



PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR

FACULTAD DE INGENIERÍA

“MODELO MATEMÁTICO DE EXPORTACIONES PRIMARIAS Y SU IMPACTO
EN EL PIB DEL ECUADOR. PERIODO 2000-2022”

TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE
MÁSTER EN SISTEMAS DE INFORMACIÓN, MENCIÓN DATA SCIENCE

KARLA CARMEN RAMÍREZ SAMANIEGO

TUTOR: MSC. ALFONSO PRADO ALBORNOZ

QUITO, 2022

TABLA DE CONTENIDOS

CAPÍTULO I.....	9
1. DESCRIPCIÓN DEL PROBLEMA	9
1.1 Resumen ejecutivo	9
1.2 Justificación	10
1.3 Planteamiento del problema.....	10
1.4 Contextualización del tema u objeto.....	11
1.5 Objetivos	11
1.5.1 Objetivo General.....	11
1.5.2 Objetivos Específicos	12
CAPÍTULO II.....	13
2. MARCO TEÓRICO	13
2.1 Exportaciones.....	13
2.1.1 Definición de Exportaciones	13
2.1.2 Tipos de exportaciones	13
2.1.3 Impacto de exportaciones primarias en las exportaciones totales del país	15
2.1.4 Efectos Covid-19 en exportaciones de países latinoamericanos.	15
2.2 Análisis de series temporales	16
2.2.1 Serie de tiempo	17
2.2.2 Modelo ARIMA	17
2.2.3 Metodología Box Jenkins	17
2.2.4 Componentes de una serie temporal	18
2.2.5 Notación general (Box Jenkins)	18
2.2.6 Consideraciones generales modelo ARIMA	19
2.3 Supuestos modelo ARIMA	20
2.3.1 Prueba de raíz unitaria	20
2.3.2 Ruido blanco.....	21

2.3.3	Proceso estocástico	21
2.3.4	Estacionariedad.....	21
2.4	Correlogramas.....	21
2.4.1	Función de autocorrelación simple (ACF)	22
2.4.2	Función de autocorrelación parcial (PACF).....	23
2.4.3	Definición de valores p y q con ACF Y PACF	24
2.5	Criterios de Información.....	25
2.5.1	Criterio de Información de Akaike (AIC)	25
2.5.2	Criterio de Información Bayesiano (BIC)	26
2.6	Validación del modelo ARIMA.....	27
2.6.1	Validación Cruzada en series temporales.....	27
2.7	Modelos de regresión múltiple.....	28
2.7.1	Supuestos del modelo	28
2.7.2	Heterocedasticidad.....	28
2.7.3	Autocorrelación	29
2.7.4	Normalidad	29
2.8	Aplicación técnica de regresión en el PIB del Ecuador	30
CAPÍTULO III		31
3.	METODOLOGÍA	31
3.1	Recolección de datos.....	31
3.2	Modelos ARIMA	31
3.2.1	Modelo ARIMA (Petróleo)	31
3.2.2	Modelo ARIMA (Banano).....	44
3.2.3	Modelo ARIMA (Camarón)	58
3.3	Modelo de regresión múltiple para analizar impacto en el PIB	70
3.3.1	Estimación del modelo	71
3.3.2	Supuestos del modelo	72

Distribución normal de varianza	73
3.4 Pronóstico PIB 2022	74
CAPÍTULO IV	77
4. CONCLUSIONES Y RECOMENDACIONES	77
4.1 CONCLUSIONES	77
4.2 RECOMENDACIONES	79
BIBLIOGRAFÍA	81
ANEXOS	84
Anexo 1: Script R Modelos Arima- Petróleo.....	84
Anexo 2: Script R Modelos Arima- Banano.....	89
Anexo 3: Script R Modelos Arima- Camarón	91
Anexo 4: Script R Modelo 4- Modelo Final	98
Anexo 5: Base de datos Mensual-2000-2021	100
Anexo 6: Base de datos Anual-2000-2021	106

ÍNDICE DE TABLAS

Tabla 1 Definición valores p y q con la función ACF y PACF.....	25
Tabla 2 Resultados del test Phillips-Perron.....	32
Tabla 3 Resultados del test Dickey-Fuller.....	33
Tabla 4 Resultados del primer modelo ARIMA de la data petróleo.....	35
Tabla 5 División de los coeficientes del modelo (obtenidos de la tabla 4).....	35
Tabla 6 Resultados de la evaluación de la bondad del primer modelo de la data petróleo.	36
Tabla 7 Resultados de la prueba de Box-Ljung.....	38
Tabla 8 Resultados del segundo modelo ARIMA de la data petróleo.....	38
Tabla 9 Resultados de la evaluación de la bondad del segundo modelo de la data petróleo.	39
Tabla 10 Resultados de la prueba de Box-Ljung.....	40
Tabla 11 Valores de predicción del modelo 1.....	42
Tabla 12 Valores de predicción del modelo 2.....	42
Tabla 13 Resultados de la validación cruzada del modelo 1.....	43
Tabla 14 Resultados de la validación cruzada del modelo 2.....	44
Tabla 15 Resultados del test Phillips-Perron.....	45
Tabla 16 Resultados del test Dickey-Fuller.....	46
Tabla 17 Resultados del primer modelo ARIMA de la data banano.....	49
Tabla 18 División de los coeficientes del modelo (obtenidos de la tabla 17).....	49
Tabla 19 Resultados de la evaluación de la bondad del primer modelo de la data banano	50
Tabla 20 Resultados de la prueba de Box-Ljung.....	51
Tabla 21 Resultados del primer modelo ARIMA de la data banano.....	52
Tabla 22 División de los coeficientes del modelo (obtenidos de la tabla 21).....	53
Tabla 23 Resultados de la evaluación de la bondad del segundo modelo de la data banano.	54
Tabla 24 Resultados de la prueba de Box-Ljung.....	54
Tabla 25 Valores de predicción del Modelo 1.....	56
Tabla 26 Valores de predicción del Modelo 1.....	56
Tabla 27 Resultados de la validación cruzada del modelo 1.....	57
Tabla 28 Resultados de la validación cruzada del modelo 2.....	57

Tabla 29 Resultados del test Dickey-Fuller.....	60
Tabla 30 Resultados del primer modelo ARIMA de la data camarón.....	62
Tabla 31 División de los coeficientes del modelo (obtenidos de la tabla 30)	62
Tabla 32 Resultados de la evaluación de la bondad del primer modelo de la data camarón.	63
Tabla 33 Resultados de la prueba de Box-Ljung.....	64
Tabla 34 Resultados del segundo modelo ARIMA de la data camarón	65
Tabla 35 División de los coeficientes del modelo (obtenidos de la tabla 34)	65
Tabla 36 Resultados de la evaluación de la bondad del segundo modelo de la data camarón.	66
Tabla 37 Resultados de la prueba de Box-Ljung.....	67
Tabla 38 Valores de predicción del Modelo 1	Tabla 39 Valores de predicción del Modelo 2.....
68	68
Tabla 40 Resultados de la validación cruzada del modelo 1	70
Tabla 41 Resultados de la validación cruzada del modelo 2.....	70
Tabla 42 Visualización del modelo de regresión múltiple	71
Tabla 43 Visualización de resultado de autocorrelación	72
Tabla 44 Resultados de la prueba de Heterocedasticidad.....	73
Tabla 45 Resultados de la prueba de Multicolinealidad.....	73
Tabla 46 Resultados de la prueba de Normalidad	74
Tabla 47 Pronóstico al término del año 2022 del petróleo, banano y camarón.....	74
Tabla 48 Visualización de resultados del PIB pronosticado al 2022	75

ÍNDICE DE GRÁFICOS

Gráfico 1 Correlograma ACF	23
Gráfico 2 Correlograma PACF	24
Gráfico 3 Visualización del funcionamiento de la validación cruzada continua en series temporales	28
Gráfico 4 Visualización de la data de petróleo desde el año 2000	32
Gráfico 5 Visualización de la función ACF de la data petróleo	34
Gráfico 6 Visualización de la función PACF de la data petróleo	35
Gráfico 7 Visualización círculos unitarios	36
Gráfico 8 Visualización de residuos del primer modelo de la data petróleo	37
Gráfico 9 Visualización de residuos con la función ACF y PACF	38
Gráfico 10 Visualización círculos unitarios	39
Gráfico 11 Visualización de residuos del segundo modelo de la data petróleo	40
Gráfico 12 Visualización de residuos con la función ACF y PACF	41
Gráfico 13 Visualización de pronósticos del modelo 1 y 2 de la data petróleo	42
Gráfico 14 Visualización de serie original – Petróleo 2019-2022, pronóstico modelo 1 y modelo 2	43
Gráfico 15 Visualización de la data de banano desde el año 2000	45
Gráfico 16 Visualización de la función ACF de la data banano	48
Gráfico 17 Visualización de la función PACF de la data banano	48
Gráfico 18 Visualización círculos unitarios	50
Gráfico 19 Visualización de residuos del primer modelo de la data banano	51
Gráfico 20 Visualización de residuos con la función ACF y PACF	52
Gráfico 21 Visualización círculos unitarios	53
Gráfico 22 Visualización de residuos del segundo modelo de la data banano	54
Gráfico 23 Visualización de residuos con la función ACF y PACF	55
Gráfico 24 Visualización de pronósticos del modelo 1 y 2 de la data banano	56
Gráfico 25 Visualización de serie original – Banano 2019-2022, pronóstico modelo 1 y modelo 2	57
Gráfico 26 Visualización de la data de camarón desde el año 2000	58
Gráfico 27 Resultados del test Phillips-Perron	59
Gráfico 28 Visualización de la función ACF de la data camarón	61
Gráfico 29 Visualización de la función PACF de la data camarón	61

Gráfico 30 Visualización círculos unitarios	63
Gráfico 31 Visualización de residuos del primer modelo de la data camarón	63
Gráfico 32 Visualización de residuos con la función ACF y PACF	64
Gráfico 33 Visualización círculos unitarios	66
Gráfico 34 Visualización de residuos del segundo modelo de la data petróleo	66
Gráfico 35 Visualización de residuos con la función ACF y PACF	67
Gráfico 36 Visualización de pronósticos del modelo 1 y 2 de la data camarón.....	68
Gráfico 37 Visualización de serie original – Camarón 2019-2022, pronóstico modelo 1 y modelo 2	69
Gráfico 38 Visualización de serie temporal del PIB, petróleo, banano y camarón.....	71
Gráfico 39 Evolución del PIB desde el año 2000 con proyección a 2025	75

CAPÍTULO I

1. DESCRIPCIÓN DEL PROBLEMA

1.1 Resumen ejecutivo

Las exportaciones primarias conforman el 80% de las exportaciones totales del país, y es importante el análisis de su comportamiento tras la afectación por pandemia y en cómo se tradujo en la conformación del PIB del país.

Por tanto, la tesis pretende llevar a cabo un análisis enfocado en desarrollar un conjunto de modelos matemáticos que permitan predecir el comportamiento de las exportaciones primarias de los principales productos de exportación del país y su impacto directo en el PIB.

En primera instancia se aplicará técnicas estudiadas de series temporales, con el propósito de entender la volatilidad de cada uno de los productos en el transcurso del tiempo, los cuales conforman gran parte de las exportaciones totales del país y por ende afectan significativamente al producto interno del país (crecimiento del PIB). Finalmente se ejecutará un modelo de regresión, utilizando como variable dependiente al producto interno bruto, mientras que, como variables independientes a los factores de exportación de crudo, camarón y banano, todos expresados en miles de USD.

El proyecto de investigación se limita a construir modelos univariantes para los principales productos de exportación, debido a que se requiere tener una idea de la exportación de cada uno de ellos expresados en miles de dólares FOB, y con eso finalmente cuantificar el impacto en el PIB del Ecuador.

A través de la aplicación de este modelo se probará si efectivamente lo pronosticado en los modelos univariantes ARIMA afecta de manera positiva o negativa en el PIB del Ecuador al finalizar el año 2022, los cuales permitirán establecer un parámetro respecto al crecimiento económico del país dadas las condiciones de producción de cada uno de los productos más relevantes que son de exportación.

Es importante entender que el papel de las exportaciones es vital en lo que concierne al desarrollo económico del Ecuador, de modo que este tipo de análisis resulta útil realizarlo tras haber pasado por una pandemia mundial especialmente para las economías de países latinoamericanos que fueron muy afectados; para las empresas especializadas en la exportación de los principales productos primarios del Ecuador, a quienes resulta

transcendental entender el comportamiento exportador de la misma para así poder hallar oportunidades de crecimiento y tomar medidas en el caso de presentarse riesgos, y para el gobierno en general como una herramienta de planificación a fin de que exista una articulación entre la planificación nacional e institucional tomando en cuenta estos elementos orientadores.

Palabras clave: *exportaciones primarias, PIB, desarrollo económico, divisas, riesgos, regresión, variable dependientes, independientes, series temporales, modelos univariantes, ARIMA.*

1.2 Justificación

El modelo servirá para que el País y específicamente las empresas dedicadas a la actividad de exportación de productos primarios (petróleo, camarón, banano) puedan anticipar movimientos futuros y así adelantarse a los acontecimientos que permitan identificar oportunidades de crecimiento en los sectores estratégicos, mediante el empleo de herramientas estadísticas que validen y habiliten la posibilidad de crear una medición adecuada tanto del comportamiento de los principales productos y como se traducirían en el PIB del Ecuador, lo cual influye de forma importante en las decisiones a tomar.

La actividad exportadora es un promotor del crecimiento en el capitalismo globalizado; tiene la capacidad de fortalecer los ingresos en países tanto desarrollados como en vías de desarrollo. Además, es preciso mencionar que estos últimos países son los que presentan más beneficios a medida que se diversifica su producción, sobre todo al exportarlos a economías basales o bien enfocadas en el sector primario, como es el Ecuador. En este sentido, la realización de intercambios implica la generación de subordinaciones que se manifiestan cuando se compara el crecimiento del PIB entre los países. Lo claro es que los países más desarrollados tienen grandes sectores exportadores en contraste con los emergentes. Ecuador, en este contexto, ha tenido como ingresos en torno a los 20 647 millones de USD por concepto de exportación.

1.3 Planteamiento del problema

La investigación iniciará con la construcción de varios modelos univariantes ARIMA para los principales productos de exportación primaria, y posteriormente se construirá un modelo de regresión con el fin de responder a la siguiente pregunta:

¿Qué tipo de modelo matemático obtenido describe adecuadamente la influencia de las exportaciones de tipo primarias en el producto interno bruto del Ecuador?

Para el Ecuador, las exportaciones de productos primarios son un aspecto estructural de la economía (PIB), de modo que el proyecto de investigación se enfoca en desarrollar un análisis del período 2000-2022 para la determinación de un modelo matemático, ya que tras haber sufrido el impacto de una pandemia la economía ha decreciendo producto de los bajos niveles de productividad e innovación, fenómeno que se evidencia en la mayoría de las economías de la región latinoamericana. Por lo tanto, se vuelve necesario llevar a cabo un pronóstico a futuro, y de qué manera impactará en el crecimiento económico de un país (PIB) al finalizar el año 2022.

1.4 Contextualización del tema u objeto

El objeto de estudio se enfoca en las exportaciones primarias y el PIB del Ecuador, por tanto, contará con un enfoque cuantitativo y se ejecutará con un histórico de datos de las exportaciones y producto interno bruto (PIB) obtenidas de fuentes gubernamentales específicamente del Banco Central del Ecuador.

El presente estudio pretende analizar el sector de las exportaciones primarias, tratando de generar modelos econométricos a través del software R-Studio con las librerías forecast, tseries y ggplot2, etc., con el objetivo de encontrar los mejores modelos matemáticos, con la menor variabilidad, valores residuales normales y sobre todo que se logre obtener un proceso generador de datos estable para cada uno de los productos de exportación de tipo primario (petróleo, banano, camarón) con el fin de ejecutar posteriormente un modelo de regresión que permita medir el impacto en el PIB del Ecuador utilizando como insumo los datos pronosticados con los modelos ARIMA.

1.5 Objetivos

1.5.1 Objetivo General

Desarrollar un modelo matemático que permita medir el impacto de los principales productos primarios de exportación en el PIB del Ecuador, para evitar pérdidas de capital en exportaciones y detectar oportunidades de crecimiento en los sectores estratégicos que permitan fortalecer la economía ecuatoriana.

1.5.2 Objetivos Específicos

- Analizar datos cuantitativos de las exportaciones y PIB del Ecuador desde el año 2000 - 2022.
- Predecir el comportamiento exportador del petróleo, banano y camarón a través de modelos ARIMA
- Pronosticar y evaluar con el modelo encontrado el impacto de las exportaciones primarias en el PIB del Ecuador.

CAPÍTULO II

2. MARCO TEÓRICO

2.1 Exportaciones

2.1.1 Definición de Exportaciones

Según Cimoli (2019) el término de exportación refiere al intercambio de bienes y de servicios que provienen del territorio nacional (o bien de una zona franca), y que cumplen con las disposiciones normativas correspondientes en los países que se encuentran implicados en la transacción; esta salida del producto se produce a cambio del ingreso de divisas.

En otras palabras, la exportación es el tráfico de bienes o bien de servicios que son de un país en particular para que sean utilizados en otro distinto. Por su parte, Toledo (2017) destaca que la salida o tráfico de bienes genera gran cantidad de aspectos de índole fiscal debido a que cualquier bien o producto que se envía más allá de la frontera de una nación se encuentra sometido a leyes y acuerdos comerciales para la entrega de los bienes bajo condiciones específica acorde al país destino.

2.1.2 Tipos de exportaciones

De acuerdo con Rueda (2018) las exportaciones representan la parte fundamental para generar el crecimiento económico de la economía de un país. Esto significa que, en la actualidad es una parte primordial en el desarrollo económico, es así que van según el crecimiento a nivel mundial y sus necesidades, incluyendo en el estudio macroeconómico y estrategias comerciales, por lo que resulta relevante comprender su clasificación con el fin de realizar un acercamiento al tema de comercio internacional. Las exportaciones se clasifican de la siguiente manera:

- **Exportaciones tradicionales:** son aquellos servicios o productos que son exportados con regularidad. Por ejemplo, el petróleo para el caso ecuatoriano.
- **Exportaciones no tradicionales:** son aquellos servicios o productos que se transan con frecuencias menores o esporádicas. Por ejemplo, la mermelada en el caso nacional.
- **Exportaciones restringidas:** son las transacciones que se limitan por normativa institucional del estado por motivos de seguridad.

- **Exportaciones no restringidas:** son las que no presentan limitaciones por parte del Estado para ser transadas, de modo que se llevan a cabo atendiendo a la reglamentación vigente (Rueda, 2018).

También pueden ser clasificadas con base en los siguientes criterios:

- **Por su valor:** cuando es menor a USD 2 000 no se reflejan dentro de la estadística nacional, en contraste con aquellas que superan dicho monto.
- **Por su periodo:** como destaca la normativa nacional, existen exportaciones que son de carácter temporal, como las ferias o consignaciones, y aquellas definitivas.
- **Por su libertad:** constan las exportaciones prohibidas por atentar contra la seguridad de la nación, de su flora o de su fauna. Las restringidas, por su parte, implican el requerimiento de autorización específica. Por último, constan las exportaciones libres, sin restricciones.
- **Por su destino:** las exportaciones pueden ser consideradas con respecto al destino al que son enviadas, que pueden ser bloques comerciales o bien a países de carácter independientes.
- **Por el sector de origen:** según sean producidas en diversos tipos de industrias o sectores económicos, como textiles, exportaciones primarias, tecnología, etc. (Rueda, 2018).

Sin embargo, para el proyecto se hará énfasis en la clasificación de las exportaciones totales del país como las primarias e industrializadas. Esto se describe a continuación:

Exportaciones Primarias: constituyen aproximadamente el 79,8% de las exportaciones totales (Rueda, 2018). Este tipo de exportaciones incluyen los siguientes productos:

- Crudo (petróleo)
- Banana o plátano en distintas variedades
- Variedades de café en grano
- Productos marinos como camarón, atún u otros pescados
- Frutos característicos como el cacao
- Madera y flores

Exportaciones Industrializadas: en este tipo de exportaciones se incorporan los siguientes productos

- Petróleo (derivados)
- Café procesado.
- Cacao elaborado como chocolate u otras presentaciones.
- Harina de pescado o de otros productos marinos.
- Químicos y fármacos
- Manufacturas
- Textiles manufacturados, entre otros.

2.1.3 Impacto de exportaciones primarias en las exportaciones totales del país

En la actualidad, las exportaciones representan un aspecto esencial en la economía de las naciones. De tal forma, cuando se tiene un alto nivel de exportaciones representa un rubro bueno para la economía del país, esto indica que se contará con mayor empleo por la demanda externa. Por ende, cuando hay mayor nivel de trabajo incide en los ingresos de las personas para cubrir sus necesidades, incrementando la actividad económica que se traduce en el crecimiento del producto interno (PIB) (Toledo, 2017).

Debido a que el Ecuador es una economía pequeña, caracterizada por una economía sin innovación y de baja productividad, las exportaciones de productos de tipo primario son la base sobre la que se sostiene, lo que se manifiesta en términos generales en todos los países de la región latinoamericana (Alvarado, 2019). Al ser el rubro (primarias) que ocupa aproximadamente el 80% de las exportaciones totales del país, la importancia radica en el efecto que tienen sobre el empleo, la productividad y, por lo tanto, el crecimiento del producto del Ecuador.

2.1.4 Efectos Covid-19 en exportaciones de países latinoamericanos.

Conforme a las proyecciones que fueron informadas por la Organización Mundial del Comercio (OMC), en Latinoamérica y el Caribe se ha producido una gran reducción del comercio internacional (exportaciones e importaciones), de en torno al 13 % (exp.) y al 22 % (imp.), similares estimaciones se presentan a nivel mundial. Por lo tanto, el

comercio de la región mostró contracciones significativas, especialmente a inicios del año 2020 (Martincus, 2020).

