```
arch6=garch(cc,order = c(0,1), trace=F)  
aicarch6=AIC(arch6)
```

```
arch7=garch(cc,order = c(0,3), trace=F)  
aicarch7=AIC(arch7)
```

```
arch8=garch(cc,order = c(0,5), trace=F)  
aicarch8=AIC(arch8)
```

```
arch9=garch(cc,order = c(0,7), trace=F)  
aicarch9=AIC(arch9)
```

```
arch10=garch(cc,order = c(0,10), trace=F)  
aicarch10=AIC(arch10)
```

```
Garch6=garch(c,order = c(1,1), trace=F)  
Gaicarch6=AIC(Garch6)
```

```
Garch7=garch(cc,order = c(1,2), trace=F)  
Gaicarch7=AIC(Garch7)
```

```
Garch8=garch(cc,order = c(2,2), trace=F)  
Gaicarch8=AIC(Garch8)
```

```
Garch9=garch(cc,order = c(5,1), trace=F)  
Gaicarch9=AIC(Garch9)
```

```
Garch10=garch(cc,order = c(9,1), trace=F)  
Gaicarch10=AIC(Garch10)
```

```
#####
```

```
##### APPLE #####
```

```
arch11=garch(e,order = c(0,1), trace=F)  
aicarch11=AIC(arch11)
```

arch12=garch(e,order = c(0,3), trace=F)
aicarch12=AIC(arch12)

arch13=garch(e,order = c(0,5), trace=F)
aicarch13=AIC(arch13)

arch14=garch(e,order = c(0,7), trace=F)
aicarch14=AIC(arch14)

arch15=garch(e,order = c(0,10), trace=F)
aicarch15=AIC(arch15)

Garch11=garch(e,order = c(1,1), trace=F)
Gaicarch11=AIC(Garch11)

Garch12=garch(e,order = c(1,2), trace=F)
Gaicarch12=AIC(Garch12)

Garch13=garch(e,order = c(2,2), trace=F)
Gaicarch13=AIC(Garch13)

Garch14=garch(e,order = c(5,1), trace=F)
Gaicarch14=AIC(Garch14)

Garch15=garch(e,order = c(10,1), trace=F)
Gaicarch15=AIC(Garch15)
#####

NETFLIX

Garch16=garch(g,order = c(1,1), trace=F)
Gaicarch16=AIC(Garch16)

Garch17=garch(g,order = c(1,2), trace=F)
Gaicarch17=AIC(Garch17)

Garch18=garch(g,order = c(2,2), trace=F)
Gaicarch18=AIC(Garch18)

Garch19=garch(g,order = c(5,1), trace=F)
Gaicarch19=AIC(Garch19)

Garch20=garch(g,order = c(9,1), trace=F)
Gaicarch20=AIC(Garch20)

arch16=garch(g,order = c(0,1), trace=F)
aicarch16=AIC(arch16)

arch17=garch(g,order = c(0,3), trace=F)
aicarch17=AIC(arch17)

arch18=garch(g,order = c(0,5), trace=F)
aicarch18=AIC(arch18)

arch19=garch(g,order = c(0,7), trace=F)
aicarch19=AIC(arch19)

arch20=garch(g,order = c(0,2), trace=F)
aicarch20=AIC(arch20)

#####

ESTIMACIÓN y DIAGNÓSTICO #####
#####

#Amazon
summary (Garch8)

#Apple
summary (Garch11)

#Netflix
summary (arch17)

