



**ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL**

**Facultad de Ciencias Naturales y Matemáticas**

“Estimación de la Demanda de Transporte en un Operador  
Logístico con Servicio de Carga Pesada.”

**PROYECTO INTEGRADOR**

Previo a la obtención del Título de:

**Ingeniero en Logística y Transporte**

Presentado por:

José Antonio Balcázar Arévalo

José Daniel Reyes Vera

GUAYAQUIL – ECUADOR

Año: 2019

## DEDICATORIA

A Dios, por darme la oportunidad de estudiar en tan prestigiosa institución, ser el que guio mi camino y mi soporte en todo momento.

A mis Padres por haberme forjado como la persona que soy en la actualidad, el apoyo brindado, los consejos dados y por ser un pilar fundamental en mi vida.

A mi tío, David Reyes por el apoyo incondicional, por los consejos que en su momento fueron de gran importan en mi vida, por estar allí cuando lo he necesitado, por ser como un segundo padre.

A mis mejores Amigos, Kelvin, Rubén, John, Luis, Miguel, Ítalo, Ana y Gabriela que, aunque no los vea a diario, sé que cuento con ellos en todo momento, cuyo apoyo es incondicional y de los mas sincero

A las personas que ya no están conmigo, pero me cuidan desde el cielo, a ellos gracias por el tiempo que me permitieron amarlos, y mantengo la fe de que volveremos a vernos algún día.

***José Daniel Reyes***

A Dios y a la Virgen de Chilla, que son en los que deposite mi fe para alcanzar este logro tan anhelado.

Mi madre, Elsa Arévalo, por estar ahí incondicionalmente, por creer en mí, por ser el pilar fundamental de todo lo que soy, por ser una mujer fuerte y valiente para poder guiarme por el buen camino.

Mi abuela, Elsa Abril, mi segunda madre, quien me dio su apoyo incondicional, por estar pendiente en todo momento, cuidándome y guiándome.

Mi padre, Antonio Balcázar, por las experiencias, conocimientos y consejos que ha sabido darme durante toda mi vida.

Mis hermanos, Gabriel y Natalia, por su amor y cariño, por saber remar hacia el mismo lado en los momentos difíciles.

Finalmente, dedicar esta tesis a esos familiares que han sido importantes en mi vida, y a quienes guardo con cariño, pero ya no están presentes.

***José Balcázar Arévalo***

## **AGRADECIMIENTOS**


A la Escuela Superior Politécnica del Litoral por brindarnos una excelente educación, en un entorno agradable con todos los recursos posibles para hacer de este viaje, una experiencia única e inolvidable, que marcara un antes y un después en nuestras vidas.

A nuestros profesores y amigos, MSc. Guillermo Baquerizo y MSc Carlos Martin, quienes estuvieron apoyándonos en toda nuestra carrera y aún más en el proceso final, con sus consejos que fueron de gran importancia para culminar con éxito esta etapa.

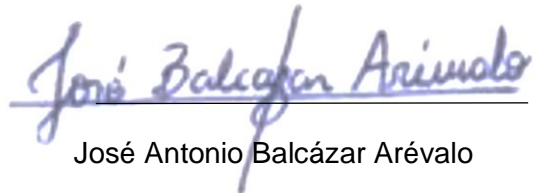
A la empresa donde se realizó este proyecto por abrirnos las puertas, y compartir con nosotros su problemática, siempre dispuesta a ayudarnos en todo lo que este a su alcance.

## DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; *José Daniel Reyes Vera* y *José Antonio Balcázar Arévalo*, damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”

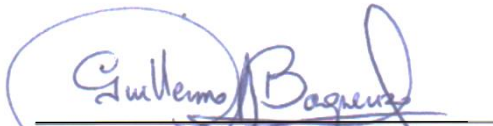


José Daniel Reyes Vera



José Antonio Balcázar Arévalo

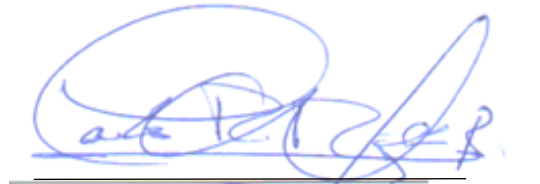
## EVALUADORES



Handwritten signature of Guillermo Baquerizo in blue ink, written over a horizontal line.

MSc. Guillermo Baquerizo

PROFESOR DE LA MATERIA



Handwritten signature of Carlos Martín in blue ink, written over a horizontal line.