Cabe mencionar que, en un escenario distinto al de la crisis financiera mundial presentada hace diez años, la pandemia del COVID-19 ocasionó un shock negativo sobre el nivel extensivo en la comercialización internacional, particularmente en la Latinoamérica, situación que repercutió en la cantidad de importación y exportación. En cuanto a las exportaciones ecuatorianas se mostró caídas del -0,1% y las importaciones con -21,7%. En países como Perú las exportaciones se contrajeron en -30,1% y las importaciones en Uruguay fueron de -7,6%, esto significa que las operaciones del comercio internacional fueron afectadas por la pandemia (Martincus, 2020).

Según el Ministerio de Producción, Comercio Exterior, Inversiones y Pesca (2020) durante la pandemia las organizaciones de Economía Popular y Solidaria (EPS) y Comercio Justo (CJ) mostraron una reducción en las exportaciones en los meses de enero y agosto. Como consecuencia de la pandemia las empresas exportadoras tuvieron pérdidas económicas por la culminación de contratos, problemas en el transporte que provocó retrasos en los envíos, por ende, no se entrega un producto de calidad, incluso se incrementó los costos de operación porque se tuvieron que adquirir los equipos de bioseguridad.

De igual modo, esta situación surtió efectos en diversos sectores, entre los más afectados fueron la comercialización de flores, pues, perdieron sus cosechas y se cancelaron los contratos; en el sector bananero y panela se presentaron reclamos en la calidad; en la actividad de ventas de cacao y café no mostró muchos efectos y en el sector de exportación de la paja toquilla disminuyó la demanda (Ministerio de Producción, Comercio Exterior, Inversiones y Pesca, 2020).

2.2 Análisis de series temporales

Este análisis corresponde a un conglomerado de técnicas de tipo estadístico que tienen como objetivo estudiar y generar modelos de comportamiento de determinados fenómenos que cambian a medida que transcurre el tiempo, con la finalidad de prever valores futuros (Ramón & López, 2018).

2.2.1 Serie de tiempo

Las series temporales corresponden a un conjunto de datos provenientes de observaciones de variables, lo que se lleva a cabo de forma longitudinal o secuencial a lo largo del tiempo, en particular en observaciones en las que el factor temporal es determinante. Así, los valores que se presentan a modo de serie temporal tienen un vínculo con los periodos de tiempo, de modo que el análisis de estas toma en cuenta como variables tanto al estudio y al tiempo.

De esta manera, las series tienen periodicidad mensual, trimestral, semestral, entre otros, esto acorde al período en el que se obtienen los datos (Marqués, 2018). Por ejemplo, las transacciones que lleva a cabo una organización cada trimestre, el número de accidentes de tránsito que se producen en la semana o bien la cantidad de exportaciones que se realizan año a año en un país.

Cuando se efectúa análisis de series temporales se obtiene las regularidades del comportamiento anterior de la variable, esto significa que se identifica el aspecto que la genera con la finalidad de contar con un conocimiento adecuado en el tiempo. Por último, con el supuesto de que los aspectos estructurales formada por el conjunto de objetos que se encuentran constantes y la predicción del comportamiento a futuro de la variable de estudio (Ramón & López, 2018).

2.2.2 Modelo ARIMA

El modelo ARIMA se trata de una metodología econométrica enfocada en un modelo dinámico debido a que aplica series temporales. Esta metodología fue propuesta en el año 1970 por los estadísticos George Edward Pelham Box y Gwilym Meirion Jenkins, quienes publicaron un libro denominado análisis de series temporales (predicción y control) (Caridad, 2016). Por lo tanto, este modelo combina el término autorregresivo y promedio móvil con el elemento diferenciador (Amaris, Ávila, & Guerrero, 2017).

2.2.3 Metodología Box Jenkins

De acuerdo con Mena y Calo (2020) esta metodología no presupone patrones particulares respecto a los datos de carácter histórico que se pretende pronosticar, por lo que la aplicación es diferente a la mayoría de los métodos, pues, utiliza una perspectiva o enfoque de iteraciones para identificar un modelo que sea adecuado y útil desde el estudio de los datos. El funcionamiento es cuando el modelo seleccionado se ratifica al

contrastarse con los datos concretos históricos con el fin de determinar si los pronostica con precisión. En el caso de que sea un buen modelo, la diferencia entre el modelo elaborado y los datos puntuales históricos deben distribuirse tanto aleatoria como independientemente.

Por lo tanto, esta metodología identifica y estima un modelo estadístico que puede comprenderse como generador de la información de la muestra, es por eso que si se lo usa para prever, se debe presuponer que la serie tiene características constantes a través del tiempo, sobre todo para momentos futuros, haciendo que la previsión se efectúe sobre un fundamento válido que tenga en cuenta la estacionariedad o estabilidad del modelo; o, dicho de otro modo, que la media y la varianza permanezcan constantes a lo largo del periodo (Tobón, 2019).

2.2.4 Componentes de una serie temporal

Según Tobón (2019) las series que son de carácter temporal se enfocan en el supuesto de que cada uno de los valores que presenta la variable en observación se compone de elementos como la tendencia, estacional y aleatoria. Estas se describen de la siguiente manera:


- **Componente tendencia:** Se trata de una modificación a largo plazo que se genera en el nivel medio (media). Se identifica cuando se presenta un movimiento suave de la serie.
- **Componente estacional:** Se enfoca en una serie variable en un tiempo específico. Un ejemplo puede ser las ventas al detalle incrementan durante los dos últimos meses del año. Su contraparte es la desestacionalización porque se mide de forma explícita o elimina los datos.
- **Componente aleatoria:** Se refiere a los resultados de los elementos aleatorios, estos influyen de manera particular dentro de la serie de tiempo.

2.2.5 Notación general (Box Jenkins)

La notación general es un modelo estadístico que se utiliza para las series temporales, el cual fue desarrollado por Box y Jenkins, donde se considera la dependencia entre los datos, pues, la observación de un tiempo determinado se modela según los valores preliminares (Tobón, 2019).

Es un modelo que permite análisis explícito, donde la notación general se denomina de forma genérica como ARIMA (*AutoRegressive Integrated Moving Average*) conformado por tres componentes: AR (autoregresivo), I (integrado) y MA (medias móviles). Con este modelo se detalla el valor de la función lineal de datos preliminares y errores; incluso se tiene un componente cíclico, puesto que tiene los aspectos necesarios para detallar el fenómeno, tal como se muestra a continuación:

$$ARIMA(p, d, q) (P, D, Q)$$



Donde:

p, P: Cantidad de parámetros AR

d, D: Cantidad de diferenciaciones I

q, Q: Cantidad de parámetros MA

- Los modelos autorregresivos AR(p) describen un aspecto específico del proceso que en un tiempo determinado se convierten en predecibles en función de las observaciones preliminares añadiendo un término de error.
- Los modelos de medias móviles MA(q) se tratan de series estacionarias debido a que el valor actual se predice en función del componente aleatorio y en menor nivel con los impulsos preliminares (Tobón, 2019).

Como se menciona en el primer párrafo, cuando las series presentan tendencias seculares y variaciones que son de tipo cíclicas, pueden ser representadas con el modelo mencionado: (p, d, q) (P, D, Q), en donde el primer paréntesis representa la primera tendencia mencionada y el segundo refleja las variaciones de tipo estacional en la serie (Tobón, 2019).

2.2.6 Consideraciones generales modelo ARIMA

A continuación, se describe las consideraciones del modelo:

- Considerar la conceptualización de los supuestos como ruido blanco, estacionariedad, proceso estocástico, entre otros.
- Tomar en cuenta las etapas desde la identificación, estimación, validación y

predicción.

- Cuando se quiere identificar el proceso del modelo de la serie temporal se debe utilizar datos estacionarios (sin tendencias ni fluctuaciones de amplitud).
- Cuando ya se ha identificado el proceso deben estimarse los parámetros de dependencia. Además, la comprobación del modelo idóneo debe analizar los parámetros, residuos, bondad de ajuste y estabilidad.
- Por último, cuando ya se valide el modelo se emplea en la obtención de valores futuros, las predicciones son puntuales e intervalos.

2.3 Supuestos modelo ARIMA

2.3.1 Prueba de raíz unitaria

Según De la Fuente (2017) la prueba de raíz unitaria representa una característica del proceso del modelo ARIMA que evolucionan constantemente y ocasionan dificultades en la inferencia estadística, específicamente en la modelización de las series temporales.

Cabe mencionar que el proceso de tipo estocástico lineal presenta una raíz de carácter unitario cuando el valor es igual a 1, es decir, no es estacionario. Cuando el resto de las raíces están en el círculo unitario, pues, tiene valor absoluto inferior a 1, donde la primera diferencia representa la estacionaria 1. En términos matemáticos, se trata de una ecuación algebraica de grado n , de la cual depende la ecuación diferencial (n -ésimo).

Por su parte, Córdova y Santa María (2021) consideran que la raíz unitaria muestra cuando la serie es estacionaria o no, esto se deduce al momento que al menos exista una raíz estacionaria en el modelo. Para la comprobación de la presencia o no de la raíz unitaria se debe considerar este supuesto con la finalidad de construir modelos de series temporales como ARIMA. Cuando no se cumple este supuesto es necesario transformar mediante diferenciaciones.

2.3.1.1 Prueba Phillips - Perron

La prueba de Phillips-Perron (P-P) se aplica en la comprobación de hipótesis nula de la serie no estacionaria. La hipótesis nula es $\rho=0$ en $y_t = \rho y_{t-1} + u_t$, donde y_t = variable de interés, t = tiempo, ρ = coeficiente y u_t = término de error. Se considera que los datos pueden contar con orden superior de la autocorrelación y se efectúa una corrección no paramétrica (Laurente & Machaca, 2020).

2.3.1.2 Prueba de Dickey - Fuller

A decir de Laurente y Machaca (2020) la prueba de Dickey-Fuller permite identificar la presencia o no de la raíz unitaria (estacionariedad), por lo que se emplea la hipótesis nula, cuando se tiene un modelo simple autorregresivo se considera $y_t = \rho y_{t-1} + u_t$. Es importante tomar en cuenta que cuando se quiere identificar la presencia de estacionariedad o no es necesario aplicar dos o tres pruebas debido a que hay la posibilidad de rechazar la hipótesis cuando existe una, incluso una conclusión equivocada incide en que se presente sesgo cuando se procede a estimar los valores pronosticados.

2.3.2 Ruido blanco

Para Caridad (2016) el ruido blanco se refiere a la sucesión de las variables aleatorias con una constante igual a cero y varianza, siendo, independientes durante el tiempo, es decir, se tiene una covarianza igual a cero.

Por ende, el ruido blanco representa el proceso estocástico sencillo ya que muestra la sucesión de las variables de tipo aleatorio con media igual a cero, con varianza constante como se mencionó y con covarianza nula. Es así que es estacionario cuando se tiene una varianza finita mediante el uso de la función de autocovarianzas (FACV) y autocorrelación (FAC) (Hervás, 2020).

2.3.3 Proceso estocástico

El proceso estocástico se trata de variables aleatorias, estas dependen de un argumento (tiempo). Es estacionario cuando se tiene una media y varianza constante en cualquier período, incluyendo las covarianzas de dos variables están en función del tiempo transcurrido entre las mismas (Caridad, 2016).

2.3.4 Estacionariedad

En la serie temporal, la estacionariedad (varianza finita) depende de los siguientes aspectos:

- Tiene una media constante en función del tiempo.
- Posee una varianza constante (homocedasticidad) en función del tiempo.
- Tiene auto covarianza constante en función del tiempo (Novales, 2016).

2.4 Correlogramas

De acuerdo con Hidalgo (2021) el correlograma representa una herramienta utilizada para comprobar si los datos son aleatorios. Cuando se tienen datos aleatorios se presentan valores absolutos derivados de las autocorrelaciones, las cuales deben ser iguales o cercanas a cero en todas las separaciones que muestran retardos. Por el contrario, cuando no se tienen datos aleatorios se identifican una o más autocorrelaciones significativas.

Esta herramienta se emplea en la fase de identificación de la serie de tiempo (promedio móvil autorregresivo). Además, en caso de datos aleatorios es importante señalar que el valor absoluto debe ser igual o cerca de cero, pues, cuando no se verifica este supuesto ocasiona que no se cuente con conclusiones estadísticas oportunas (Hidalgo, 2021).

Básicamente un correlograma es una representación gráfica de la correlación, empleado con el propósito de validar la aleatoriedad de los datos. Cuando existen relaciones en observaciones contiguas o ruido blanco se deduce que es un modelo adecuado de la serie temporal. Un correlograma considera los siguientes aspectos:

- Función de autocorrelación simple.
- Función de autocorrelación parcial
- Definición de valores.

Para los factores expuestos de un correlograma en párrafos previos se detallan en los siguientes incisos.

2.4.1 Función de autocorrelación simple (ACF)

En el siguiente gráfico (correlograma) se presenta la función ACF:




Gráfico 1 Correlograma ACF

Fuente: (Ríos, et al., 2019)

Para Ríos, et al., (2019) la función ACF presenta las siguientes características:

- Facilita la medición de la relación que tienen dos variables que se encuentran separadas por k cantidad de períodos.
- Permite medir el nivel de correlación lineal entre dos variables que se encuentran en el mismo proceso estocástico.
- Se aplica para conocer el proceso MA (de media móvil).
- El intervalo de confianza es representado por líneas entrecortadas, generalmente se utiliza el 95% de confiabilidad.

2.4.2 Función de autocorrelación parcial (PACF)

En el siguiente gráfico (correlograma) se presenta la función PACF:

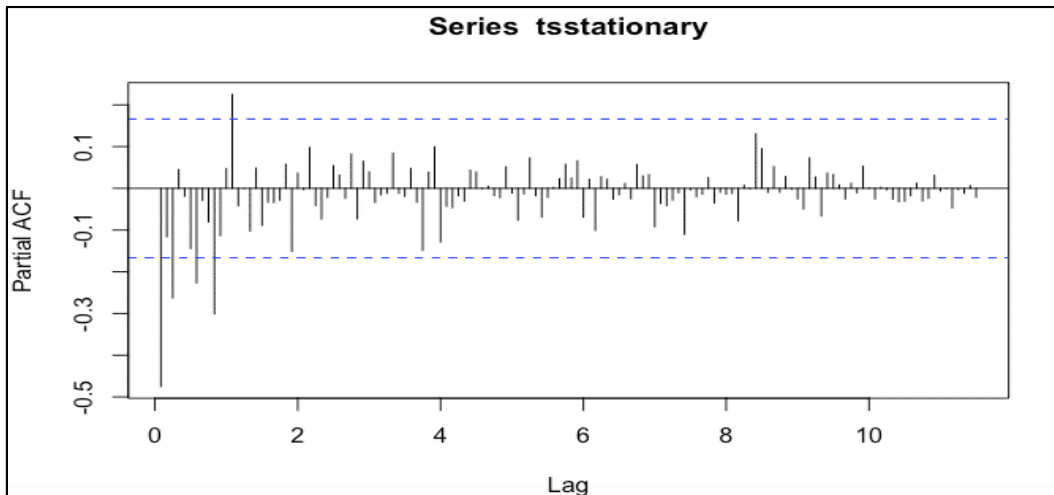


Gráfico 2 Correlograma PACF

Fuente: (Ríos, et al., 2019)

- Permite estimar la relación que se da entre un par de variables que se encuentran separadas por k cantidad períodos. Esto es así en la medida en que no se toma en cuenta la dependencia derivada de los retardos que se encuentran en medio.
- Ayudar a medir la auto relación entre dos variables, eliminando los efectos derivados de las variables intermedias.
- Permite identificar el proceso autoregresivo (AR).
- El intervalo de confianza es representado por líneas entrecortadas, generalmente se utiliza el 95% de confiabilidad (Ríos, et al., 2019).

2.4.3 Definición de valores p y q con ACF Y PACF

La forma de ACF y PACF para definir valores de p y q se debe observar los gráficos con la finalidad de establecer el tipo de modelo a escoger y valores (p, d, q) . A continuación se presenta el resumen según la forma y modelo:

Tabla 1 Definición valores p y q con la función ACF y PACF

Forma	Modelo
Serie exponencial declinando a cero	Modelo (AR): Utiliza función pacf () con la finalidad de conocer el orden del modelo.
Picos positivos y negativos, decayendo a cero	Modelo (AR): Utiliza función pacf () con la finalidad de conocer el orden del modelo.
Uno o más picos en serie y los demás son cero	Modelo (MA): Permite conocer el orden donde el gráfico se transforma en cero.
Luego de varios retrasos la serie va disminuyendo.	Modelo AR y MA
La serie total es cero o cerca de cero	Datos aleatorios
Valores intermedios a intervalos fijos	Se incluye el término AR de estacionalidad
Picos visibles que no llegan a cero	Series temporales no estacionarias

Fuente: (Calvo, 2018)

2.5 Criterios de Información

El criterio de información de Akaike (AIC), así como el criterio de información bayesiano (BIC) son medidas de la calidad relativa de un modelo que representan los aspectos relacionados al ajuste y el número de términos que hacen parte del modelo (Soporte de Minitab, 2021).

Los indicadores hacen posible definir los parámetros de compromiso entre el grado de complejidad y la potencialidad para predecir de que dispone un modelo. Conforme la complejidad se incrementa será más difícil definir las múltiples situaciones que se pueden generar. Cuando el modelo es más simple se toman en cuenta únicamente los componentes más importantes dentro del sistema a fin de reducir el nivel de error en la precisión (Rubalcaba, Modelización y Estadística en Biología, 2016).

2.5.1 Criterio de Información de Akaike (AIC)

Este criterio de información es en la actualidad el que más se usa para el análisis de datos:

$$AIC = 2k - 2 \ln(L)$$

Donde:

k: corresponde a la cantidad de parámetros

L: corresponde al máximo valor que se presenta en la función de verosimilitud (Maximum likelihood).

El AIC realiza la medición de la bondad de ajuste desde la máxima verosimilitud del modelo, y la complejidad considerando el número de parámetros. En relación a la verosimilitud, se establece que se trata de la probabilidad condicionada a k que tienen los datos. Consiste en “la medida inversa de la suma de las distancias euclídeas de cada uno de los datos al modelo” (Rubalcaba, Modelización y Estadística en Biología, 2016). Se debe tomar en cuenta que entre más elevado sea el valor de máxima verosimilitud el modelo se encontrará mejor relacionado con los datos. Esto depende de la intervención de variables como: la forma del modelo (su estructura) y el grado de dispersión de los datos (Rubalcaba, Modelización y Estadística en Biología, 2016).

2.5.2 Criterio de Información Bayesiano (BIC)

El criterio bayesiano de información, BIC (Bayesian Information Criterion) de Schwarz, tienen un alto nivel de similitud al AIC. El BIC se define por:

$$BIC = k \ln(n) - 2 \ln(L)$$

Donde:

k: es el número de parámetros

L: es el valor de máxima verosimilitud

n: es el número de datos

Similar a lo que sucede con AIC se fundamenta en la máxima verosimilitud como método de medida de la bondad de ajuste. Se puede observar que la medida de la complejidad incorpora tanto k como $\ln(n)$. Esto hace posible que se independice el indicador del tamaño muestral, además de penalizar la complejidad que el AIC (Rubalcaba, Modelización y Estadística en Biología, 2016).

El BIC de manera general permite realizar la selección del modelo más abstracto, o del más sencillo para la formulación de predicciones con un menor número de detalles. Por

su parte el AIC analizar un modelo más complejo y pragmático con predicciones más detalladas en función de los datos que se tienen. Sin embargo, el AIC y el BIC generan la simplificación del significado que tiene que el modelo sea complejo. Se debe tomar en cuenta que los dos conciben la complejidad considerando el número de parámetros k (Rubalcaba, Modelización y Estadística en Biología, 2016).

2.6 Validación del modelo ARIMA

En esta etapa se realiza una evaluación de qué tan adecuado son los modelos estimados respecto a los datos, con el objetivo de elegir el mejor, se debe tener en cuenta dos puntos importantes, que a continuación se detallan:

1. Cuando los residuos del modelo se refieren a ruido blanco (comportamiento similar).
2. Cuando se pueden considerar como significativas las estimaciones de los coeficientes del modelo y se ajustan a los supuestos anteriormente detallados como el de estacionalidad.

2.6.1 Validación Cruzada en series temporales

Con el fin de establecer si el modelo es robusto, se utilizan diferentes técnicas una de ellas es la validación cruzada.

La validación cruzada de series temporales, es un procedimiento, en el que existe una serie de grupos de prueba que constan con una observación única. Así, el conjunto para realizar el entrenamiento de las observaciones que sucedieron previo a la observación que compone el conjunto de la prueba. Qué tan precisa sea la previsión se calculará mediante el promedio de los grupos de prueba. Esto se denomina también como la "evaluación sobre un origen de pronóstico continuo", ya que dicho origen de la previsión se moviliza a través del tiempo (Araya, 2015).

El método a utilizarse para la validación cruzada de los modelos de series temporales para los principales productos de exportación primaria (petróleo, banano y camarón) es la validación cruzada continua. Se inicia con un pequeño subconjunto de datos para el entrenamiento, se pronostica para los puntos de datos posteriores y luego se comprueba la precisión de los puntos (Pérez et al., 2015). Esta información se incluye como parte del siguiente grupo de datos de entrenamiento y se pronostican puntos de datos posteriores.