PREDICCIÓN #####
#####

#####

```
#Entrenamiento y error de pronóstico
#####

##Amazon##

#Especificar modelo
spec2 = ugarchspec(variance.model = list(model="sGARCH", garchOrder=c(2,2)), mean.model =
list(armaOrder=c(2,2)))
#Estimar modelo.
fit2 = ugarchfit(data = cc1, spec = spec2)
fit2
summary (fit2)
#Entrenamiento
test2=ugarchroll(spec2,cc1, forecast.length = 82, n.start = 1258, refit.every = 1, refit.window =
"moving")
#Reporte VaR
report(test2, type="VaR", VaR.alpha = 0.01, conf.level = 0.95) #Esto ser?a interesante
#Reporte Error de pron?stico
report(test2, type="fpm")
#Distintos gr?ficos
par(mfrow=c(1,2))
plot (test2)
#Predicci?n: Con los valores pronosticados lo pasamos a ggplot para que
#quede m?s bacano
forc2=ugarchforecast(fit2, n.ahead=10)
plot (forc2)

##Risa###
plot(fit2)

##Apple##

#Especificar modelo
spec3 = ugarchspec(variance.model = list(model="sGARCH", garchOrder=c(1,1)), mean.model =
list(armaOrder=c(1,2)))
#Estimar modelo.
fit3 = ugarchfit(data = e1, spec = spec3)
fit3
summary (fit3)
#Entrenamiento
test3=ugarchroll(spec3,e1, forecast.length = 82, n.start = 1258, refit.every = 1, refit.window =
"moving")
#Reporte VaR
report(test3, type="VaR", VaR.alpha = 0.01, conf.level = 0.95) #Esto ser?a interesante
```

```
#Reporte Error de pronóstico
report(test3, type="fpm")
#Distintos gráficos
par(mfrow=c(1,2))
plot (test3)
#Predicción: Con los valores pronosticados lo pasamos a ggplot para que
#quede más bonito
forc3=ugarchforecast(fit3, n.ahead=10)
plot (forc3)

##Risa###
plot(fit3)

##Netflix##

#Especificar modelo
spec4 = ugarchspec(variance.model = list(model="sGARCH", garchOrder=c(3,0)), mean.model =
list(armaOrder=c(2,2)))
#Estimar modelo.
fit4 = ugarchfit(data = g1, spec = spec4)
fit4
summary (fit4)
#Entrenamiento
test4=ugarchroll(spec4,g1, forecast.length = 82, n.start = 1258, refit.every = 1, refit.window =
"moving")
#Reporte VaR
report(test4, type="VaR", VaR.alpha = 0.01, conf.level = 0.95) #Esto sería interesante
#Reporte Error de pronóstico
report(test4, type="fpm")
#Distintos gráficos
par(mfrow=c(1,2))
plot (test4)
#Predicción: Con los valores pronosticados lo pasamos a ggplot para que
#quede más bonito
forc4=ugarchforecast(fit4, n.ahead=10)
plot (forc4)

##Risa###
plot(fit4)

###Pronóstico de precios#####
```

```
#Facebook
```

```
#Entrenamiento
```

```
Y11=window(FACEBOOK0,end=2019.5); start(Y11); end(Y11)
```

```
Y11
```

```
y11.19= Arima(Y11,order=c(2,0,2),lambda="auto")
```

```
y11.19
```

```
E11<- forecast::forecast(y11.19, h=84, level = 95)
```

```
E11a<-plot(forecast::forecast(y11.19, h=85, level = 95), ylab = "Retorno")
```

```
lines(FACEBOOK0, col="red")
```

```
autoplot (E11a, confint=F)
```

```
autoplot(E11) +
```

```
  xlab ("") +
```

```
  ylab("Cotización") +
```

```
  ggtitle("Entrenamiento") +
```

```
  theme(plot.title = element_text(hjust = 0.5) +
```

```
    theme_bw())
```

```
#Con datos no usados
```

```
y11.19a = Arima(window(FACEBOOK0, start = c(2014.5)),model=y11.19)
```

```
y11.19a
```

```
plot(forecast::forecast(y11.19a,h=30))
```

```
EV1 <- forecast::forecast(y11.19a,h=30)
```

```
autoplot(EV1) +
```

```
  xlab ("") +
```

```
  ylab("Cotización") +
```

```
  ggtitle("Predicción") +
```

```
  theme(plot.title = element_text(hjust = 0.5) +
```

```
    theme_bw())
```

```
accuracy(y11.19)
```

```
accuracy(y11.19a)
```

```
##Amazon##
```

```
#Especificar modelo
```

```
spec2 = ugarchspec(variance.model = list(model="sGARCH", garchOrder=c(2,2)), mean.model =  
list(armaOrder=c(2,2)))
```

```
#Estimar modelo.
```

```
fit22 = ugarchfit(data = AMAZON0, spec = spec2)
```

```
fit22
```

```
summary (fit22)
```

```
forc22=ugarchforecast(fit22, n.ahead=10)
```

```
##Apple##
```

```
#Especificar modelo
```

```
spec3 = ugarchspec(variance.model = list(model="sGARCH", garchOrder=c(1,1)), mean.model =  
list(armaOrder=c(1,2)))
```

```
#Estimar modelo.
```

```
fit33 = ugarchfit(data = APPLE0, spec = spec3)
```

```
fit33
```

```
summary (fit33)
```

```
forc33=ugarchforecast(fit33, n.ahead=10)
```

```
##Netflix##
```

```
#Especificar modelo
```

```
spec4 = ugarchspec(variance.model = list(model="sGARCH", garchOrder=c(3,0)), mean.model =  
list(armaOrder=c(2,2)))
```

```
#Estimar modelo.
```

```
fit44 = ugarchfit(data = NETFLIX0, spec = spec4)
```

```
fit44
```

```
summary (fit44)
```

```
forc44=ugarchforecast(fit44, n.ahead=10)
```

```
plot (forc44)
```

```
##Risa###
```

```
plot(fit4)
```

```
#Google
```

```
#Entrenamiento
```

```
Y55=window(GOOGLE0,end=2019.5); start(Y55); end(Y55)
```

```
Y55
```

```
y55.19= Arima(Y55,order=c(2,1,2),lambda="auto")
```

```
y55.19
```

```
E55<- forecast::forecast(y55.19,h=84, level = 95)
```

```
E55a<-plot(forecast::forecast(y55.19,h=85, level = 95), main="Entrenamiento", ylab =
"Rendimiento")
lines(GOOGLE0, col="red")
autoplot (E55a, confint=F)

autoplot(E55) +
  xlab ("") +
  ylab("Rendimiento") +
  ggtitle("Entrenamiento") +
  theme(plot.title = element_text(hjust = 0.5) +
        theme_bw())

#Con datos no usados
y55.19a = Arima(window(GOOGLE0, start = c(2014.5)),model=y55.19)
y55.19a
plot(forecast::forecast(y55.19a,h=30))
EV55 <- forecast::forecast(y55.19a,h=30)
autoplot(EV55) +
  xlab ("") +
  ylab("Rendimiento") +
  ggtitle("Predicción") +
  theme(plot.title = element_text(hjust = 0.5) +
        theme_bw())

accuracy(y55.19)
accuracy(y55.19a)
```