MSc. Carlos Martín

PROFESOR TUTOR

## RESUMEN

Estadísticamente hablando, la demanda del servicio de transporte por parte de los clientes, aumenta los fines de mes, por lo tanto, el departamento de planeación de la operación se ve obligado a trabajar al máximo para cubrir la totalidad de los requerimientos, es así como nace la necesidad de tener una herramienta con la cual pueda predecir el comportamiento de la demanda en un tiempo determinado, obteniendo como resultado un servicio eficaz y oportuno.

La ineficaz planeación en cuanto a sus operaciones conlleva: incumplimientos de los servicios que el cliente requiere, retrasos en cargas y entregas, clientes insatisfechos, gastos no presupuestados (contratación a terceros), o en algunos casos, la pérdida total de la operación dañando la imagen de la empresa.

El presente proyecto tiene como objetivo, mostrar una solución a este problema, para lo cual, se diseñó una herramienta informática para poder estimar la demanda, en base a los datos históricos recopilados y proporcionados por esta empresa.

Con esta herramienta informática se podrá pronosticar la demanda, ya sea, semanal, mensual, o anual de cada cliente, dependiendo del caso que la empresa crea oportuno, la cual fue creada con todas las características que implican un análisis de series de tiempo.

Se analizaron las demandas históricas de los clientes KC y CG, y, de acuerdo con las particularidades que presentó cada una de ellas, se pudo determinar que el modelo estacional autorregresivo integrado de media móvil (SARIMA), es con el que se puede realizar el ajuste de la serie, para posteriormente obtener el pronóstico, en este caso semanal, de cada cliente con el menor error porcentual absoluto medio (MAPE).

## ABSTRACT

From an analytical perspective, the clients demand for transport service from a company increases at the end of the month, therefore, the operations planning department works tirelessly to fulfill all of its clients' requests. This is how gathering big data to create a prediction tool in order to regulate periodic demand levels comes to mind, subsequently, obtaining efficient and timely results.

The department's lack of planning through tasks may lead to: unfulfilled client service requests, product loading and delivery delays, unsatisfied clients, over-budgeting (e.i. hiring subcontractors), and/or in certain instances, forever damaging the company's image by completely forgoing operations.

The objective of this project is to come up with a solution to this problem. In order to accomplish this, a data tool was designed to determine the demand levels based on commutative past data provided by the company.

With this informational tool, along with the analysis of timely characteristics, we can predict weekly, monthly, or even annual requests from each client and combine it with the company's productivity.

The KC and CG clients' past demands were analyzed and according to their individual particularities, it was determined that by using the fickle media information of the seasonal autoregressive integrated moving average (SARIMA) we can manage the necessary adjustments, to therefore obtain a likely outcome of each client's weekly demands with a minimal margin of error, also known as; mean absolute percentage error (MAPE).



# ÍNDICE GENERAL

1	CAPITULO.....	17
1.1	INTRODUCCIÓN .....	17
1.2	Descripción del Problema.....	18
1.3	Antecedentes.....	18
1.4	Situación Actual.....	19
1.5	Diagrama de la problemática.....	19
1.6	Justificación .....	21
1.7	Objetivos .....	21
1.7.1	Objetivo General.....	21
1.7.2	Objetivo Específicos .....	21
1.8	Marco Teórico.....	22
1.8.1	Revisión de la Literatura.....	22
1.9	Marco Conceptual .....	25
1.9.1	Demanda.....	25
1.9.2	Pronósticos o Predicciones .....	25
1.9.3	Series de Tiempo .....	25
1.9.4	Modelos de Autoregresión.....	28
1.9.5	Metodología Box-Jenkins .....	31
1.9.6	Modelos SARIMA.....	34
1.9.7	Error Porcentual Absoluto Medio (MAPE).....	35

2	CAPITULO.....	36
	<b>2 METODOLOGÍA DE TRABAJO .....</b>	<b>36</b>
	<b>2.1 Procedimiento de extracción de Datos .....</b>	<b>36</b>
	<b>2.2 Depuración de datos.....</b>	<b>36</b>
	<b>2.3 Análisis de información mediante el uso de series de tiempo. ....</b>	<b>36</b>
	<b>2.4 Flujograma de actividades.....</b>	<b>37</b>
	<b>2.5 Cronograma de actividades.....</b>	<b>39</b>
	<b>2.6 Aplicaciones informáticas utilizadas.....</b>	<b>40</b>
3	CAPITULO.....	41
	<b>3.1 Tratamiento y depuración de datos:.....</b>	<b>41</b>
	<b>3.2 Análisis de datos mediante series de tiempo.....</b>	<b>46</b>
	<b>3.2.1 Análisis para la empresa CG .....</b>	<b>46</b>
	<b>3.2.2 Análisis para la Empresa KC.....</b>	<b>64</b>
	<b>3.3 Interfaz.....</b>	<b>79</b>
4	CAPÍTULO.....	86
	<b>4.1 Conclusiones y Recomendaciones .....</b>	<b>86</b>
	<b>4.1.1 Conclusiones .....</b>	<b>86</b>
	<b>4.1.2 Recomendaciones .....</b>	<b>87</b>
	<b>BIBLIOGRAFÍA.....</b>	<b>88</b>