En el gráfico se puede apreciar de mejor manera el proceso relacionado con el funcionamiento de la validación cruzada continua:

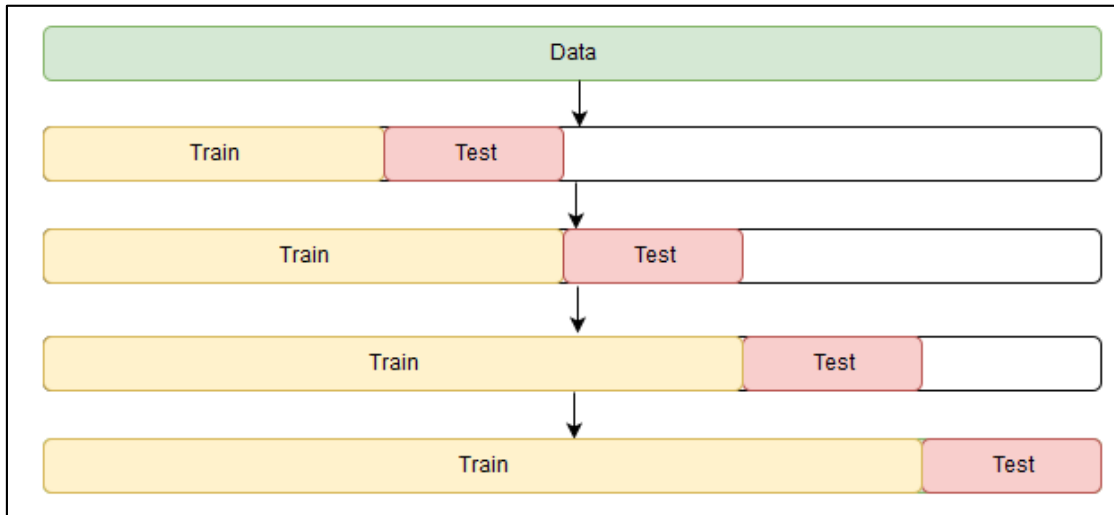


Gráfico 3 Visualización del funcionamiento de la validación cruzada continua en series temporales

Fuente: (Pérez et al., 2015)

2.7 Modelos de regresión múltiple

La regresión múltiple busca explicar cómo se comporta una variable de tipo dependiente mediante el uso de información obtenidas a partir de los valores presente en el conjunto de variables explicativas.

2.7.1 Supuestos del modelo

Multicolinealidad: El término colinealidad (o multicolinealidad) desde el punto de vista estadístico tiene relación con el hecho en el cual dos o más variables de origen explicativo tienen un alto grado de similitud, por lo que se dificulta realizar la medición de los efectos individuales sobre la variable explicada. Generalmente esta situación se presenta de manera frecuente al considerar series temporales y macroeconómicas. (Asturias, Multicolinealidad, Heterocedasticidad y Autocorrelacion, 2017)

2.7.2 Heterocedasticidad

Otro de los supuestos que se comprueban dentro de los modelos de regresión es la homocedasticidad de la perturbación aleatoria. Esto hace referencia a manera similar en la que se distribuyen los términos de la perturbación sobre la recta de regresión, es decir, tienen la misma varianza (varianza constante). En los casos en los cuales la dispersión

de los términos de perturbación no es igual para cada uno de los diferentes valores de se presentan en la variable de tipo explicativa, se habla de heterocedasticidad (Asturias, Multicolinealidad, Heterocedasticidad y Autocorrelacion, 2017).

La heterocedasticidad tiene importantes consecuencias en el método de estimación. Es debido a esto que no se puede construir intervalos de confianza y tampoco efectuar pruebas de hipótesis correctas, ya que al elaborarlas es necesario contar con el valor de error estándar. La dificultad de trabajarla tiene que ver con el hecho de que desarrolla patrones diferentes (Asturias, Multicolinealidad, Heterocedasticidad y Autocorrelacion, 2017)

2.7.3 Autocorrelación

Se presentan situaciones frecuentes cuando se trabaja con datos de series temporales, en las que no se da cumplimiento al supuesto del modelo el cual señala que los términos de perturbación aleatoria se mantienen de manera independiente unos de otros. Por el contrario, se observa una correlación dada por la perturbación de un período y la del período anterior, es importante tomar las acciones para evitar este hecho y así evitar la atenuación del modelo. (Asturias, Multicolinealidad, Heterocedasticidad y Autocorrelacion, 2017)

2.7.4 Normalidad

La Normalidad implica que las variables independientes y dependientes, tengan una distribución normal. (Castro, 2019)

El proyecto en desarrollo se centra en probar la normalidad de los residuos ya que éstos influyen cuando se quiere obtener pronósticos, tomando en cuenta que la normalidad que presentan los errores hace posible determinar por intervalos de confianza, además de para los coeficientes de regresión, para la predicción. Así es posible plantear pruebas de hipótesis en función de los parámetros de que dispone el modelo. En los casos en los cuales no se presenta normalidad los resultados no son fiables, razón por la cual no se los puede considerar como válidos.

A fin de comprobar la existencia o no de normalidad se aplica la prueba de Shapiro-Wilk, misma que plantea una hipótesis nula determinando que la muestra tiene como origen de una distribución normal mientras que por el otro lado se define una hipótesis alternativa en la que se considera a la distribución por fuera de los parámetros de normalidad.

2.8 Aplicación técnica de regresión en el PIB del Ecuador

La economía ecuatoriana ha experimentado una etapa de alto crecimiento económico. Entre los años 2000 al 2009 alcanzó un ritmo promedio de 5,8%, a partir del año 2010 hasta el 2014 fue de 5,2%, siendo esta las tasas más altas desde 1950, sin considerar la temporalidad de 1970 a 1979 cuando fue del 6,6%. Fue desde las décadas de los ochenta y noventa que se presentaron problemas de tipo político tanto a nivel interno como externos los cuales provocaron condiciones como la inestabilidad macroeconómica, y elevadas altas tasas de inflación lo que provocó un proceso de ajuste macroeconómico que desembocó en la dolarización en el año 2000. Es a partir de esta medida que se logró cierta estabilidad, mejorando la productividad del país y la obtención de ingresos (Briones, 2018).

Frente a esta realidad, resulta necesario investigar sobre las causas que han llevado al crecimiento económico del Ecuador enfocándose principalmente en el PIB ya que aporta información relevante respecto el comportamiento de la elasticidad de cada uno de los productos primarios de exportación principales. La razón es que básicamente el modelo de desarrollo ecuatoriano se basa precisamente en el sector primario, es así que, ante cambios en los factores a utilizar, se aplicará técnicas de regresión para medir el impacto utilizando como insumo los valores pronosticados de los principales productos de exportación obtenidos de los modelos ARIMA.

CAPÍTULO III

3. METODOLOGÍA

3.1 Recolección de datos

Se realiza una investigación previa de las fuentes gubernamentales con bancos de datos abiertos, específicamente, del Banco Central Ecuador (BCE) para recopilar la información necesaria y construir los modelos descritos en el proyecto de investigación. Una vez se cuente con la data completa respecto a los productos: petróleo, banano y camarón con el PIB se utilizó el software R.

Para la construcción y ejecución de los modelos univariantes se utilizaron las librerías *forecast*, *urca*, *openxlsx*, *highcharter*, entre otras, en el ambiente R. El proyecto de investigación comenzó con un análisis exploratorio de la serie de cada uno de los productos primarios, lo que permitió verificar si hay tendencias crecientes o decrecientes. Posteriormente, se comenzó con todos los supuestos que se requiere contrastar con este tipo de modelos.

3.2 Modelos ARIMA

3.2.1 Modelo ARIMA (Petróleo)

3.2.1.1 Descripción y visualización de data

Se visualiza la serie general del petróleo crudo expresado en miles de dólares FOB con una frecuencia mensual (12) a partir del año 2000.

En el Gráfico 4 se observa una serie con una tendencia creciente a partir del año 2005, sin embargo, se presenta varios quiebres estructurales en la serie durante el último trimestre del año 2020, en particular entre marzo y abril, debido al inicio de la pandemia mundial (COVID-19). A primera vista la serie no es estacionaria, pero, esto se comprobará a través de la ejecución de varios contrastes.




Gráfico 4 Visualización de la data de petróleo desde el año 2000

Fuente y Elaboración propia.

3.2.1.2 Ejecución de contrastes de raíces unitarias

3.2.1.2.1 Prueba Phillips-Perron

En la Tabla 2 se observan los resultados de éste primer contraste ejecutado, este se utilizó para probar la existencia o no de raíces unitarias, consecuentemente la existencia o no de estacionariedad.

Tabla 2 Resultados del test Phillips-Perron

```
# Phillips-Perron unit root test #
#####
Test regression with intercept and trend

Call:
lm(formula = y ~ y.l1 + trend)

Residuals:
    Min       1Q   Median       3Q      Max
-513.09  -61.63  -10.87   62.58  669.68

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  53.82945   16.30788    3.301  0.0011 **
y.l1         0.91273    0.02504   36.456 <2e-16 ***
trend        0.14689    0.10252    1.433  0.1531
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 117.5 on 265 degrees of freedom
Multiple R-squared:  0.8638,    Adjusted R-squared:  0.8628
F-statistic: 840.6 on 2 and 265 DF, p-value: < 2.2e-16

value of test-statistic, type: Z-tau is: -3.118

      aux. Z statistics
Z-tau-mu      4.4767
Z-tau-beta    1.2598

Critical values for Z statistics:
      1pct      5pct     10pct
critical values -3.995628 -3.427919 -3.137028
```

Fuente y Elaboración propia.

Se establecen las siguientes hipótesis:

- Ho: Existen raíces unitarias.
- H1: No existen raíces unitarias, la serie es estacionaria.

Si el p-value > 0.05 no se rechaza la hipótesis nula, para el caso de la serie correspondiente al petróleo crudo, el p-value < 0.05 . Por tanto, rechazo Ho, y se comprueba que no existen raíces unitarias y se podría afirmar que la serie es estacionaria en todos los niveles de confianza mostrados en el test (90%, 95%, 99%).

3.2.1.2.2 Prueba Dickey Fuller

Se ejecuta un segundo y última prueba para ratificar si la serie es o no estacionaria, a continuación, en la Tabla 3, se adjuntan los resultados.

Tabla 3 Resultados del test Dickey-Fuller

```
Augmented Dickey-Fuller Test
data: log(tsdata_petroleo)
Dickey-Fuller = -3.5863, Lag order = 0, p-value = 0.0349
alternative hypothesis: stationary
```

Fuente y Elaboración propia.

Para las siguientes hipótesis:

- Ho: Existen raíces unitarias.
- H1: No existen raíces unitarias, la serie es estacionaria.

El valor $p < 0.05$ con lo cual se ratifica que de la serie correspondiente al petróleo si es estacionaria, pues, se rechaza la hipótesis nula. En conclusión, tras haber ejecutado dos tipos de contrastes se comprueba que la serie no presenta raíces unitarias, es posible probar que la serie es de tipo estacionario. Por lo tanto, no es necesario determinar las veces en las que se tiene diferenciar una serie, ya que ésta es estacionaria.

3.2.1.3 Construcción Modelos ARIMA

El hecho de identificar el mejor modelo significa utilizar la información de la serie temporal correspondiente al objeto de estudio (petróleo) para proponer un conjunto pequeño de posibles modelos, que dispongan de muchas posibilidades de ajuste a los

datos. Es por ello que deben ser encontrados los valores más adecuados (p, d, q), como se explica en la metodología Box-Jenkins.

Es preciso indicar que, si la serie no ha sido estacionaria, como primer paso se tendría que transformar en una serie de ese tipo a través una diferenciación de orden d antes de iniciar con la ejecución de los modelos.

Una vez que se ha probado que la serie es de tipo estacionario como es el petróleo, una estrategia adecuada es el contraste de los correlogramas de la función de autocorrelación simple (ACF) y la función de autocorrelación parcial (ACPF), el cual es un mecanismo que ofrece una guía para el desarrollo del modelo orientativo, esto con el fin de identificar cuantos autoregresores y medias móviles deberían emplearse en los modelos ARIMA (p, d, q).

La función ACF permite identificar el mecanismo MA en un modelo ARIMA, en el Gráfico 5 se observa líneas que están dentro y fuera de las bandas, se hace énfasis en los que están fuera, determinando que los componentes de medias móviles (MA) que se podría proceder a construir el conjunto de modelos ARIMA es con una (1) media móvil tomando en cuenta a la línea que más sobresale de las bandas.




Gráfico 5 Visualización de la función ACF de la data petróleo

Fuente y Elaboración propia.

Por otro lado, la función PACF permite determinar valores del proceso autoregresivo (AR), en el Gráfico 6 se aprecia líneas que están dentro y fuera de las bandas al igual que en la función ACF, se hace énfasis en los que están fuera, determinando el número de

componentes del proceso autoregresivo (AR) con los que se podría proceder a construir el conjunto de modelos ARIMA es con 1 o ningún autoregresor, tomando en cuenta a la línea que más sobresale de las bandas.




Gráfico 6 Visualización de la función PACF de la data petróleo

Fuente y Elaboración propia.

De acuerdo a los correlogramas analizados tanto ACF como PACF se ejecutó dos tipos de modelos de diferente orden, esto para establecer el mejor modelo ARIMA para la serie temporal correspondiente a uno de los productos, el petróleo:

- Modelo 1: (1,0,1)
- Modelo 2: (0,1,1)

3.2.1.4 Ejecución Modelo 1: ARIMA (1,0,1)

Tabla 4 Resultados del primer modelo ARIMA de la data petróleo

```

Series: .
ARIMA(1,0,1) with non-zero mean

Coefficients:
      ar1      ma1      mean
      0.9638  -0.2567  578.7106
s.e.   0.0169   0.0602  130.3003

sigma^2 estimated as 13111:  log likelihood=-1656.48
AIC=3320.96  AICC=3321.11  BIC=3335.33
    
```

Fuente y Elaboración propia.

Tabla 5 División de los coeficientes del modelo (obtenidos de la tabla 4)

```

> 0.9638/0.0169
[1] 57.02959
> 0.2567/0.0602
[1] 4.26412
> 578.7106/130.3003
[1] 4.44136

```

Fuente y Elaboración propia.

Se evaluó la significancia de los coeficientes correspondientes a los modelos, siendo, éstos mayor que 2, por ende, el modelo ejecutado si es significativo.

A continuación, se aprecia en el Gráfico 7 círculos unitarios con el propósito de evaluar la raíz unitaria de la media móvil utilizado. Donde se puede comprobar que todos los puntos están dentro del círculo unitario, es así que se entiende que el proceso generador de datos es estable (PGD).




Gráfico 7 Visualización círculos unitarios

Fuente y Elaboración propia.

3.2.1.4.1 Evaluación de la Bondad del Modelo

Los resultados de la evaluación de la bondad el modelo se aprecia en la Tabla 6:

Tabla 6 Resultados de la evaluación de la bondad del primer modelo de la data petróleo.

```

> accuracy(modelo_estimado1)
      ME      RMSE      MAE      MPE      MAPE      MASE
Training set 3.445674 113.8623 79.74105 -5.414051 17.12275 0.4008978
      ACF1
Training set -0.01343036

```

Fuente y Elaboración propia.

Para la evaluación de los distintos modelos a desarrollarse durante el proyecto, se centrará en la interpretación del MAPE también conocido como “Error porcentual absoluto medio” ya que constituye un indicador que da cuenta de cómo se desempeña la previsión del tamaño del error absoluto en porcentajes. El que se estime un error en porcentajes lo vuelve un indicador usado regularmente por los profesionales estadistas, ya que permite una interpretación sencilla.

En el caso del primer modelo desarrollado para el petróleo, el MAPE corresponde al 17.12% por tanto es bueno, ya que el error del pronóstico sería menor al 20% en promedio, entendiendo la volatilidad del precio del petróleo y los quiebres estructurales presentes en la serie debido a factores exógenos como pandemia.

3.2.1.4.2 Evaluación de residuos:




Gráfico 8 Visualización de residuos del primer modelo de la data petróleo

Fuente y Elaboración propia.

En el Gráfico 8 aparentemente la mayoría de residuos están centrados, pero no se puede afirmar, por tanto, se procede a ejecutar el Box.Test, planteándose las siguientes hipótesis

- H_0 : Residuos independientes
- H_1 : Los residuos no son independientes

Teniendo como regla lo siguiente: si el P-value < 0.05 Rechazo H_0 .

Tabla 7 Resultados de la prueba de Box-Ljung

```
Box-Ljung test
data: modelo_estimado1$residuals
X-squared = 0.049064, df = 1, p-value = 0.8247
```

Fuente y Elaboración propia.

En este caso (Tabla 7) no se rechaza H_0 por tanto los residuos son independientes, es decir, no presentan autocorrelación ($0.8247 > 0.05$).

3.2.1.4.3 Evaluación de residuos mediante la función de autocorrelación simple y parcial




Gráfico 9 Visualización de residuos con la función ACF y PACF

Fuente y Elaboración propia.

Las barras están dentro de las líneas segmentadas para ambas funciones (Gráfico 9), esto quiere decir que se ha extraído gran cantidad de información con el modelo, por tanto, el modelo ha sido útil para replicar la serie en estudio asumiendo que el precio del crudo del petróleo es bastante volátil y siempre se ve afectado por factores exógenos, como fue el fenómeno de la pandemia.

3.2.1.5 Ejecución Modelo 2: ARIMA (0, 1, 1)

Tabla 8 Resultados del segundo modelo ARIMA de la data petróleo

```
ARIMA(0,1,1)
Coefficients:
      ma1
      -0.2794
s.e.      0.0578

sigma^2 estimated as 13236:  log likelihood=-1651.57
AIC=3307.14   AICc=3307.18   BIC=3314.32
> 0.2794/0.0578
[1] 4.83391
```

Fuente y Elaboración propia.

Se evaluó la significancia del coeficiente correspondiente a la media móvil del modelo, siendo, este mayor que 2 por ende, el modelo si es significativo (Tabla 8).

A continuación, en el Gráfico 10 se tiene círculos unitarios con el propósito de evaluar la raíz unitaria de la media móvil utilizado. Donde se comprueba que todos los puntos están dentro del círculo unitario por tanto se entiende que el proceso generador de datos es estable (PGD).

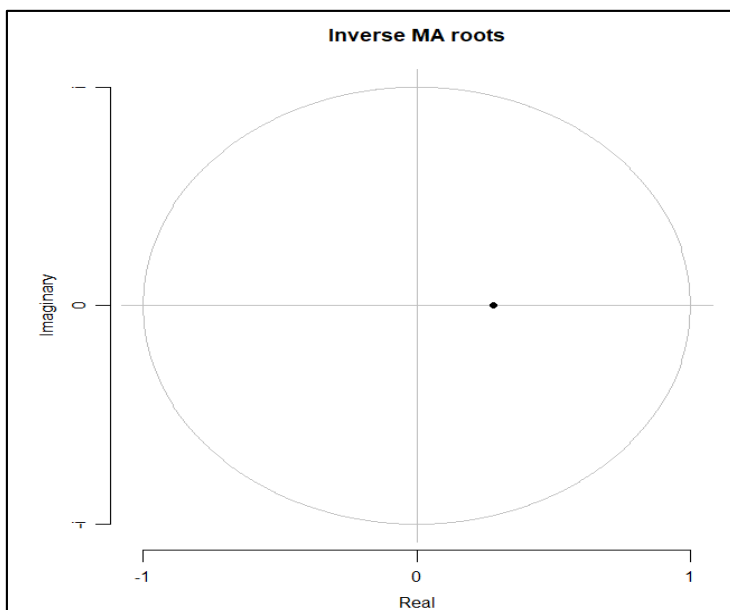


Gráfico 10 Visualización círculos unitarios

Fuente y Elaboración propia.

3.2.1.5.1 Evaluación de la bondad del modelo

En la Tabla 9 se presenta la evaluación de bondad del modelo:

Tabla 9 Resultados de la evaluación de la bondad del segundo modelo de la data petróleo.

```

> accuracy(modelo_petróleo)
      ME      RMSE      MAE
Training set 3.815231 114.6193 79.75764
      MPE      MAPE      MASE
Training set -2.881977 16.38305 0.4009812
      ACF1
Training set -0.008890333

```

Fuente y Elaboración propia.

El MAPE corresponde al 16.38%, por tanto, es bueno, ya que el error del pronóstico sería menor al 20% en promedio, entendiendo, la volatilidad del precio del petróleo y los quiebres estructurales presentes en la serie debido a factores exógenos como pandemia.

3.2.1.5.2 Evaluación de residuos

El Gráfico 11 muestra la evaluación de residuos:




Gráfico 11 Visualización de residuos del segundo modelo de la data petróleo

Fuente y Elaboración propia.

Aparentemente la mayoría de residuos están centrados, pero no se puede afirmar, por tanto, se procede a ejecutar el Box Test, planteándose las siguientes hipótesis:

- Ho: Residuos independientes
- H1: Los residuos no son independientes

Teniendo como regla lo siguiente: si el P-value < 0.05 Rechazo Ho.

Tabla 10 Resultados de la prueba de Box-Ljung

```
Box-Ljung test
data: modelo_petróleo$residuals
X-squared = 0.021499, df = 1, p-value = 0.8834
```

Fuente y Elaboración propia.

En este caso (Tabla 10) no se rechaza H_0 por tanto los residuos son independientes, es decir, no presentan autocorrelación ($0.8834 > 0.05$).

3.2.1.5.3 Evaluación de residuos mediante la función de autocorrelación simple y parcial




Gráfico 12 Visualización de residuos con la función ACF y PACF

Fuente y Elaboración propia.

Las barras están dentro de las líneas segmentadas para ambas funciones (Gráfico 12), esto quiere decir que se ha extraído gran cantidad de información con el modelo, por tanto, el modelo ha sido útil para replicar la serie en estudio asumiendo que el precio del crudo del petróleo es bastante volátil y siempre se ve afectado por factores exógenos, como fue el fenómeno de la pandemia.

3.2.1.6 Pronósticos fuera de la muestra para los dos tipos de modelos ARIMA (petróleo)

Una vez probado que, en primera instancia ambos modelos ARIMA ejecutados son procesos generadores de datos estable (PGD) y que los residuos son independientes para ambos casos, se procede a realizar el pronóstico con el 95% de confianza para los siguientes 7 meses con el objetivo de utilizarlos como insumo en la construcción de un modelo de regresión para medir el impacto del PIB al finalizar el año 2022, es por ello

que se debe compararlos para elegir el mejor modelo que se ajuste a la serie original (Gráfico 13).

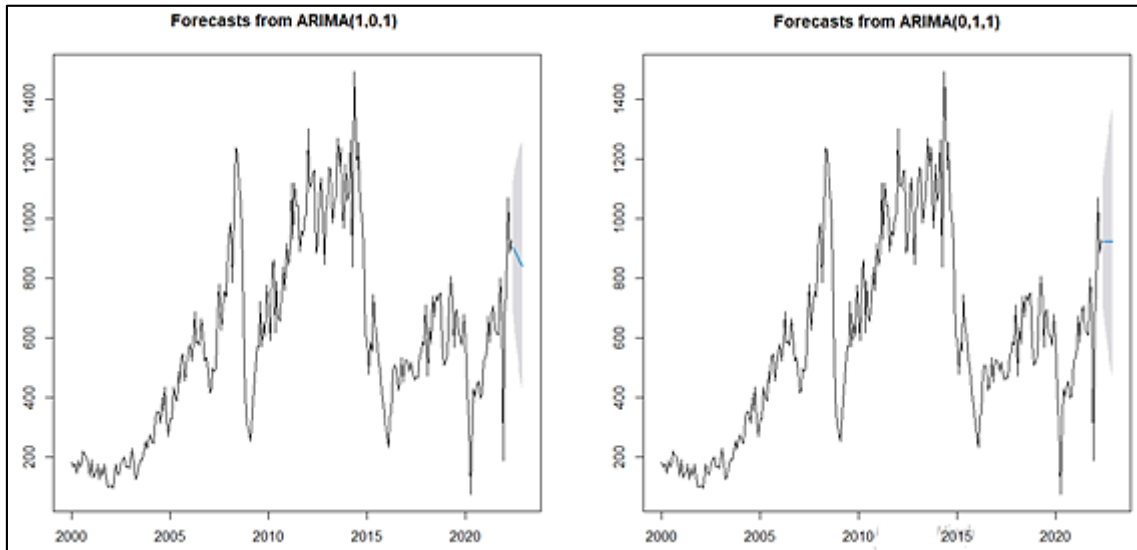


Gráfico 13 Visualización de pronósticos del modelo 1 y 2 de la data petróleo

Fuente y Elaboración propia.

Tabla 11 Valores de predicción del modelo 1

> MODELO1_PETROLEO1				
	Point Forecast	Lo 95	Hi 95	
Jun 2022	904.9744	680.5535	1129.395	
Jul 2022	893.1484	618.2961	1168.001	
Aug 2022	881.7510	567.2187	1196.283	
Sep 2022	870.7668	523.4158	1218.118	
Oct 2022	860.1808	484.9092	1235.452	
Nov 2022	849.9784	450.5180	1249.439	
Dec 2022	840.1458	419.4624	1260.829	

Fuente y Elaboración propia.

Tabla 12 Valores de predicción del modelo 2

> MODELO1_PETROLEO2				
	Point Forecast	Lo 95	Hi 95	
Jun 2022	921.1001	695.6106	1146.590	
Jul 2022	921.1001	643.1713	1199.029	
Aug 2022	921.1001	599.1633	1243.037	
Sep 2022	921.1001	560.4865	1281.714	
Oct 2022	921.1001	525.5737	1316.627	
Nov 2022	921.1001	493.5021	1348.698	
Dec 2022	921.1001	463.6737	1378.527	

Fuente y Elaboración propia.

3.2.1.7 Elección mejor modelo

Se realiza una comparación de los dos modelos (Gráfico 14) para identificar cual modelo se ajusta de mejor manera a la serie original, adicional, se empleará un test de validación cruzada para verificar el mejor modelo y la decisión se complementará con la evaluación de los MAPE anteriormente ejecutados.

Es importante recordar que para la proyección se utiliza la información desde el año 2000, sin embargo, para efectos de una mejor visualización se realiza desde el año 2019, en el

cual se puede observar que las predicciones en las que incurren ambos modelos presentan resultados diferentes. Por tanto, se recurrirá a la aplicación del método de validación cruzada como se explica en el primer párrafo con el objetivo de medir el poder predictivo de cada uno de los modelos ejecutados. Aunque a simple vista la proyección del modelo 2 del petróleo presenta observaciones de carácter lineal, es así que es un buen indicador de que el modelo sea bueno, esto se comprobará con la ejecución de la validación cruzada.

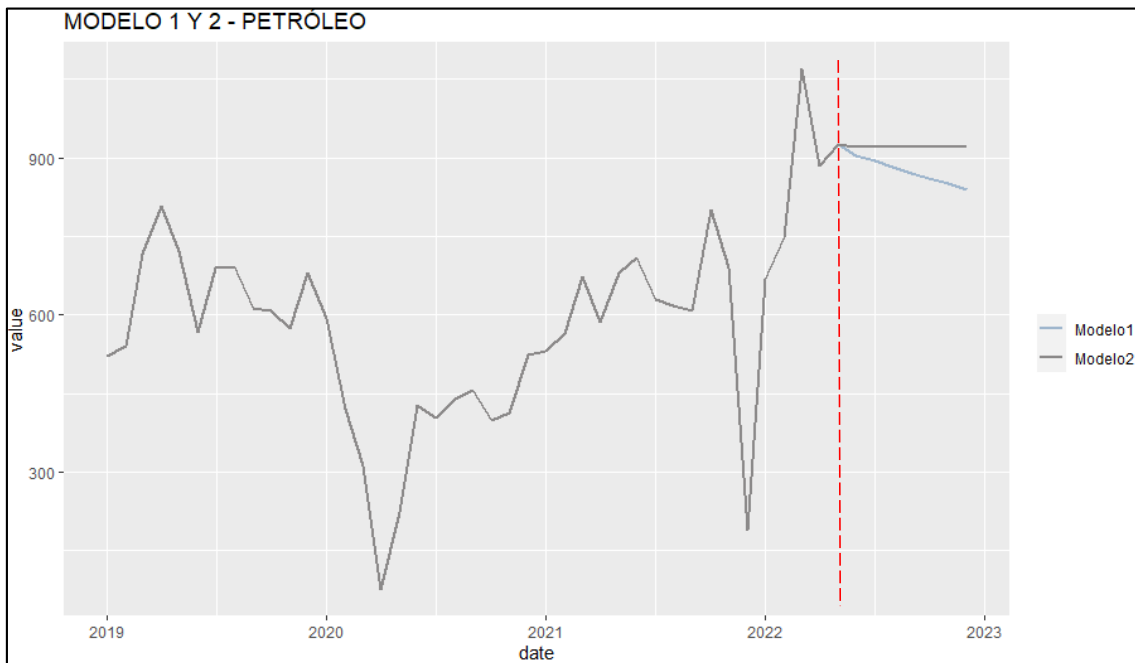


Gráfico 14 Visualización de serie original – Petróleo 2019-2022, pronóstico modelo 1 y modelo 2

Fuente y Elaboración propia.

3.2.1.7.1 Validación cruzada para series temporales

Para la ejecución del test de validación cruzada se ejecutará tomando en cuenta que uno de los parámetros denominados ventana móvil (Window) utilizado en series de tiempo considerará los 3 primeros meses para predecir los 3 siguientes (h), es decir, utilizando el primer trimestre de análisis de cada año con el objetivo de verificar el error de predicción ya que la data con la que se está trabajando se presenta en frecuencia mensual (12).

Modelo 1: (1, 0, 1)

Tabla 13 Resultados de la validación cruzada del modelo 1

```
> Modelo1_PETR <- function(x, h){forecast(Arima(tpdata_petroleo, order=c(1,0,1)), h=h)}
> e <- tscv(tpdata_petroleo,Modelo1_PETR, h=3, window=3)
> mean(e^2, na.rm = TRUE)
[1] 189.3639
```

Fuente y Elaboración propia.

Modelo 2: (0, 1, 1)

Tabla 14 Resultados de la validación cruzada del modelo 2

```
> Modelo2_PETR <- function(x, h){forecast(Arima(tpdata_petroleo, order=c(0,1,1)), h=h)}
> e <- tscv(tpdata_petroleo,Modelo2_PETR, h=3, window=3)
> mean(e^2, na.rm = TRUE)
[1] 206.6865
```

Fuente y Elaboración propia.

Se considera como mejor modelo al que arroje el menor error, para el petróleo se concluye que el mejor modelo es el 1 (Tabla 14), por ende, la predicción arrojada de este modelo se usará como insumo en la construcción del modelo de regresión para medir el impacto del PIB. De hecho, las predicciones que arrojaba el modelo 2 en primera instancia eran lineales, por lo que daban indicio de que no era un buen modelo, es así que fue necesario corroborar esta decisión a través del método de validación cruzada.

3.2.2 Modelo ARIMA (Banano)

3.2.2.1 Descripción y visualización de data

Se visualiza la serie de manera general del banano expresado en miles de dólares FOB con una frecuencia mensual (12) desde 2000 (Gráfico 15).

Se observa una serie con una tendencia de tipo creciente desde el 2000. Adicional a primera vista la serie no es estacionaria, sin embargo, esto se comprobará a través de la ejecución de varios contrastes como se lo realizó con el anterior modelo univariante.




Gráfico 15 Visualización de la data de banano desde el año 2000

Fuente y Elaboración propia.

3.2.2.2 Ejecución de contrastes raíces unitarias

3.2.2.2.1 Prueba de raíz unitaria Phillips Perron

A continuación, se adjunta los resultados de éste primer contraste ejecutado para el banano, servirá para probar la existencia o no de raíces unitarias (Tabla 15):

Tabla 15 Resultados del test Phillips-Perron

```
#####
# Phillips-Perron Unit Root Test #
#####

Test regression with intercept and trend

Call:
lm(formula = y ~ y.l1 + trend)

Residuals:
    Min       1Q   Median       3Q      Max
-72.220 -11.793  -0.873  10.194  79.222

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  66.28552    8.42970   7.863 9.48e-14 ***
y.l1         0.62343    0.04796  12.998 < 2e-16 ***
trend        0.37006    0.04947   7.481 1.09e-12 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 19.19 on 265 degrees of freedom
Multiple R-squared:  0.9429,    Adjusted R-squared:  0.9424
F-statistic: 2186 on 2 and 265 DF,  p-value: < 2.2e-16

value of test-statistic, type: Z-tau is: -7.9755

            aux. Z statistics
Z-tau-mu      7.3589
Z-tau-beta    7.6039

Critical values for Z statistics:
            1pct      5pct      10pct
critical values -3.995628 -3.427919 -3.137028
```

Fuente y Elaboración propia.

Se establecen las siguientes hipótesis:

- Ho: Existen raíces unitarias.
- H1: No existen raíces unitarias, la serie es estacionaria.

Si el p-value > 0.05 no es posible rechazar la hipótesis nula, para el caso de la serie correspondiente al banano, el p-value < 0.05, por tanto rechazo Ho, con esto se comprueba que no se presentan raíces unitarias y se podría sostener que la serie es de tipo estacionario en todos los niveles de confianza mostrados en el test (90%,95%,99%).

3.2.2.2.2 Prueba de raíz unitaria Dickey Fuller

Se ejecuta otro tipo de prueba para establecer si la serie es o no estacionaria, a continuación, se adjuntan los resultados (Tabla 16).

Tabla 16 Resultados del test Dickey-Fuller

```
Augmented Dickey-Fuller Test
data: (tsdata_banano)
Dickey-Fuller = -7.8512, Lag order = 0, p-value = 0.01
alternative hypothesis: stationary
```

Fuente y Elaboración propia.

Para las siguientes hipótesis:

- H_0 : Existen raíces unitarias.
- H_1 : No existen raíces unitarias, la serie es estacionaria.

El p- value es <0.05 con lo cual podemos ratificar que de que la serie correspondiente al banano si es estacionaria, tras haber ejecutado tres tipos de pruebas. Por tanto, en cada una de las pruebas la hipótesis nula de que la serie de tiempo correspondiente al banano tiene raíces unitarias es rechazada, corroborando que se está trabajando con una serie de carácter estacional.

3.2.2.3 Construcción Modelos ARIMA para el Banano

De la misma manera una vez que se ha probado que la serie es estacionaria como es fue en el caso anterior, una estrategia adecuada es contrastar los correlogramas de la función ACF y la función ACPF, con el fin de tener una idea de la formulación del modelo orientativo, es decir, cuantos autoregresores y medias móviles deberían emplearse en los modelos a desarrollarse.

Cabe recalcar que la función ACF permite establecer en el proceso cuantas medias móviles (MA) deberían emplearse en un modelo ARIMA, tomando en cuenta las líneas que sobresalen de las barras. Esto se muestra a continuación, pues, se aprecia líneas que están dentro y fuera de las bandas, se hace énfasis en los que están fuera, determinando que los componentes de medias móviles (MA) que se podría proceder a construir el conjunto de modelos ARIMA es con una (1) media móvil, considerando a la línea que más sobresale de las bandas (Gráfico 16).




Gráfico 16 Visualización de la función ACF de la data banano

Fuente y Elaboración propia.

Por otro lado, la función PACF se usa para identificar los valores de la parte del proceso autoregresivo (AR). En el Gráfico 17 se observa líneas que están dentro y fuera de las bandas al igual que en la función ACF, se hace énfasis en los que están fuera, determinando así que el número de componentes del proceso autoregresivo (AR).




Gráfico 17 Visualización de la función PACF de la data banano

Fuente y Elaboración propia.

Tras analizar conforme a los correlogramas obtenidos tanto de autocorrelación simple (ACF) y autocorrelación parcial (PACF) se ejecutarán dos tipos de modelos de diferente orden. Esto con el fin de determinar el mejor modelo ARIMA para la serie temporal correspondiente al banano. Es importante tomar en cuenta que la serie como se describe

en el párrafo correspondiente a descripción y visualización de la serie, tiene una especie de tendencia creciente por lo que en uno de los modelos se agregará un componente estacional con el fin de verificar si esto influye en la elección de un buen modelo, en cuanto a los correlogramas se visualiza que la ACF crece exponencialmente en el rezago 2, mientras que la PACF presenta valores altos entre el primer y segundo rezago. Por lo tanto, se prueba los siguientes modelos:

- Modelo 1: (2,0,2)
- Modelo 2: (2,0,1) (0,1,1)

3.2.2.4 Ejecución Modelo 1- Banano: ARIMA (2,0,2)

La ejecución del modelo 1 se aprecia en la Tabla 17 y la división de coeficientes en la Tabla 18:

Tabla 17 Resultados del primer modelo ARIMA de la data banano

```

ARIMA(2,0,2) with non-zero mean

Coefficients:
      ar1      ar2      ma1      ma2      mean
      0.2403  0.7302  0.5110  -0.2115  176.6365
s.e.    0.1939  0.1896  0.1981   0.0658   45.8850

sigma^2 estimated as 425.2:  log likelihood=-1194.69
AIC=2401.38  AICC=2401.7  BIC=2422.95

Training set error measures:
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set  0.854372  20.42843  15.1176  -0.9575085  9.271373  0.8032481  -0.01410704

```

Fuente y Elaboración propia.

Tabla 18 División de los coeficientes del modelo (obtenidos de la tabla 17)

```

> 0.2403/0.1939
[1] 1.239299
> 0.7302/0.1896
[1] 3.851266
> 0.5110/0.1981
[1] 2.579505
> 0.2115/0.0658
[1] 3.214286
> 176.6365/45.8850
[1] 3.849548

```

Fuente y Elaboración propia.

Se evaluó la significancia de los coeficientes correspondientes a los modelos, siendo, en la mayoría de casos mayores que 2, por ende, se podría entender que el modelo ejecutado si puede ser significativo. A continuación, en el Gráfico 18 se aprecia círculos unitarios para comprobar que todos los puntos están dentro del círculo unitario y concluir que el proceso generador de datos es estable (PGD).




Gráfico 18 Visualización círculos unitarios

Fuente y Elaboración propia.

Evaluación de la Bondad del Modelo

La evaluación de la bondad del modelo se observa en la Tabla 19.

Tabla 19 Resultados de la evaluación de la bondad del primer modelo de la data banano

```
> accuracy(modelo_estimado1)
      ME      RMSE      MAE      MPE      MAPE
Training set 0.854372 20.42843 15.1176 -0.9575085 9.271373
      MASE      ACF1
Training set 0.8032481 -0.01410704
```

Fuente y Elaboración propia.

El MAPE corresponde al 9.27% por tanto es bueno, ya que el error del pronóstico sería menor al 10% en promedio.

3.2.2.4.1 Evaluación de residuos

La evaluación de los residuos del producto de banano (Gráfico 19) se aprecia de la siguiente manera:




Gráfico 19 Visualización de residuos del primer modelo de la data banano

Fuente y Elaboración propia.

Aparentemente la mayoría de residuos están centrados, pero no se puede afirmar, por tanto, se procede a ejecutar el Box.Test, planteándose las siguientes hipótesis:

- H_0 : Residuos independientes
- H_1 : Los residuos no son independientes

Teniendo como regla lo siguiente: si el P-value < 0.05 Rechazo H_0 .

Tabla 20 Resultados de la prueba de Box-Ljung

```

Box-Ljung test

data: modelo_estimado1$residuals
X-squared = 0.054133, df = 1, p-value = 0.816

```

Fuente y Elaboración propia.

En este caso (Tabla 20) no se rechaza H_0 , por ende, los residuos son independientes, es decir, no presentan autocorrelación ($0.816 > 0.05$).

3.2.2.4.2 Evaluación de residuos mediante la función de autocorrelación simple y parcial

En el Gráfico 20 se exponen los resultados de la evaluación de residuos:




Gráfico 20 Visualización de residuos con la función ACF y PACF

Fuente y Elaboración propia.

La mayoría de las barras están fuera de las líneas segmentadas para ambas funciones, esto quiere decir que, no se ha extraído la cantidad suficiente de información con el modelo, es así que, el modelo no es del todo bueno para replicar la serie de tiempo correspondiente al banano, por lo que es necesario ejecutar un nuevo modelo como se realizará a continuación.

3.2.2.5 Ejecución Modelo 2- Banano: (S)ARIMA (2,0,1) (0,1,1) (12)

Conforme a la teoría analizada especialmente cuando se trabaja con datos de periodicidad inferior al año (en el proyecto de investigación las observaciones son de frecuencia mensual), suele agregarse el factor estacional para la mayoría de modelos en series temporales, convirtiendo un modelo ARIMA en SARIMA. Cabe destacar que dentro de la metodología Box-Jenkins este componente no es de carácter obligatorio.

Por lo tanto, para el modelo 2 correspondiente al banano (Tabla 21), se elabora un modelo SARIMA del siguiente orden (2,0,1) (0,1,1):

Tabla 21 Resultados del segundo modelo ARIMA de la data banano

```

Series: tsdata
ARIMA(2,0,1)(0,1,1)[12] with drift

Coefficients:
      ar1      ar2      ma1      sma1      drift
      1.0033  -0.1067  -0.5505  -0.7948  0.9229
s.e.  0.2598   0.1871   0.2444   0.0452  0.0879

sigma^2 estimated as 236.7:  log likelihood=-1070.75
AIC=2153.51  AICC=2153.84  BIC=2174.8

```

Fuente y Elaboración propia.

Se evaluó la significancia de los coeficientes del modelo (Tabla 22), siendo, este mayor que 2 en la mayoría de ellos como se muestra a continuación, por tanto, el modelo si es significativo.

Tabla 22 División de los coeficientes del modelo (obtenidos de la tabla 21)

```
> 1.0033/0.2598  
[1] 3.861817  
> 0.1067/0.1871  
[1] 0.5702833  
> 0.5505/0.2444  
[1] 2.252455  
> 0.7948/0.0452  
[1] 17.58407  
> 0.9229/0.0879  
[1] 10.49943
```

Fuente y Elaboración propia.

A continuación, en el Gráfico 21 se observan círculos unitarios con el propósito de evaluar las raíces de los autoregresivos y medias móviles. Dónde se puede comprobar que todos los puntos están dentro del círculo unitario por tanto se entiende que el proceso generador de datos es estable (PGD).

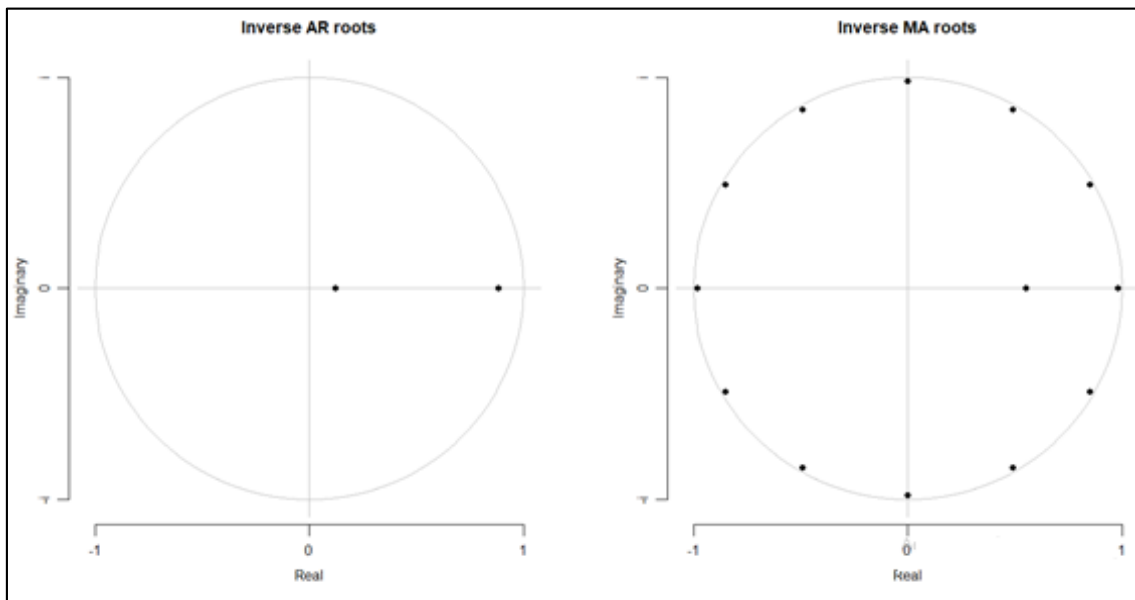


Gráfico 21 Visualización círculos unitarios

Fuente y Elaboración propia.

3.2.2.5.1 Evaluación del accuracy del modelo

En la Tabla 23 se exponen los resultados de la evaluación de la bondad del modelo dos:

Tabla 23 Resultados de la evaluación de la bondad del segundo modelo de la data banano.

```
> accuracy(modelo_banana)
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set -0.3373508 14.89145 10.85013 -1.255299 6.510769 0.5765032 0.001090945
```

Fuente y Elaboración propia.

El MAPE corresponde al 6.51% por tanto es bueno, ya que el error del pronóstico para el caso del banano sería menor al 7% en promedio.

3.2.2.5.2 Evaluación de residuos

El Gráfico 22 muestra la evaluación de los residuos:




Gráfico 22 Visualización de residuos del segundo modelo de la data banano

Fuente y Elaboración propia.

En la gráfica la mayoría de residuos están centrados, esto proporciona una buena señal de que se está construyendo un buen modelo.

Se procede a ejecutar el Box.Test, planteándose las siguientes hipótesis:

- H_0 : Residuos independientes
- H_1 : Los residuos no son independientes

Teniendo como regla lo siguiente: si el P-value < 0.05 Rechazo H_0 .

Tabla 24 Resultados de la prueba de Box-Ljung

```
Box-Ljung test
data: modelo_banana$residuals
X-squared = 0.00032374, df = 1, p-value = 0.9856
```

Fuente y Elaboración propia.

En este caso (Tabla 24) no se rechaza H_0 , pues, los residuos son independientes, es decir, no presentan autocorrelación ($0.9856 > 0.05$).

3.2.2.5.3 Evaluación de residuos mediante la función de autocorrelación simple y parcial

El Gráfico 23 muestra la evaluación de los residuos:

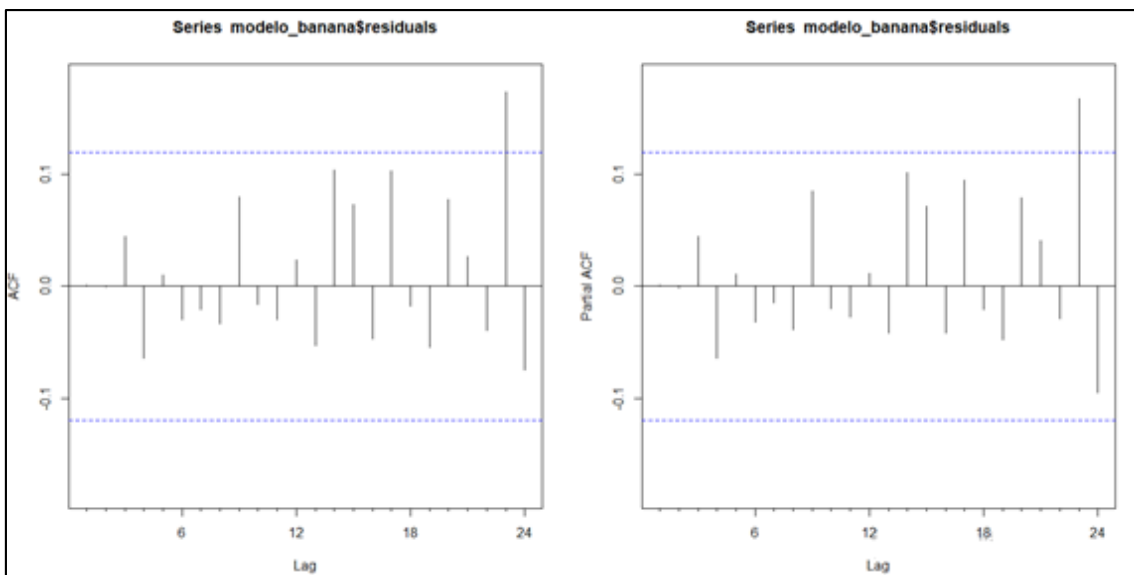


Gráfico 23 Visualización de residuos con la función ACF y PACF

Fuente y Elaboración propia.

La mayoría de barras están dentro de las líneas segmentadas para ambas funciones, esto quiere decir que, se está extrayendo gran cantidad de información con el modelo, es así que, el modelo es útil para replicar la serie en estudio en el caso del banano.

3.2.2.6 Pronósticos fuera de la muestra para los dos tipos de modelos ARIMA (Banano)

Una vez probado que ambos modelos arima ejecutados son relativamente buenos (Gráfico 24) y que los residuos son independientes para ambos casos, se procederá a realizar el pronóstico con el 95% de confianza para los siguientes 7 meses con el objetivo de utilizarlos como insumo en la construcción de un modelo de regresión para medir el impacto del PIB al finalizar el año 2022, es por ello que, se debe compararlos para seleccionar el mejor modelo que se adecúe a la serie original (Tabla 25 y Tabla 26).

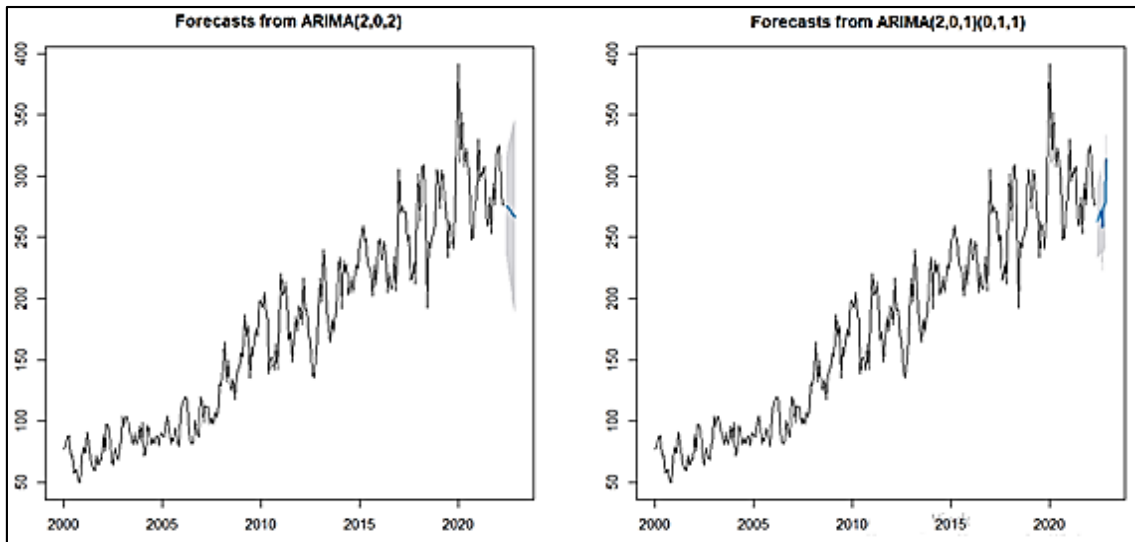


Gráfico 24 Visualización de pronósticos del modelo 1 y 2 de la data banano

Fuente y Elaboración propia.

Tabla 25 Valores de predicción del Modelo 1.

> MODELO_BANANO1				
	Point Forecast	Lo 95	Hi 95	
Jun 2022	275.5283	235.1120	315.9447	
Jul 2022	274.6443	224.0936	325.1950	
Aug 2022	272.3966	214.4840	330.3092	
Sep 2022	271.2110	206.4608	335.9612	
Oct 2022	269.2848	198.9007	339.6690	
Nov 2022	267.9563	192.2894	343.6232	
Dec 2022	266.2306	185.9504	346.5108	

Fuente y Elaboración propia

Tabla 26 Valores de predicción del Modelo 2

> MODELO_BANANO2				
	Point Forecast	Lo 95	Hi 95	
Jun 2022	263.0339	232.8786	293.1893	
Jul 2022	267.2108	234.1074	300.3142	
Aug 2022	271.7991	237.0753	306.5230	
Sep 2022	258.2000	222.3134	294.0867	
Oct 2022	273.9406	237.1790	310.7022	
Nov 2022	277.6635	240.2353	315.0918	
Dec 2022	314.0401	276.1010	351.9791	

Fuente y Elaboración propia.

3.2.2.7 Elección mejor modelo

Se realiza una comparación de los dos modelos para identificar cual modelo se ajusta de mejor manera a la serie original, adicional se empleará un test de validación cruzada para verificar el mejor modelo y la decisión se complementará con la evaluación de los accuracy anteriormente ejecutados.

Es importante mencionar que para la proyección se utiliza la información desde el año 2000, sin embargo, para efectos de una mejor visualización se lo realiza desde el año 2019, en el cual se puede observar que las predicciones en las que incurren ambos modelos presentan resultados diferentes, por tanto, se recurrirá a la aplicación del método de validación cruzada como se explica en el primer párrafo con el objetivo de medir el

poder predictivo de cada uno de los modelos ejecutados.

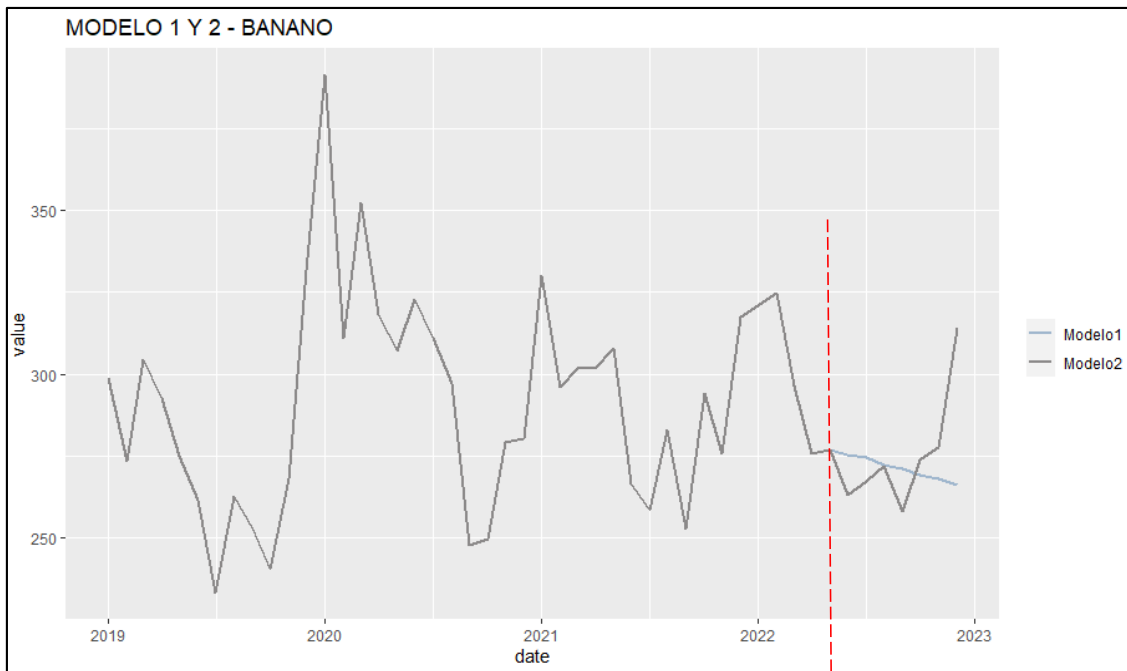


Gráfico 25 Visualización de serie original – Banano 2019-2022, pronóstico modelo 1 y modelo 2

Fuente y Elaboración propia.

3.2.2.7.1 Validación cruzada para series temporales (Banano)

Para la ejecución del test de validación cruzada se ejecutará tomando en cuenta los mismos parámetros que en la serie temporal del petróleo, utilizando el primer trimestre de análisis de cada año con el objetivo de verificar el error de predicción.

Modelo 1: (2, 0, 2)

Tabla 27 Resultados de la validación cruzada del modelo 1

```
> Modelo1_BAN <- function(x, h){forecast(Arima(tsddata_banano, order=c(2,0,2)), h=h)}
>> e <- tsCV(tsddata_banano,Modelo1_BAN, h=3, window=3)
>> mean(e^2, na.rm = TRUE)
[1] 15.92284
```

Fuente y Elaboración propia.

Modelo 2: (2, 0, 1) (0, 1, 1)

Tabla 28 Resultados de la validación cruzada del modelo 2

```
> Modelo2_BAN <- function(x, h){forecast(Arima(tsddata_banano, order=c(2,0,1),seasonal=c(0,1,1)), h=h)}  
> e <- tscv(tsddata_banano,Modelo2_BAN, h=3, window=3)  
> mean(e^2, na.rm = TRUE)/1000  
[1] 14.24177
```

Fuente y Elaboración propia.

Se considera como mejor modelo al que arroje el menor error, para el banano finalmente se concluye que el mejor modelo es el 2 (Tabla 28), por tanto, la predicción arrojada de este modelo se usará como insumo en la construcción del modelo de regresión para medir el impacto del PIB.

3.2.3 Modelo ARIMA (Camarón)

3.2.3.1 Descripción y visualización de data

Se visualiza la serie de manera general sobre la exportación de camarón expresado en miles de dólares FOB con una frecuencia mensual (12) desde el año 2000.

Se observa una serie con una tendencia de tipo creciente a partir del año 2015, a diferencia de lo sucedido con el petróleo crudo y banano. Otra cuestión que es importante mencionar es que durante el primer trimestre del año 2020, en particular entre marzo y abril hubo una ligera disminución, sin embargo, vuelve a repuntar en los últimos años 2021-2022 alcanzando niveles que no han sido registrados con anterioridad en la historia de la actividad exportadora del camarón. La serie aparentemente no es estacionaria, esto se comprobará a través de la ejecución de varios contrastes como se lo realizó con los anteriores modelos univariantes del petróleo y banano.




Gráfico 26 Visualización de la data de camarón desde el año 2000

Fuente y Elaboración propia.

3.2.3.2 Ejecución de contrastes raíces unitarias

3.2.3.2.1 Prueba de raíz unitaria Phillips Perron

A continuación, se adjunta los resultados de éste primer contraste ejecutado para el camarón, el cual servirá para probar la existencia o no de raíces unitarias.

```
# Phillips-Perron Unit Root Test #
#####

Test regression with intercept and trend

Call:
lm(formula = y ~ y.l1 + trend)

Residuals:
    Min       1Q   Median       3Q      Max
-172.316  -8.316   0.887   8.269  94.770

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  7.92350    4.21815   1.878  0.0614 .
y.l1         0.96269    0.02709  35.537 <2e-16 ***
trend        0.09458    0.04717   2.005  0.0460 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 26.81 on 265 degrees of freedom
Multiple R-squared:  0.9631,    Adjusted R-squared:  0.9629
F-statistic: 3463 on 2 and 265 DF,  p-value: < 2.2e-16

Value of test-statistic, type: Z-tau is: 0.3111

      aux. Z statistics
Z-tau-mu      4.6016
Z-tau-beta    0.7848

Critical values for Z statistics:
              1pct      5pct      10pct
critical values -3.995628 -3.427919 -3.137028
```

Gráfico 27 Resultados del test Phillips-Perron

Fuente y Elaboración propia.

Se establecen las siguientes hipótesis:

H₀: Existen raíces unitarias.

H₁: No existen raíces unitarias, la serie es estacionaria.

Si el p-value > 0.05 se acepta hipótesis nula, para este caso (banano), el p-value < 0.05 por tanto se rechaza H₀. Se comprueba que no hay raíces unitarias y se podría afirmar que la serie es estacionaria en todos los niveles de confianza mostrados en el test (90%,95%,99%).

Tras haber ejecutado dos tipos de contrastes se comprueba que la serie en el caso del banano no presenta raíz unitaria por tanto es estacionaria.

3.2.3.2.2 Prueba de raíz unitaria Dickey Fuller

En la Tabla 29, se ejecuta otro tipo de ensayo para identificar si la serie es o no estacionaria, por lo que, se adjuntan los siguientes resultados.

Tabla 29 Resultados del test Dickey-Fuller

```
Augmented Dickey-Fuller Test
data: log(tsddata_camaron)
Dickey-Fuller = -6.4194, Lag order = 0, p-value = 0.01
alternative hypothesis: stationary
```

Fuente y Elaboración propia.

Para las siguientes hipótesis:

Ho: Existen raíces unitarias.

H1: No existen raíces unitarias, la serie es estacionaria.

El p- value es <0.05 con lo cual se ratifica que de que la serie correspondiente al banano si es estacionaria, tras haber ejecutado tres tipos de pruebas.

Por tanto, en cada una de las pruebas no se acepta la hipótesis nula, que sostiene que el tiempo correspondiente al camarón tiene raíces unitarias, se corrobora que se está trabajando con una serie de carácter estacional.

3.2.3.3 Construcción Modelos ARIMA para el Camarón

De la misma manera una vez que se ha probado que es estacionaria como fue en el caso anterior, un adecuado mecanismo nuevamente se basa en cotejar los correlogramas de las funciones como autocorrelación (ACF) y autocorrelación parcial (ACPF). De esta manera se tiene una idea de la formulación del modelo orientativo, es decir, cuantos autoregresores y medias móviles podrían emplearse en los modelos a desarrollarse.

Cabe recalcar que la función ACF se aplica para conocer en el procedimiento de cuantas medias móviles (MA) deberían emplearse en el modelo ARIMA, se hace énfasis en los que están fuera de las bandas.




Gráfico 28 Visualización de la función ACF de la data camarón

Fuente y Elaboración propia.

Por otro lado, la función PACF permite conocer los valores del procedimiento autoregresivo (AR), de la misma manera se considera las que están fuera de las barras.




Gráfico 29 Visualización de la función PACF de la data camarón

Fuente y Elaboración propia.

Tras haber realizado los análisis conforme a los correlogramas obtenidos tanto de autocorrelación simple (ACF) y parcial (PACF) se ejecutaron dos diferentes órdenes, con el fin de determinar el mejor modelo ARIMA para la serie temporal correspondiente al camarón. Se debe tomar en cuenta que la serie, como se describe en el párrafo correspondiente a descripción y visualización, presenta una especie de tendencia por lo tanto se agregó un componente estacional como se lo hizo con el banano. De esta manera se pudo verificar si esto influye en la elección de un buen modelo, en cuanto a los correlogramas se visualiza que la ACF crece exponencialmente en el rezago 1 y 2,

mientras que la PACF presenta valores altos entre el primer y cuarto rezago. Por lo tanto, se probaron los siguientes aspectos:

- Modelo 1: (4,1,1)
- Modelo 2: (4,2,1) (0,0,2)

3.2.3.4 Ejecución Modelo 1- Camarón: ARIMA (4,1,1)

Tabla 30 Resultados del primer modelo ARIMA de la data camarón

```
Series: .
ARIMA(4,1,1)

Coefficients:
      ar1      ar2      ar3      ar4      ma1
    -0.6264  -0.3943  -0.1401  -0.2524  0.4453
s.e.   0.1811   0.0774   0.0793   0.0673   0.1881

sigma^2 estimated as 625.7:  log likelihood=-1240.82
AIC=2493.64  AICC=2493.96  BIC=2515.19

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set 4.016901 24.73354 15.30968 0.602907 12.21045 0.4617356 -0.02423969
```

Fuente y Elaboración propia.

Tabla 31 División de los coeficientes del modelo (obtenidos de la tabla 30)

```
> -0.6264/0.1811
[1] -3.458863
> -0.3943/0.0774
[1] -5.094315
> -0.1401/0.0793
[1] -1.766709
> -0.2524/0.0673
[1] -3.750371
> 0.4453/0.1881
[1] 2.367358
```

Fuente y Elaboración propia.

Las Tablas muestran la evaluación de la significancia de los coeficientes correspondientes a los modelos, siendo en algunos casos mayores que 2 por lo tanto se podría entender que el modelo ejecutado no es del todo significativo. Se complementó con la gráfica de círculos unitarios para comprobar que todos los puntos están dentro y poder concluir que es un proceso generador de datos estable (PGD).




Gráfico 30 Visualización círculos unitarios

Fuente y Elaboración propia.

3.2.3.4.1 Evaluación del Accuracy Modelo

Tabla 32 Resultados de la evaluación de la bondad modelo 1 de la data camarón.

```
> accuracy(modelo_estimado1)
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set 4.016901 24.73354 15.30968 0.602907 12.21045 0.4617356 -0.02423969
```

Fuente y Elaboración propia.

La Tabla presenta el MAPE corresponde al 12.21% por tanto es bueno, ya que el error del pronóstico sería menor al 15% en promedio.

3.2.3.4.2 Evaluación de residuos




Gráfico 31 Visualización de residuos del primer modelo de la data camarón

Fuente y Elaboración propia.

Aparentemente la mayoría de residuos están centrados, pero no se puede afirmar al 100%, por tanto, se procede a ejecutar el Box.Test, planteándose las siguientes hipótesis

Ho: Residuos independientes

H1: Los residuos no son independientes

Teniendo como regla lo siguiente: si el P-value < 0.05 Rechazo Ho.

Tabla 33 Resultados de la prueba de Box-Ljung

Box-Ljung test	
data:	modelo_estimado1\$residuals
X-squared =	0.15982, df = 1, p-value = 0.6893

Fuente y Elaboración propia.

En este caso no se rechaza Ho por tanto los residuos son independientes, es decir, no presentan autocorrelación ($0.6893 > 0.05$).

3.2.3.4.3 Evaluación de residuos mediante la función de autocorrelación simple y parcial




Gráfico 32 Visualización de residuos con la función ACF y PACF

Fuente y Elaboración propia.

Algunas barras están fuera de las líneas segmentadas para ambas funciones, esto quiere decir que no se ha extraído la cantidad suficiente de información con el modelo, por tanto, no es del todo bueno para replicar la serie de tiempo correspondiente al camarón. Es decir, es necesario ejecutar un nuevo modelo como se muestra a continuación con el objetivo de poder realizar una comparación.

3.2.3.5 Ejecución Modelo 2- Camarón: ARIMA (4,2,1)(0,0,2) (12)

Para este último modelo correspondiente al camarón también se agrega un factor estacional, convirtiendo un modelo ARIMA en SARIMA; cabe destacar nuevamente que dentro de la metodología Box-Jenkins este componente no es de carácter obligatorio.

Por lo tanto, para el modelo 2 correspondiente al camarón, se elabora un modelo SARIMA del siguiente orden (4,2,1) (0,0,2), esto se observa a continuación:

Tabla 34 Resultados del modelo 2 ARIMA de la data camarón

```
Series: tsdata
ARIMA(4,2,1)(0,0,2)[12]

Coefficients:
          ar1      ar2      ar3      ar4      ma1      sma1      sma2
-0.4041  -0.5465  -0.2410  -0.3903  -0.8341   0.2338   0.3391
s.e.      0.0684   0.0756   0.0728   0.0631   0.0552   0.0629   0.0749

sigma^2 estimated as 516.8:  log likelihood=-1212.8
AIC=2441.6  AICC=2442.16  BIC=2470.3
```

Fuente y Elaboración propia.

Se evaluó la significancia de los coeficientes del modelo, siendo éste mayor que 2 en cada uno ellos como se muestra a continuación, por tanto el modelo si es significativo, como se puede apreciar en la Tabla.

Tabla 35 División de los coeficientes del modelo (obtenidos de la tabla 34)

```
> 0.4041/0.0684
[1] 5.907895
> 0.5465/0.0756
[1] 7.228836
> 0.2410/0.0728
[1] 3.31044
> 0.3903/0.0631
[1] 6.18542
> 0.8341/0.0552
[1] 15.11051
> 0.2338/0.0629
[1] 3.717011
> 0.3391/0.0749
[1] 4.52737
```

Fuente y Elaboración propia.

A continuación, se agrega un gráfico con círculos unitarios con el propósito de evaluar las raíces de los autoregresivos y medias móviles. Dónde se pudo comprobar que todos los puntos están dentro del círculo unitario, por tanto, se entiende que el proceso generador de datos es estable (PGD).

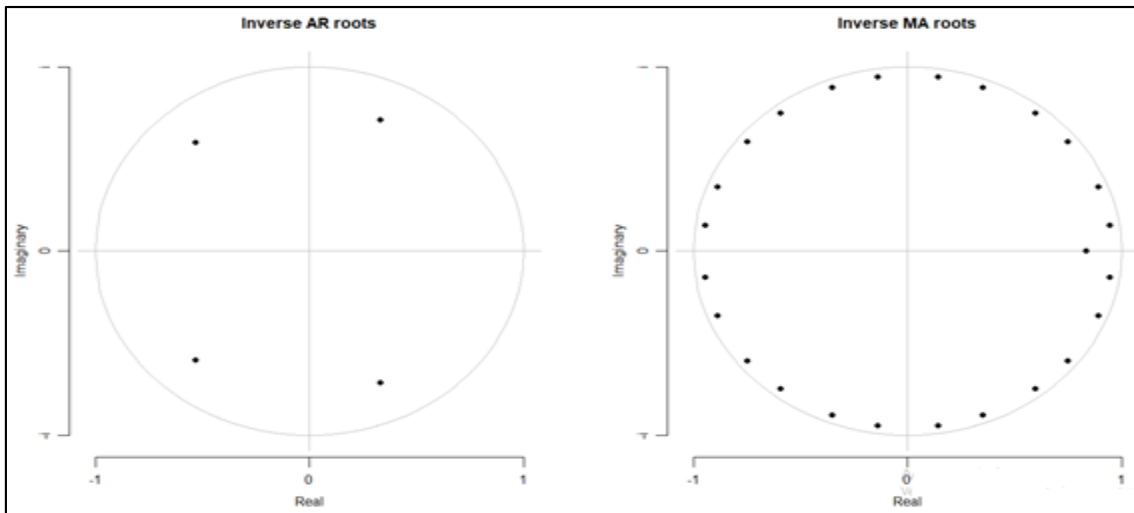


Gráfico 33 Visualización círculos unitarios

Fuente y Elaboración propia.

3.2.3.5.1 Evaluación del accuracy del modelo

Tabla 36 Resultados de evaluación de la bondad del segundo modelo data camarón.

```
> accuracy(modelo_camaron)
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set 1.00828 22.34909 13.99195 -1.151649 11.58792 0.4219933 0.01604689
```

Fuente y Elaboración propia.

El MAPE corresponde al 11.58% por tanto es bueno, ya que el error del pronóstico para el caso del banano sería menor al 12% en promedio.

3.2.3.5.2 Evaluación de residuos




Gráfico 34 Visualización de residuos del segundo modelo de la data petróleo

Fuente y Elaboración propia.

En la gráfica la mayoría de residuos están centrados, esto proporciona una buena señal de que se está construyendo un buen modelo.

Se procede a ejecutar el Box.Test, planteándose las siguientes hipótesis:

Ho: Residuos independientes

H1: Los residuos no son independientes

Teniendo como regla lo siguiente: si el P-value < 0.05 Rechazo Ho.

Tabla 37 Resultados de la prueba de Box-Ljung

```
Box-Ljung test
data: modelo_camaron$residuals
X-squared = 0.070044, df = 1, p-value = 0.7913
```

Fuente y Elaboración propia.

En este caso no se rechaza Ho por tanto los residuos son independientes, es decir, no presentan autocorrelación ($0.7913 > 0.05$)

3.2.3.5.3 Evaluación de residuos mediante de la función de autocorrelación simple y parcial




Gráfico 35 Visualización de residuos con la función ACF y PACF

Fuente y Elaboración propia.

Visualmente las barras están dentro de las líneas segmentadas para ambas funciones, esto quiere decir que se ha extraído gran cantidad de información con el modelo, por tanto, este ha sido útil para replicar la serie correspondiente al camarón.

3.2.3.6 Pronósticos fuera de la muestra para los dos tipos de modelos ARIMA (Camarón)

Una vez ejecutado 2 modelos de diferente orden se precedió a realizar los respectivos pronósticos ya que además los residuos son independientes para ambos casos. Se hizo una predicción con el 95% de confianza para los siguientes 7 meses con el objetivo de utilizarlos como insumo en la construcción de un modelo de regresión para medir el impacto del PIB al finalizar el año 2022, es por ello que fueron comparados para elegir el que mejor se ajuste a la serie original.

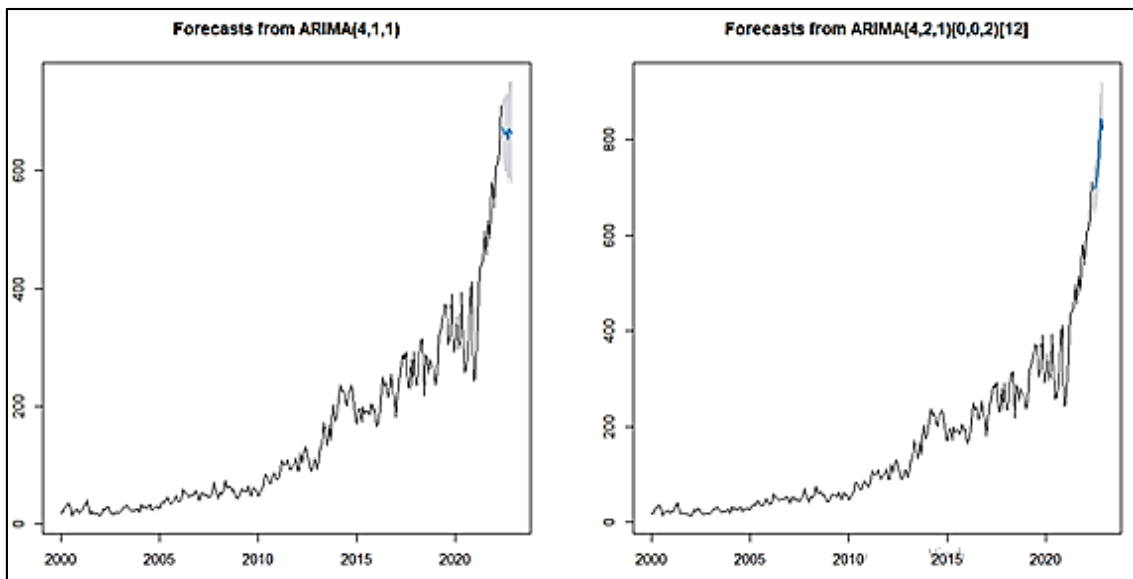


Gráfico 36 Visualización de pronósticos del modelo 1 y 2 de la data camarón

Fuente y Elaboración propia.

Tabla 38 Valores de predicción del Modelo 1

> MODELO_CAMARON1			
	Point Forecast	Lo 95	Hi 95
Jun 2022	672.3435	623.3168	721.3702
Jul 2022	661.4921	598.1239	724.8602
Aug 2022	667.1518	598.5122	735.7914
Sep 2022	653.3510	577.7717	728.9302
Oct 2022	671.0116	592.1132	749.9100
Nov 2022	667.3361	582.7933	751.8790
Dec 2022	663.1803	572.8492	753.5115

Fuente y Elaboración propia.

Tabla 39 Valores de predicción del Modelo 2

> MODELO_CAMARON2			
	Point Forecast	Lo 95	Hi 95
Jun 2022	699.7223	655.1672	744.2774
Jul 2022	696.8962	640.8852	752.9072
Aug 2022	719.2140	659.2988	779.1292
Sep 2022	756.5428	690.0462	823.0395
Oct 2022	798.0299	726.8952	869.1647
Nov 2022	842.6668	762.4098	922.9238
Dec 2022	820.9753	729.0504	912.9002

Fuente y Elaboración propia.

3.2.3.7 Elección mejor modelo

Se realizó una comparación de los dos modelos para identificar cual se ajustó de mejor manera a la serie original, adicional se empleó un test de validación cruzada para verificar el mejor modelo y la decisión se complementó con la evaluación de los accuracy anteriormente ejecutados.

Es importante recordar que para la proyección se utilizó la información desde el año 2000, sin embargo, para efectos de una mejor visualización se lo realizó desde el año 2019, en el cual se puede observar que las predicciones en las que incurren ambos modelos presentaron resultados diferentes. Por lo tanto, se recurrió a la aplicación de validaciones cruzadas como se explica en el primer párrafo para medir el poder predictivo de cada uno de los modelos ejecutados.




Gráfico 37 Visualización de serie original – Camarón 2019-2022, pronóstico modelo 1 y modelo 2

Fuente y Elaboración propia.

3.2.3.7.1 Validación cruzada para series temporales (camarón)

La ejecución del test de validación cruzada se ejecutó tomando en cuenta los mismos parámetros que en las series temporales correspondientes al petróleo y banano, utilizando el primer trimestre de análisis de cada año con el objetivo de verificar el error de predicción.

Modelo 1: (4, 1, 1)

Tabla 40 Resultados de la validación cruzada del modelo 1

```
> Modelo1_CAM <- function(x, h){forecast(Arima(tsdata_camaron, order=c(4,1,1)), h=h)}  
>  
> e <- tscv(tsdata_camaron,Modelo1_CAM, h=3, window=3)  
>  
> mean(e^2, na.rm = TRUE)/1000  
[1] 329.7006
```

Fuente y Elaboración propia.

Modelo 2: (4, 2, 1) (0, 0, 2)

Tabla 41 Resultados de la validación cruzada del modelo 2

```
> Modelo2_CAM <- function(x, h){forecast(Arima(tsdata_camaron, order=c(4,2,1),seasonal=c(0,0,2)), h=h)}  
> e <- tscv(tsdata_camaron,Modelo2_CAM, h=3, window=3)  
>  
> mean(e^2, na.rm = TRUE)/1000  
[1] 288.479
```

Fuente y Elaboración propia.

Para el camarón finalmente se concluyó que el mejor modelo es el 2, por tanto, la predicción arrojada de este modelo se usó como insumo en la construcción del modelo de regresión para medir el impacto del PIB.

3.3 Modelo de regresión múltiple para analizar impacto en el PIB

Una vez asegurado la fiabilidad de las estimaciones para los próximos 7 meses de los principales productos de exportación primaria (petróleo, banano, camarón) los cuales serán usados como insumo para medir el impacto en el PIB al finalizar el año, se procede a definir la variable de respuesta (Y) el cual será el PIB expresado en miles de dólares. Mientras que las variables predictoras corresponden a los principales productos de exportación anteriormente definidos, a esto se le agrega el pronóstico obtenido de los modelos ARIMA, con el objetivo de cuantificar a la variable dependiente al finalizar el año 2022, es importante mencionar que dentro del campo de los modelos matemáticos es indispensable definir la especificación funcional a través de la determinación de las variables a utilizar.

Para este modelo, la información se obtuvo del Banco Central del Ecuador (BCE), considerando como periodo de tiempo entre 2000-2021, representada en miles de dólares FOB.

Dentro del modelado, es importante que se asegure varios supuestos, entre los más importantes es asegurar una limitada presencia de multicolinealidad, entre otros.




Gráfico 38 Visualización de serie temporal del PIB, petróleo, banano y camarón.

Fuente y Elaboración propia.

3.3.1 Estimación del modelo

Para poder estimar el modelo final se utiliza como fuente principal los datos obtenidos del BCE desde el año 2000 al 2022, en lo que respecta al año 2022 al ser un año que no finaliza se utiliza como insumo las predicciones obtenidas de los modelos ARIMA de los principales productos de exportación (petróleo, banano, camarón), de tal manera que nos permite cuantificar el PIB al término del año 2022.

Tabla 42 Visualización del modelo de regresión múltiple

```
> modelo1 <- lm(PIB ~ Petróleo + Banano + Camarón, data=data_modelo)
> summary(modelo1)

Call:
lm(formula = PIB ~ Petróleo + Banano + Camarón, data = data_modelo)

Residuals:
    Min       1Q   Median       3Q      Max
-11628406  -3457214   892781   5333889  11312956

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.171e+07  5.720e+06   3.795  0.00132 **
Petróleo     1.242e+00  5.187e-01   2.394  0.02779 *
Banano       1.884e+01  5.453e+00   3.456  0.00282 **
Camarón      3.533e+00  3.283e+00   1.076  0.29613
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 7284000 on 18 degrees of freedom
Multiple R-squared:  0.9298, Adjusted R-squared:  0.9181
F-statistic: 79.45 on 3 and 18 DF, p-value: 1.415e-10
```

Fuente y Elaboración propia.

A nivel general los coeficientes son estadísticamente significativos, usando como referencia tanto el valor P (menor que 0.05) y la prueba T (mayor que 2) a excepción del coeficiente correspondiente al camarón.

En cuanto al coeficiente de determinación ajustado (r^2) considera que las variables predictoras (petróleo, banano y camarón) explican en un 92% a la variable de respuesta (PIB) por tanto estamos frente a un buen modelo.

En términos generales, los coeficientes se interpretan a continuación:

Intercepto. EL PIB promedio anual sin influencia de las variables petróleo, banano y camarón corresponde a 2,17 miles de millones de dólares.

Petróleo. Cuando se incrementa en 1 mil millones de dólares la exportación de petróleo, se tendrá un aumento del PIB en 1.24.

Banano. Cuando incrementa en 1 mil millones de dólares la exportación de banano, el PIB incrementará en 1.88.

Camarón: Si se incrementa en 1 mil millones de dólares la exportación de camarón, se tendrá un aumento del PIB en 0.35.

3.3.2 Supuestos del modelo

3.3.2.1 Autocorrelación

Se usará dos tipos de contrastes con el fin de verificar que en el modelo no exista autocorrelación:

3.3.2.1.1 Prueba de Durbin-Watson

Tabla 43 Visualización de resultado de autocorrelación

```
Durbin-watson test
data: modelo
Dw = 6.639 , p-value = 0.4631
alternative hypothesis: true autocorrelation is greater than 0
```

Fuente y Elaboración propia.

Se establecen las siguientes hipótesis:

H_0 : No hay autocorrelación

H_1 : Autocorrelación

Si el valor p es < 0.05 , se rechaza H_0 ; valor p $(0.4631) > 0.05$; por tanto, no hay autocorrelación.

3.3.2.2 Heterocedasticidad

Se debe asegurar que en modelo no exista heterocedasticidad a través de los siguientes contrastes:

3.3.2.2.1 Test BP (Studentized Breusch-Pagan)

Tabla 44 Resultados de la prueba de Heterocedasticidad

```
studentized Breusch-Pagan test
data: modelo
BP = 7.1762, df = 3, p-value = 0.06649
```

Fuente y Elaboración propia.

Si el valor $p < 0.05$, rechazo hipótesis nula
Ho: Homocedasticidad
Ha: Heterocedasticidad

Por lo tanto Acepto H_0 , no existe heterocedasticidad en el modelo

3.3.2.3 Multicolinealidad

Para probar este supuesto se utilizará el factor de inflación de la varianza, esto se muestra de la siguiente manera:

Tabla 45 Resultados de la prueba de Multicolinealidad

```
> vif(modelo)
Petróleo   Banano   Camarón
1.386886   0.310113   9.267955
```

Fuente y Elaboración propia.

Si en algunos de los factores se presenta un valor mayor a 10 existe un problema severo de multicolinealidad, por tanto para este caso no hay un problema grave de multicolinealidad.

Distribución normal de varianza

Se hará uso de la prueba de Shapiro-Wilk para contrastar la existencia o no de normalidad, a través del planteamiento de hipótesis:

Ho: Datos normales

H1: Inexistencia de normalidad

Cuando se tiene $p < 0.05$, no se debe aceptar Ho.

3.3.2.3.1 Prueba de Shapiro-Wilk

Tabla 46 Resultados de la prueba de Normalidad

```
shapiro-wilk normality test
data: modelo1$residuals
W = 0.94205, p-value = 0.2181
```

Fuente y Elaboración propia.

Efectivamente los residuos presentan normalidad en los datos, pues, los valores p en la prueba es mayor que 0.05.

De esta manera finalmente se prueba todos los supuestos comúnmente ejecutados en modelos de regresión múltiple para corroborar que estamos frente a un modelo generador de datos estable, y, por lo tanto, el modelo es estadísticamente bueno, esto permite tomar decisiones oportunas. Finalmente se procederá a cuantificar el valor del PIB al término del año 2022 considerando la información desde el año 2000 hasta 2021 y respecto al 2022 se considerará los 5 primeros meses del 2022, más el insumo de los 7 meses pronosticados anteriormente con modelos ARIMA de los productos de exportación primaria (petróleo, banano, camarón).

3.4 Pronóstico PIB 2022

Conforme al pronóstico obtenido, las exportaciones anuales al término del año 2022, correspondientes a los principales productos de exportación podrían alcanzar los siguientes niveles, que se detallan a continuación:

Tabla 47 Pronóstico al término del año 2022 del petróleo, banano y camarón

PETROLEO	BANANO	CAMARON
10,399,445.23	3,420,637.26	5,432,451.53

Fuente y Elaboración propia.

Los valores obtenidos en la tabla 32 son reemplazados en el modelo estimado en el punto 3.3.1 con el objetivo de cuantificar finalmente el PIB al término del año.

Tabla 48 Visualización de resultados del PIB pronosticado al 2022

```
> 2.171e+07 + (4.242e+00*10399445)+(1.884e+0*3420637)+(3.533e+00*5432452)
[1] 102060779
```

Fuente y Elaboración propia.

Por lo tanto el PIB para el año 2022, tomando en cuenta los valores de los coeficientes podría alcanzar en término nominales 102.01 miles de millones de dólares, por tantos se estaría generando una mejora notable especialmente si se analiza respecto al año 2020 como se muestra en el grafico 30 donde se puede visualizar el comportamiento del PIB desde el año 2000-2021 y los posibles valores que podría alcanzar en los próximos años, la fuente corresponde a las proyecciones del FMI que utiliza otro tipo de metodología, sin embargo para el proyecto de investigación resulta útil para realizar una comparación y así poder asegurar que la cifra pronosticada para el PIB 2023 presenta cierto nivel de similitud.




Gráfico 39 Evolución del PIB desde el año 2000 con proyección a 2025

Fuente: Elaboración BCE y FMI.

Por lo tanto se esperaría que la economía ecuatoriana esté reportando una mejora notable en la economía al finalizar el año 2022, cabe recalcar que quizá este valor podría verse afectado por el tema del paro nacional reportado en junio 2022 y más aun específicamente por el precio del petróleo ya que es bastante volátil frente a factores exógenos; aun así la

proyección nos permite tener una idea de que efectivamente la economía ecuatoriana está tratando de salir adelante tras haber sufrido una pandemia mundial, además este indicador incluso podría mejorar si se incrementan los valores de exportación de los principales productos primarios, ya que éstos se traducen directamente en el crecimiento económico del país como se vio en los resultados anteriormente expuestos.

CAPÍTULO IV

4. CONCLUSIONES Y RECOMENDACIONES

4.1 CONCLUSIONES

A partir del desarrollo del proyecto de investigación es posible establecer las siguientes conclusiones.

El hecho de poder hacer uso de los datos macroeconómicos de cuentas nacionales que tiene a disposición el BCE y el modelo propuesto para el análisis de series temporales ARIMA, se pudo constatar que los productos analizados (banano, petróleo y camarón) son un eje central del crecimiento económico ecuatoriano (PIB). Esto debido a que teóricamente las exportaciones constituyen factores que inciden en la dinamización económica; los cambios que se presentan en esta variable son generadores de variaciones significativas en el PIB (su crecimiento). Esto también se observa a nivel de desarrollo tecnológico, de innovación, de productividad y de generación de puestos de empleo.

Respecto a las exportaciones, cabe mencionar que el país es dependiente de las exportaciones de carácter primario, tal como se presenta para otros países vecinos. Sin embargo, como se mencionó, estas exportaciones son un importante pilar para el crecimiento del producto. La dificultad radica en la dependencia a uno de los precios de estos productos, en particular del petróleo, ya que cuando este baja, se reducen de manera crítica los ingresos del país. En el modelo ARIMA se evidencia este fenómeno, en particular su volatilidad. Así, tal como lo plantea la información provista por el BCE, el petróleo es el producto que más ingreso (dólares FOC) aporta a la economía nacional, en comparación con el banano o con el camarón. Es claro el hecho de que, si una economía y más aún la economía ecuatoriana depende en gran medida de las exportaciones primarias o de los productos que son parcialmente elaborados, y por ende la probabilidad de que las variaciones de los precios mundiales impacten en la economía son muy elevadas, y las acciones y decisiones por tomar que permitan evitar una disminución o contracción en la actividad comercial son muy limitadas en dicho contexto.

El motivo de la utilización de los modelos ARIMA en forma inicial dentro del proyecto nace del hecho de que se usó series temporales para cada uno de los productos y junto a ello se tuvo en mente siempre la idea de detectar errores en la predicciones para cada uno de ellos, lo cual conllevó a un análisis profundo en el despliegue de una metodología para

controlar estadísticamente la calidad para cada uno de los modelos de los productos primarios para exportación; permitiendo manejar de manera óptima varias pruebas estadísticas, que a la vez nos han servido como herramienta de depuración en la elección del mejor modelo y a la vez han garantizado la fiabilidad de las estimaciones obtenidas en cada uno de los modelos ARIMA correspondiente a cada uno de los productos de exportación primaria; para posteriormente ser utilizados como insumo en la construcción de un modelo de regresión final para cuantificar el PIB al término del 2022.

Así, la investigación realizada se compone de dos secciones fundamentales: la que presenta la metodología desarrollada para los modelos ARIMA y modelos de regresión múltiple así como todas las pruebas estadísticas necesarias para probar que son modelos matemática y estadísticamente buenos, y por otro lado es el uso del programa R, para poder modelizar cada una de las series de tiempo para los productos primarios de exportación estudiados (petróleo, banano y camarón) para finalmente llevar a cabo la construcción del modelo final, éste proyecto ha sido desarrollado de manera detallada con el fin de que cada una de las variables utilizadas tengan los requisitos mínimos exigidos por la teoría estadística, como por ejemplo la estacionariedad tanto de la media como de la varianza, además de que los residuos al cuadrado en los primeros rezagos del correlograma no sean de carácter significativo, etc. Por tanto, se ha obtenido un método que hace posible desplegar por etapas la herramienta para el control estadístico en modelos ARIMA y regresión múltiple, utilizando la teoría estudiada durante el programa de maestría, dando un enfoque sobre todo matemático y estadístico.

La regresión estadística usada en el proyecto de investigación corresponde a una de las herramientas que más son utilizadas para determinar una variable que constituya la respuesta de una o varias variables predictoras; en este caso la variable respuesta se enfocó en el PIB, mientras que las variables predictoras corresponden a los principales productos primarios de exportación (petróleo, banano y camarón), generalmente se utiliza la herramienta para el cálculo de mínimos cuadrados ordinarios (MCO), la que presenta dificultades en cuanto las variables explicativas presentan multicolinealidad, es decir, se presenta una relación lineal entre ellas. Por lo tanto, en el presente proyecto de investigación se abordan los distintos problemas que deben ser corregidos para poder obtener un modelo matemático robusto a través de la aplicación de varias pruebas estadísticas, las cuales fueron aplicadas mediante el software R, lo que hace posible cuantificar y realizar los ajustes de los resultados en las previsiones mediante el análisis

de las condiciones de inicio de los datos, en lo que compete a materia económica respecto a la variables utilizadas en el modelo de regresión final, es un poco complejo resumir en pocas líneas su comportamiento desde el año 2000-2022 y más aún del comportamiento a través del tiempo de cada uno de los productos de exportación analizados (petróleo, banano y camarón), ya que a ello se suma el gran cambio que produjo en la economía del país el hecho de haber atravesado por una pandemia mundial (COVID-19).

El 2020 sin duda fue un periodo de importantes desafíos, dificultades y mucha incertidumbre; sin embargo se puede pronosticar que para finalizar el año 2022 se espera tener más aciertos socioeconómicos que permitan llegar a la estimación obtenida, y no solamente lo ratifica este proyecto de investigación en que el 2023 comience con expectativas más elevadas, a pesar de que la pandemia continúa presente, sino que por fuentes del BCE afirman que el cierre de 2022 se espera que sea mejor que el 2021 debido al exitoso plan de vacunación, y el incremento notable de las exportaciones primarias, las cuales han permitido que las actividades retomen su cauce.

Es claro que el modelo matemático que usó como insumo predicciones de los principales productos de exportación primaria muestra que se encamina a la recuperación de la confianza en el país, así como de las demás naciones; incluso representa una parte esencial para la transformación social, financiera y económica; más aún frente a la expectativa de que el paro nacional no haya impactado de manera significativa el camino de mejora en la que está enfocada la economía ecuatoriana. Sin duda, el incremento de las exportaciones primarias (crudo, camarón y banano) son factores que potencian el desarrollo económico, es así que, el Banco Mundial proyecta que para el año 2023 el PIB crecerá en 3,1%.

4.2 RECOMENDACIONES

- Se recomienda para futuras investigaciones agregar los productos que se ubican en cuarto y quinto lugar (Café/cacao y flores naturales) en volumen de exportación de productos primarios, los cuales no fueron considerados en este proyecto para medir el impacto del PIB.
- Respecto a la manera del modelamiento matemático empleado se podría incursionar por otro tipo de modelos que incluyan otro tipo de pruebas.
- Al ser un proyecto de carácter matemático y estadístico, se podría dar un enfoque

más económico, por ejemplo, analizando elasticidades de cada una de las variables utilizadas.

BIBLIOGRAFÍA

- Soporte de Minitab. (2021). *Soporte de Minitab*. Obtenido de AIC, AICc y BIC: <https://support.minitab.com/es-mx/minitab/19/help-and-how-to/statistical-modeling/regression/how-to/fit-binary-logistic-model/interpret-the-results/all-statistics-and-graphs/model-summary-statistics/#aic-aicc-and-bic>
- Alvarado, M. (2019). Impacto de exportaciones primarias en el crecimiento económico del Ecuador: análisis econométrico desde Cobb Douglas, período 2000-2017. *INNOVA Research Journal*, 5(1), 220-231. Obtenido de Impacto de exportaciones primarias en el crecimiento económico del Ecuador:.
- Amaris, G., Ávila, H., & Guerrero, T. (2017). Aplicación de modelo ARIMA para el análisis de series de volúmenes anuales en el río Magdalena. *Tecnura*, 21(52), 88-101.
- Araya, J. (2015). Uso de un criterio de validación cruzada para la evaluación de un método multivariado de relleno de datos. *C Global*, 27-36.
- Asturias, C. u. (2017). *Multicolinealidad, Heterocedasticidad y Autocorrelacion*. Asturias: Corporación Asturias. Obtenido de https://www.centro-virtual.com/recursos/biblioteca/pdf/econometria/unidad3_pdf1.pdf
- Asturias, C. u. (s.f.). *Multicolinealidad, Heterocedasticidad y Autocorrelacion*. Obtenido de https://www.centro-virtual.com/recursos/biblioteca/pdf/econometria/unidad3_pdf1.pdf
- Banco Mundial*. (06 de 04 de 2022). Obtenido de América Latina y el Caribe : Impacto Covid-19: <https://www.bancomundial.org/es/region/lac/overview>
- Briones, X. (01 de 12 de 2018). *Research Gate*. Obtenido de La función de producción Cobb-Douglas en el Ecuador: https://www.researchgate.net/publication/329952152_La_funcion_de_produccion_Cobb-Douglas_en_el_Ecuador
- Calvo, D. (2 de noviembre de 2018). *Análisis de series temporales en R ARIMA*. Recuperado el 5 de abril de 2022, de <https://www.diegocalvo.es/analisis-de-series-temporales-en-r-arima/>

- Caridad, J. (2016). *Econometría: modelos econométricos y series temporales*. Madrid: Reverte. Obtenido de Modelos Arima.
- Castro, M. (2019). Bioestadística aplicada en investigación clínica: conceptos básicos. *Revista Médica Clínica Las Condes*, 30(1), 50-65.
- CEPAL. (19 de 01 de 2015). *Análisis de Series de Tiempo*. Obtenido de Los modelos ARIMA univariantes: https://www.cepal.org/sites/default/files/courses/files/01_2_arima.pdf
- Cimoli, M. (2019). *Perspectivas del Comercio Internacional de América Latina y el Caribe*. Nueva York : CEPAL .
- Córdova, D., & Santa María, F. (2021). Aplicación del método autorregresivo integrado de medias móviles para el análisis de series de casos de covid-19 en Perú. *Revista de la Facultad de Medicina Humana*, 21(1), 65-74.
- De la Fuente, S. (2017). *Series Temporales, modelo ARIMA, metodología de Box - Jenkins*. Madrid: Universidad Autónoma de Madrid.
- Ecured. (s.f.). *Normalidad en modelos de regresión*. Obtenido de https://www.ecured.cu/Normalidad_del_modelo_de_regresi%C3%B3n_lineal#:~:text=La%20normalidad%20es%20uno%20de,la%20distribuci%C3%B3n%20normal%20tambi%C3%A9n%20llamada
- Elliott, R. &. (s.f.). *ur.ers: Elliott, Rothenberg & Stock Unit Root Test*. Obtenido de <https://rdrr.io/cran/urca/man/ur.ers.html>
- Hervás, Á. (2020). *Análisis de series temporales no estacionarias en R Studio* . Jaén : Universidad del Jaén .
- Hidalgo, N. (2021). *Modelización de datos económicos utilizando series temporales* . Jaén: Universidad del Jaén .
- iCiencias*. (s.f.). Obtenido de Validación cruzada k-fold para la selección de modelos de series temporales: <https://www.i-ciencias.com/pregunta/39749/uso-de-la-validacion-cruzada-k-fold-para-la-seleccion-de-modelos-de-series-temporales>
- Laurente, L., & Machaca, F. (2020). Análisis econométrico de la paridad del poder de compra en Perú. *A Latin American Journal of Applied Economics*, 24(50), 4-24.

- Marqués, F. (2018). *Análisis de Series Temporales. Modelos Multivariados*. Michigan: Independently Published.
- Martincus, J. C. (11 de 09 de 2020). *BID*. Obtenido de El comercio en tiempos de pandemia: el impacto del COVID-19 en las firmas de seis países latinoamericanos: <https://blogs.iadb.org/integracion-comercio/es/el-comercio-en-tiempos-de-pandemia-el-impacto-del-covid-19-en-las-firmas-de-seis-paises-latinoamericanos/>
- McKenzie, T. (15 de 04 de 2020). *Inomics*. Obtenido de Economics Terms A-Z - Los términos más importantes de economía.: <https://inomics.com/es/terms/funcion-de-produccion-cobb-douglas-1456726>
- Mena, L., & Calo, D. (2020). *Modelo arima para el pronóstico de la producción de cacao en el Ecuador para el .* Quito: UCE.
- Ministerio de Producción, Comercio Exterior, Inversiones y Pesca. (2020). *COVID-19: Impacto en las exportaciones de organizaciones de pequeños productores, afectaciones, desafíos y oportunidades*. Quito: Subsecretaría de Promoción de Exportaciones.
- Minitab, S. d. (s.f.). *Soporte de Minitab*. Obtenido de AIC, AICc y BIC: <https://support.minitab.com/es-mx/minitab/19/help-and-how-to/statistical-modeling/regression/how-to/fit-binary-logistic-model/interpret-the-results/all-statistics-and-graphs/model-summary-statistics/#aic-aicc-and-bic>
- Novales, A. (2016). *Series temporales. Estacionariedad, raíces unitarias* . Madrid : Universidad Complutense.
- Pfaff, B. (2008). *Validación cruzada de series de tiempo*. Obtenido de <https://otexts.com/fpp3/tscv.html>
- Ramón, N., & López, J. (2018). *Series Temporales y modelos de ecuaciones simultáneas*. Alicante: UMH.
- Ríos, V., Lavilla, G., Farfán, M., Cruz, C., Tairo, R., & Quispe, H. (2019). Modelo de serie temporal y metodología de Box Jenkins a registro de pacientes intervenidos en cirugía mayor de baja complejidad en el seguro social de salud en la ciudad Puerto Maldonado. *Revista El Ceprosimad*, 7(1), 53-66.

- Roldan, P. N. (15 de 09 de 2016). *Economipedia*. Obtenido de Función de producción Cobb Douglas: <https://economipedia.com/definiciones/funcion-de-produccion-cobb-douglas.html>
- Rubalcaba, J. (2016). *Modelización y Estadística en Biología*. Obtenido de Cosas que conviene saber al usar AIC, DIC y otros criterios de información: <https://jgrubalcaba.wordpress.com/2016/02/21/cosas-que-conviene-saber-al-usar-aic-dic-y-otros-criterios-de-informacion/>
- Rubalcaba, J. (s.f.). *Modelización y Estadística en Biología*. Obtenido de Cosas que conviene saber al usar AIC, DIC y otros criterios de información: <https://jgrubalcaba.wordpress.com/2016/02/21/cosas-que-conviene-saber-al-usar-aic-dic-y-otros-criterios-de-informacion/>
- Rueda, V. (23 de junio de 2018). *Clasificación de exportaciones ecuatorianas según sus particularidades*. Recuperado el 5 de abril de 2022, de <https://comunidad.todocomercioexterior.com.ec/profiles/blogs/clasificaci-n-de-exportaciones-ecuatorianas-seg-n-sus>
- Tobón, J. (2019). *Desarrollo de un modelo de pronóstico en la metodología de Box-Jenkins para la demanda de estudiantes de pregrado de la Fundación Universitaria Tecnológico COMFENALCO*. Bogotá: Fundación Universitaria Los Libertadores .
- Toledo, W. (2017). El rol de las exportaciones en el crecimiento económico: evidencia de una muestra de países de América Latina y el Caribe. *Revista de economía*, 34(89), 78-100.

ANEXOS

Anexo 1: Script R Modelos Arima- Petróleo

```
library(forecast)
library(urca)
library(openxlsx)
library(highcharter)
library(tseries)
library(ggplot2)
library(forecast)
library(dplyr)
library(tsibble)
library(fable)
```

```

library(fabletools)

# CARGA DE DATA

file.choose()

data_petroleo<-      read.xlsx("C:\\Users\\user\\Desktop\\MARCO      TEORICO
TESIS\\ARIMA_PETROLEO.xlsx")
ts.plot(data_petroleo)

tsdata_petroleo <- ts(data_petroleo/1000,
                      start=c(2000,1),
                      frequency = 12)

ts.plot(tsdata_petroleo)

plot(tsdata_petroleo, main="PETROLEO", ylab="", legend("blue"))

### GRAFICO FINAL

autoplot(tsdata_petroleo) + ggtitle("SERIE TEMPORAL PETRÓLEO") +
  xlab("Time (Año)") + ylab("Miles de dólares") +
  theme_bw() +
  theme(plot.title = element_text(hjust = 0.5))

# TEST RAICES UNITARIAS

#PHILIPS PERRON

pptest <- ur.pp(tsdata_petroleo,
               type=c("Z-tau"),
               model=c("trend"),
               lags=c("short"))
summary(pptest)

# VALOR P>0.05 ACEPTO HO
#Ho: Existen raíces unitarias.
#H1: No existen raíces unitarias, la serie es estacionaria.

# ELLIOT ROTHENBERG AND STOCK

erstest <- ur.ers(tsdata_petroleo,
                 type=c("DF-GLS"),
                 model=c("trend"),
                 lag.max = 4)
summary(erstest)

# PRUEBA DICKEY FULLER

```

```
adf.test(tsdata_petroleo, alternative = c("stationary", "explosive"))
```

```
adf.test(log(tsdata_petroleo), k=0)
```

```
ndiffs(tsdata_petroleo, test = c("kpss"))
```

```
ndiffs(tsdata_petroleo, test = c("adf"))
```

```
ndiffs(tsdata_petroleo, test = c("pp"))
```

```
acf(tsdata_petroleo, lag.max = 0, plot = T)
```

```
library(astsa)
```

```
acf2(diff(Nile))
```

```
par(mfrow=c(1,2))
```

```
Acf(diff(tsdata_petroleo,1))
```

```
Pacf(diff(tsdata_petroleo,1))
```

```
par(mfrow=c(1,1))
```

```
Acf(diff(tsdata_petroleo))
```

```
Pacf(diff(tsdata_petroleo))
```

```
# MODELO 1-----
```

```
# CONSTRUCCION MODELO
```

```
modelo_estimado1 <- tsdata_petroleo %>%
```

```
  Arima (order = c(1,0,1),
```

```
        seasonal = c(1,0,2))
```

```
summary(modelo_estimado2)
```

```
modelo_estimado1 <- tsdata_petroleo %>%
```

```
  Arima (order = c(1,0,1))
```

```
summary(modelo_estimado1)
```

```
0.9638/0.0169
```

```
0.2567/0.0602
```

```
578.7106/130.3003
```

```
# GRAFICO CIRCULO UNITARIO
```

```
plot(modelo_estimado1)
```

```
# ACCURACY
```

```
accuracy(modelo_estimado1)
```

```
# EVALUACION DE RESIDUOS:
```

```
par(mfrow=c(1,1))
```

```
plot(modelo_estimado1$residuals)
```

```
Box.test(modelo_estimado1$residuals,  
         type=c("Ljung-Box"))
```

```
### ACF Y PACF CON RESIDUOS
```

```
par(mfrow=c(1,2))  
Acf(modelo_estimado1$residuals)  
Pacf(modelo_estimado1$residuals)
```

```
#### PRONOSTICO PARA LOS DOS MODELOS
```

```
par(mfrow=c(1,2))  
MODELO1_PETROLEO1<-forecast(modelo_estimado1,h=7,  
                             level=(95))  
plot(MODELO1_PETROLEO1)
```

```
MODELO1_PETROLEO2<-forecast(modelo_petróleo,h=7,  
                             level=(95))  
plot(MODELO1_PETROLEO2)
```

```
par(mfrow=c(1,2))  
MODELO1_PETROLEO1  
MODELO1_PETROLEO2
```

```
#### GRAFICO COMBINADO
```

```
####LIBRERIA HIGHCHARTER
```

```
par(mfrow=c(1,2))  
hchart(MODELO1_PETROLEO1)  
hchart(MODELO1_PETROLEO2)
```

```
##### COMBINACION
```

```
par(mfrow=c(1,1))  
cols<- c("BLACK", "#EEA236", "skyblue", "blue", "blue")  
ts.plot(tsdata_petroleo,Yt_Sarima2,Yt_HW2,PRONOSTICO1,PRONOSTICO2,col=cols)  
legend("topleft",c("serie  
original","modelo1","modelo2","pronostico_model1","pronostico_model2")  
      ,cex=0.70, fill=cols)
```

```
Yt_Sarima2<-MODELO1_PETROLEO1$fitted  
Yt_HW2<-MODELO1_PETROLEO2$fitted  
PRONOSTICO1<-MODELO1_PETROLEO1$mean  
PRONOSTICO2<-MODELO1_PETROLEO2$mean
```

```

ts.plot(tsdata_petroleo,PRONOSTICO1,PRONOSTICO2,col=cols)
legend("topright",c("Serie original","Modelo1","Modelo2")
      ,cex=0.70, fill=cols)
theme

ggplot(tsdata_petroleo, aes(x=date)) +
  geom_line(aes(y = Yt_Sarima2), color = "darkred") +
  geom_line(aes(y = Yt_HW2), color="steelblue", linetype="twodash")

#### GGLOT

cols <- c("#D43F3A", "#EEA236", "#5CB85C", "#46B8DA", "#9632B8")

ggplot(tsdata_petroleo, aes(x = x, y = value, color = variable)) +
  geom_line() +
  scale_color_manual(values = cols)

#### VALIDACION CRUZADA COMBINACION MODELO 1 +MODELO 2

####MODELO1#####

Modelo1_PETR <- function(x, h){forecast(Arima(tsdata_petroleo, order=c(1,0,1)),
h=h)}

e <- tsCV(tsdata_petroleo,Modelo1_PETR, h=3, window=3)

mean(e^2, na.rm = TRUE)/1000

####MODELO2#####

Modelo2_PETR <- function(x, h){forecast(Arima(tsdata_petroleo, order=c(0,1,1)),
h=h)}

e <- tsCV(tsdata_petroleo,Modelo2_PETR, h=3, window=3)

mean(e^2, na.rm = TRUE)/1000

##### MODELO 2---PETROLEO

par(mfrow=c(1,1))

modelo_petróleo <- Arima(tsdata,
  order=c(0,1,1),
  fixed=c(NA))

```

```

modelo_petróleo

0.2794/0.0578

plot(modelo_petróleo)

----SEPARACION
accuracy(modelo_petróleo)

ts.plot(tsdata)
modelo_petróleo <- auto.arima(tsdata)
modelo_petróleo

# EVALUACION ACCURACY DEL MODELO

accuracy(modelo1)
tsdata

par(mfrow=c(1,1))
plot(modelo_petróleo$residuals)

Box.test(modelo_petróleo$residuals,
          type=c("Ljung-Box"))

#si p-value < 0.05, rechazo ho
#ho: residuos independientes

par(mfrow=c(1,2))
Acf(modelo_petróleo$residuals)
Pacf(modelo_petróleo$residuals)

### PRONOSTICO

par(mfrow=c(1,1))
petroleo<-forecast(modelo_petróleo,h=7,
                   level=(95))
plot(petroleo)

petroleo

hchart(f1)

par(mfrow=c(1,1))
ts.plot(tsdata,f1$fitted,f1$mean,
        col=c("red","blue","green"),
        main="PROYECCION EXPORTACIONES TOTALES ECUADOR")

```

Anexo 2: Script R Modelos Arima- Banano

```
##### MODELO BANANO
```

```
### MODELO1
```

```
file.choose()
```

```
data_banano<- read.xlsx("C:\\Users\\user\\Desktop\\MARCO TEORICO  
TESIS\\ARIMA_BANANO_1.xlsx")
```

```
ts.plot(data_banano)
```

```
tsdata_banano <- ts(data_banano/1000,
```

```
start=c(2000,1),
```

```
frequency = 12)
```

```
ts.plot(tsdata_banano)
```

```
autoplot(tsdata_banano) + ggtitle("SERIE TEMPORAL BANANO") +
```

```
xlab("Time (Año)") + ylab("Miles de dólares") +
```

```
theme_bw() +
```

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

```
# TEST RAICES UNITARIAS
```

```
#PHILIPS PERRON
```

```
pptest <- ur.pp(tsdata_banano,
```

```
type=c("Z-tau"),
```

```
model=c("trend"),
```

```
lags=c("short"))
```

```
summary(pptest)
```

```
# VALOR P>0.05 ACEPTO HO
```

```
#Ho: Existen raíces unitarias.
```

```
#H1: No existen raíces unitarias, la serie es estacionaria.
```

```
# ELLIOT ROTHENBERG AND STOCK
```

```
erstest <- ur.ers(tsdata_banano,
```

```

        type=c("DF-GLS"),
        model=c("trend"),
        lag.max = 4)
summary(erstest)

# PRUEBA DICKEY FULLER

adf.test(tsdata_banano, alternative = c("stationary", "explosive"))
adf.test((tsdata_banano), k=0)
library(astsa)
acf2(diff(Nile))
par(mfrow=c(1,1))
Acf(diff(tsdata_banano))
Pacf(diff(tsdata_banano))

```

Anexo 3: Script R Modelos Arima- Camarón

```

library(forecast)
library(dplyr)
library(tsibble)
library(fable)
library(fabletools)
### MODELO1
file.choose()
data_camaron_1<- read.xlsx("C:\\Users\\user\\Desktop\\MARCO TEORICO
TESIS\\ARIMA_CAMARON_1.xlsx")
ts.plot(data_camaron)
tsdata_camaron <- ts(data_camaron_1/1000,
                    start=c(2000,1),
                    frequency = 12)
ts.plot(tsdata_camaron)
autoplot(tsdata_camaron) + ggtitle("SERIE TEMPORAL CAMARON") +
  xlab("Time (Año)") + ylab("Miles de dólares") +
  theme_bw() +

```

```

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

# TEST RAICES UNITARIAS

#PHILIPS PERRON

pptest <- ur.pp(tpdata_camaron,
               type=c("Z-tau"),
               model=c("trend"),
               lags=c("short"))
summary(pptest)

# VALOR P>0.05 ACEPTO HO
#Ho: Existen raíces unitarias.
#H1: No existen raíces unitarias, la serie es estacionaria.

# ELLIOT ROTHENBERG AND STOCK

erstest <- ur.ers(tpdata_camaron,
                 type=c("DF-GLS"),
                 model=c("trend"),
                 lag.max = 4)
summary(erstest)

# PRUEBA DICKEY FULLER

adf.test(tpdata_camaron, alternative = c("stationary", "explosive"))

adf.test(log(tpdata_camaron), k=0)

par(mfrow=c(1,2))
Acf(diff(tpdata_camaron))

```

```

Pacf(diff(tsdata_camaron))
# MODELO 1
# CONSTRUCCION MODELO
modelo_estimado100 <- tsdata_camaron %>%
  Arima (order = c(2,0,3),
        seasonal = c(1,0,2))
summary(modelo_estimado100)

### MODELO 1
modelo_estimado1 <- tsdata_camaron %>%
  Arima (order = c(4,1,1))

summary(modelo_estimado1)

-0.6264/0.1811
-0.3943/0.0774
-0.1401/0.0793
-0.2524/0.0673
0.4453/0.1881

errorArima1<- tsCV(tsdata_camaron,modelo_estimado1>window =0, h=1)
errorArima1
mean(errorArima1, na.rm = FALSE)

# GRAFICO CIRCULO UNITARIO

plot(modelo_estimado1)

# ACCURACY

accuracy(modelo_estimado1)

# EVALUACION DE RESIDUOS:

```

```
par(mfrow=c(1,1))
plot(modelo_estimado1$residuals)
```

```
Box.test(modelo_estimado1$residuals,
         type=c("Ljung-Box"))
```

```
### ACF Y PACF CON RESIDUOS
```

```
par(mfrow=c(1,2))
Acf(modelo_estimado1$residuals)
Pacf(modelo_estimado1$residuals)
```

```
#### PRONOSTICO PARA LOS DOS MODELOS
```

```
par(mfrow=c(1,2))
MODELO_CAMARON1<-forecast(modelo_estimado1,h=7,
                          level=(95))
plot(MODELO_CAMARON1)
```

```
MODELO_CAMARON2<-forecast(modelo_camaron,h=7,
                          level=(95))
plot(MODELO_CAMARON2)
```

```
par(mfrow=c(1,2))
MODELO_CAMARON1
MODELO_CAMARON2
```

```
##### COMBINACION #####
```

```
Yt_Sarima2<-MODELO_CAMARON1$fitted
Yt_HW2<-MODELO_CAMARON2$fitted
PRONOSTICO1<-MODELO_CAMARON1$mean
```

```

PRONOSTICO2<-MODELO_CAMARON2$mean
par(mfrow=c(1,1))
cols<- c("black","skyblue","gray","red","blue")
ts.plot(tsdata_camaron,Yt_Sarima2,Yt_HW2,PRONOSTICO1,PRONOSTICO2,col=cols)
legend("topleft",c("serie
original","modelo1","modelo2","pronostico_model1","pronostico_model2")
,cex=0.70, fill=cols)
#### VALIDACION CRUZADA CAMARON
#### VALIDACION CRUZADA COMBINACION MODELO 1 +MODELO 2

.      Modelo 1: (4,1,1)
.      Modelo 2: (4,2,1) (0,0,2)
####MODELO1#####
Modelo1_CAM <- function(x, h){forecast(Arima(tsdata_camaron, order=c(4,1,1)),
h=h)}

e <- tsCV(tsdata_camaron,Modelo1_CAM, h=3, window=3)

mean(e^2, na.rm = TRUE)/1000

####MODELO2#####

Modelo2_CAM <- function(x, h){forecast(Arima(tsdata_camaron,
order=c(4,2,1),seasonal=c(0,0,2)), h=h)}

e <- tsCV(tsdata_camaron,Modelo2_CAM, h=3, window=3)

mean(e^2, na.rm = TRUE)/1000

##### MODELO ARIMA CAMARON##### MODELO 2

file.choose()

```

```
data<- read.xlsx("C:\\Users\\user\\Desktop\\MARCO
TESIS\\ARIMA_CAMARON_1.xlsx")
ts.plot(data)
```

TEORICO

```
tsdata <- ts(data/1000,
             start=c(2000,1),
             frequency = 12)
ts.plot(tsdata)
```

#PP

#ERS

```
pptest <- ur.pp(tsdata,
               type=c("Z-tau"),
               model=c("trend"),
               lags=c("short"))
summary(pptest)
```

#no rechazo ho:

#ho: raiz unitaria

```
erstest <- ur.ers(tsdata,
                 type=c("DF-GLS"),
                 model=c("trend"),
                 lag.max = 4)
summary(erstest)
```

#No rechazo ho

#ho: raiz unitaria

```
ndiffs(tsdata,test = c("kpss"))
ndiffs(tsdata,test = c("adf"))
ndiffs(tsdata,test = c("pp"))
```

```
par(mfrow=c(1,2))
```

```
Acf(diff(tsddata,1))
```

```
Pacf(diff(tsddata,1))
```

```
#### CONSTRUCCION MODELO ARIMA
```

```
modelo_camaron <- auto.arima(tsddata_camaron)
```

```
modelo_camaron
```

```
0.4041/0.0684
```

```
0.5465/0.0756
```

```
0.2410/0.0728
```

```
0.3903/0.0631
```

```
0.8341/0.0552
```

```
0.2338/0.0629
```

```
0.3391/0.0749
```

```
plot(modelo_camaron)
```

```
#### ACCURACY CAMARON
```

```
accuracy(modelo_camaron)
```

```
### EVALUACION DE RESIDUOS
```

```
par(mfrow=c(1,1))
```

```
plot(modelo_camaron$residuals)
```

```
Box.test(modelo_camaron$residuals,
```

```
type=c("Ljung-Box"))
```

```
#si p-value < 0.05, rechazo ho
```

```
#ho: residuos independientes
```

```
par(mfrow=c(1,2))
```

```
Acf(modelo_camaron$residuals)
```

```
Pacf(modelo_camaron$residuals)
```

```
par(mfrow=c(1,1))
camaron<-forecast(modelo_camaron,h=7,
                  level=(95))
plot(camaron)
```

```
camaron
```

Anexo 4: Script R Modelo 4- Modelo Final

```
##### MODELO DE REGRESIÓN MÚLTIPLE #####
```

```
file.choose()
```

```
data_modelo<- read.xlsx("C:\\Users\\user\\Desktop\\MARCO TEORICO
TESIS\\Data_Modelo de Regresión Múltiple_1.xlsx")
ts.plot(data_modelo)
```

```
tsdata_modelo <- ts(data_modelo/1000,
                   start=c(2000,1),
                   frequency = 1)
```

```
ts.plot(tsdata_modelo)
```

```
autoplot(tsdata_modelo) + ggtitle("PRINCIPALES PRODUCTOS DE EXPORTACION
PRIMARIA") +
  xlab("Time (Año)") + ylab("Miles de dólares") +
  theme_bw() +
  theme(plot.title = element_text(hjust = 0.5))
```

```
# Estimación del modelo
```

```
library(regmultiple)
```

```
#----- Estimando el modelo #-----
```

```
names(data_modelo)
```

```
modelo <- lm(PIB ~ Petróleo + Banano+ Camarón, data=data_modelo)
```

```
summary(modelo)
```

```
###AUTOCORRELACION
```

```
dwtest (modelo)
```

```
bgtest(modelo, order=1)
```

```
### HETEROCEDASTICIDAD
```

```
bptest(modelo)
```

```
library(car)
```

```
ncvTest(modelo)
```

```
### MULTICOLINEALIDAD
```

```
vif(modelo)
```

```
### NORMALIDAD
```

```
library(moments)
```

```
library(nortest)
```

```
### JARQUE BERA
```

```
jarque.test(as.vector(modelo$residuals))
```

```
### ANDERSON DARLING
```

```
ad.test(modelo$residuals)
```

```
### SHAPIRO WILK
```

shapiro.test(modelo1\$residuals)

PRONOSTICO CON EL MODELO

summary(modelo)

modelo\$coefficients

Anexo 5: Base de datos Mensual-2000-2021

ANIO	MES	Petróleo Crudo	Banano y plátano (1)	Camarón
2000	1	182492	77157	17451
2000	2	165875	79008	19828
2000	3	176592	86061	27701
2000	4	144000	88227	30916
2000	5	189237	72679	35465
2000	6	163330	72297	33217
2000	7	180764	57280	20177
2000	8	220348	57401	13620
2000	9	208404	60936	21687
2000	10	201283	50649	22086
2000	11	175598	49803	24467
2000	12	136085	69877	18819
2001	1	190291	79292	21697
2001	2	128838	73736	23706
2001	3	148118	90672	31674
2001	4	149244	83324	33762
2001	5	176200	76450	40721
2001	6	124550	65073	25253
2001	7	162638	62201	17150
2001	8	136287	59905	20621
2001	9	176009	72492	17181
2001	10	132958	64034	17335
2001	11	96928	68369	18212
2001	12	100272	68967	14074
2002	1	104068	89258	14406
2002	2	95326	75352	20063
2002	3	117347	97289	26125
2002	4	176129	97215	23862
2002	5	144575	91275	29239
2002	6	142898	71088	28279
2002	7	176087	63688	20193
2002	8	188868	78369	18526
2002	9	199558	72131	14940
2002	10	164846	68198	19198
2002	11	167454	79680	19815

2002	12	161870	85796	18073
2003	1	191786	104138	19743
2003	2	227494	95011	23198
2003	3	175785	104144	27991
2003	4	125175	100679	28279
2003	5	139044	92851	32247
2003	6	173153	87094	26957
2003	7	190759	80309	23764
2003	8	190010	91320	20808
2003	9	227085	80841	22244
2003	10	253364	86323	22938
2003	11	224478	95672	24505
2003	12	254182	82418	26291
2004	1	273640	98380	20145
2004	2	248074	71250	32609
2004	3	246218	74289	27420
2004	4	330702	96851	29662
2004	5	354500	89283	25295
2004	6	349069	80278	28659
2004	7	313268	86730	32941
2004	8	398326	81553	23283
2004	9	356643	86717	24051
2004	10	435246	88199	27217
2004	11	322798	80084	29782
2004	12	270023	89995	28728
2005	1	327380	88097	26305
2005	2	326174	86531	34622
2005	3	433509	98218	37794
2005	4	397826	104119	35972
2005	5	386908	93203	43418
2005	6	486833	81035	43268
2005	7	448209	86171	37844
2005	8	532417	83097	33287
2005	9	543521	94702	35688
2005	10	454378	86702	41168
2005	11	506878	79087	48577
2005	12	552809	103432	39594
2006	1	580170	114237	37558
2006	2	521784	116880	40160
2006	3	581676	119312	59552
2006	4	687559	116033	52240
2006	5	583399	99713	53468
2006	6	587774	85028	49506
2006	7	574311	81223	45803
2006	8	664426	83189	48984

2006	9	607365	101040	48097
2006	10	522293	90353	49312
2006	11	534008	86834	55380
2006	12	489246	119646	48102
2007	1	414450	117105	39418
2007	2	426370	98886	52487
2007	3	498449	112934	49512
2007	4	488132	111824	52010
2007	5	496088	111209	46163
2007	6	674245	97094	49717
2007	7	779967	103184	43293
2007	8	625046	97036	47268
2007	9	705681	107122	54520
2007	10	756720	102641	71371
2007	11	735384	113648	55415
2007	12	827822	129866	51714
2008	1	941848	129424	42223
2008	2	984790	144137	54594
2008	3	785668	164035	49976
2008	4	1019806	131296	56653
2008	5	1237511	149771	74192
2008	6	1217920	130745	61192
2008	7	1110314	124513	62438
2008	8	1051507	134740	63559
2008	9	846349	117663	56027
2008	10	663795	127926	58461
2008	11	399275	141869	52143
2008	12	309543	143279	43428
2009	1	288745	155644	43306
2009	2	252130	151627	50362
2009	3	347888	186364	58305
2009	4	425485	169373	57722
2009	5	504278	178192	55431
2009	6	569944	135280	54932
2009	7	570194	159900	64566
2009	8	722502	152288	56419
2009	9	570008	164637	46872
2009	10	651838	174583	62104
2009	11	604398	169573	56819
2009	12	776720	198194	57583
2010	1	692358	197844	46918
2010	2	592318	192072	51567
2010	3	826288	204966	60975
2010	4	862276	186109	63169
2010	5	616218	182449	83688

2010	6	789499	138191	82564
2010	7	668913	151220	79355
2010	8	653822	152565	67384
2010	9	737054	141504	69530
2010	10	837063	162616	82651
2010	11	759227	141869	85845
2010	12	916907	181363	76029
2011	1	843433	219959	75424
2011	2	887556	201941	83047
2011	3	1119967	206038	106557
2011	4	929999	213779	107295
2011	5	1120086	199537	97639
2011	6	1042689	165899	101117
2011	7	1044543	172387	109493
2011	8	889739	148023	93504
2011	9	958878	166057	92080
2011	10	941498	185199	98491
2011	11	1006730	173482	101897
2011	12	1014857	194161	111846
2012	1	1300815	188282	90355
2012	2	1124790	178041	90290
2012	3	1104290	216789	120851
2012	4	1151473	190189	102190
2012	5	1163022	191023	121812
2012	6	884249	169874	130923
2012	7	913745	165020	116988
2012	8	1075311	141414	103081
2012	9	1135904	135246	89576
2012	10	985724	149209	94056
2012	11	847699	166169	107341
2012	12	1024206	187146	110937
2013	1	1048794	216921	92687
2013	2	1171419	197417	105965
2013	3	1165254	239613	131039
2013	4	987015	221540	134572
2013	5	1050605	191562	171917
2013	6	1079498	174811	148862
2013	7	1270303	164178	133294
2013	8	1177627	183440	167952
2013	9	1238610	172395	142636
2013	10	1069332	182180	178170
2013	11	969409	189371	203432
2013	12	1183893	221196	174411
2014	1	1059150	233286	183761
2014	2	1090015	191530	209926

2014	3	1264241	231224	235767
2014	4	838187	220172	223367
2014	5	1494127	228904	228264
2014	6	1290071	202456	206503
2014	7	1165224	210652	200725
2014	8	1256990	217941	219539
2014	9	1031365	204928	227357
2014	10	1014851	215386	235700
2014	11	906672	226940	216912
2014	12	605127	224161	183990
2015	1	598258	245916	169179
2015	2	478864	250128	194323
2015	3	584858	259580	196525
2015	4	553615	247001	171974
2015	5	746311	248628	200396
2015	6	646383	228508	188055
2015	7	606389	225261	191832
2015	8	531532	221015	192158
2015	9	495221	202055	184127
2015	10	420546	227415	204546
2015	11	374528	211017	193420
2015	12	318731	241596	193059
2016	1	272556	249118	164920
2016	2	231148	231792	172008
2016	3	333374	231588	180932
2016	4	343734	246981	208108
2016	5	488465	236902	248968
2016	6	511060	205046	232565
2016	7	495643	220953	239753
2016	8	421885	207771	215029
2016	9	447352	208863	224623
2016	10	532296	234352	253641
2016	11	450955	206117	222888
2016	12	525469	254681	216720
2017	1	526949	305556	181306
2017	2	522083	269129	218406
2017	3	488231	275225	245167
2017	4	518023	270537	259716
2017	5	483554	270674	285595
2017	6	458984	246916	281920
2017	7	468231	251805	291874
2017	8	466663	214523	236847
2017	9	545985	217734	230472
2017	10	550541	229792	279099
2017	11	584323	211845	236273

2017	12	576256	270804	291183
2018	1	709265	302050	239142
2018	2	472813	262946	235296
2018	3	635271	307730	286436
2018	4	580099	309097	310952
2018	5	738520	266451	314688
2018	6	670705	192374	217995
2018	7	743028	246762	286852
2018	8	724081	241489	279338
2018	9	738711	248761	253754
2018	10	751994	253220	279405
2018	11	581943	260020	267692
2018	12	506984	305264	263167
2019	1	521242	298710	236450
2019	2	540564	273554	253612
2019	3	715824	304669	321019
2019	4	806887	292709	325238
2019	5	721521	274827	345685
2019	6	567825	261557	360226
2019	7	690814	233176	373019
2019	8	692960	262754	365597
2019	9	611851	252766	304413
2019	10	608854	240631	322392
2019	11	573361	268223	390698
2019	12	679460	331583	292183
2020	1	594389	391452	298117
2020	2	420490	311153	352537
2020	3	312476	352440	296783
2020	4	74812	318253	322285
2020	5	222286	307217	393385
2020	6	427617	322691	310567
2020	7	403225	311135	257482
2020	8	438791	297221	270080
2020	9	455571	247879	288992
2020	10	397911	249859	378389
2020	11	412639	279213	411806
2020	12	524588	280479	243114
2021	1	531232	329951	246595
2021	2	565471	295918	307078
2021	3	673169	301744	347702
2021	4	586833	301775	433825
2021	5	681006	308044	438891
2021	6	708049	266465	447986
2021	7	629064	258502	497277
2021	8	617704	282872	456026

2021	9	607233	252705	515208
2021	10	800605	294296	483895
2021	11	689126	275818	580640
2021	12	188669	317388	568198
2022	1	668971	320901	537244
2022	2	748588	324677	607353
2022	3	1070671	296313	611022
2022	4	883709	275918	631897
2022	5	926562	276940	710888

Anexo 6: Base de datos Anual-2000-2021

PIB	Petróleo	Banano	Camarón
40848994	2144008	821375	285434
41961262	1722333	864515	281386
45406710	1839026	969339	252719
47809319	2372315	1100800	298965
49914615	3898507	1023609	329792
51007777	5396840	1084394	457539
54250408	6934010	1213489	588160
54557732	7428356	1302549	612887
56481055	10568327	1639400	674886
60925064	6284131	1995654	664419
64362433	8951941	2032769	849674
79276664	11799973	2246465	1178389
87924544	12711229	2078402	1278399
95129659	13411759	2354623	1784936
101726331	13016019	2607580	2571813
99290381	6355235	2808119	2279595
99937696	5053937	2734164	2580153
104295862	6189824	3034539	3037858
107562008	7853414	3196165	3234716
108108009	7731163	3295159	3890531
99291124	4684794	3668991	3823534