## ABREVIATURAS

<b>MA</b>	MODELOS DE MEDIA MÓVIL
<b>AR</b>	MODELOS AUTORREGRESIVOS
<b>ARMA</b>	MODELO AUTORREGRESIVO DE PROMEDIO MÓVIL
<b>ARIMA</b>	AUTOREGRESSIVE INTEGRATED MOVING AVERAGE MODEL MODELO AUTORREGRESIVO INTEGRADO DE PROMEDIO MÓVIL
<b>SARIMA</b>	SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE MODEL MODELO ESTACIONAL AUTORREGRESIVO INTEGRADO CON MEDIAS MÓVILES
<b>FAC</b>	FUNCIÓN DE AUTOCORRELACIÓN SIMPLE
<b>FAP</b>	FUNCIÓN DE AUTOCORRELACIÓN PARCIAL
<b>MAPE</b>	ERROR PORCENTUAL ABSOLUTO MEDIO
<b>AIC</b>	CRITERIO DE INFORMACIÓN AKAIKE
<b>BIC</b>	CRITERIO DE INFORMACIÓN BAYESIANO

## ÍNDICE DE ILUSTRACIONES

Ilustración 1.1 Diagrama de la Problemática .....	20
Ilustración 1.2 Componentes de una Serie de Tiempo.....	28
Ilustración 1.3 Etapas de la metodología Box-Jenkins. ....	32
Ilustración 1.4 Metodología Box-Jenkins .....	32
Ilustración 2.1 Tabulación de la Información .....	38
Ilustración 2.2 Cronograma de Actividades .....	39
Ilustración 3.1 Serie de tiempo semanal CG Enero 2017- Junio 2019.....	46
Ilustración 3.2 Función Autocorrelación Simple.....	47
Ilustración 3.3 Componentes de la Serie de Tiempo CG.....	48
Ilustración 3.4 Transformación Box-Cox/Logaritmo .....	49
Ilustración 3.5 Diferencias .....	50
Ilustración 3.6 Diferenciación Estacional .....	51
Ilustración 3.7 Diferenciación Estacional y Ordinaria.....	52
Ilustración 3.8 Test de Estacionariedad .....	53
Ilustración 3.9 ACF-Residuos.....	54
Ilustración 3.10 PACF-Residuos.....	55
Ilustración 3.11 ACF-Residuos.....	56
Ilustración 3.12 PACF-Residuos.....	57
Ilustración 3.13 ACF-Residuos-Ruido Blanco .....	58
Ilustración 3.14 PACF-Residuos-Ruido Blanco.....	59
Ilustración 3.15 Auto-Arima .....	59
Ilustración 3.16 Diagnóstico de la Serie Original.....	60
Ilustración 3.17 Diagnóstico de la Serie Ajustada .....	61
Ilustración 3.18 Predicción CG .....	62
Ilustración 3.19 Serie de Tiempo Semanal KC Enero 2018-Julio 2019 .....	64

<b>Ilustración 3.20 Funcion autocorrelación Simple .....</b>	<b>65</b>
<b>Ilustración 3.21 Transformación Box-Cox/Logaritmo .....</b>	<b>66</b>
<b>Ilustración 3.22 Prueba de Diferencias .....</b>	<b>67</b>
<b>Ilustración 3.23 Diferenciación Estacional .....</b>	<b>67</b>
<b>Ilustración 3.24 Diferenciación Estacional y Ordinaria.....</b>	<b>68</b>
<b>Ilustración 3.25 Test de Estacionariedad .....</b>	<b>69</b>
<b>Ilustración 3.26 Función Autocorrelación Simple de la serie diferenciada.....</b>	<b>70</b>
<b>Ilustración 3.27 Función Autocorrelación Parcial.....</b>	<b>70</b>
<b>Ilustración 3.28 ACF-Residuos.....</b>	<b>72</b>
<b>Ilustración 3.29 PACF-Residuos.....</b>	<b>72</b>
<b>Ilustración 3.30 ACF-Ruido Blanco .....</b>	<b>74</b>
<b>Ilustración 3.31 PACF-Ruido-Blanco .....</b>	<b>74</b>
<b>Ilustración 3.32 Auto-Arima .....</b>	<b>75</b>
<b>Ilustración 3.33 Supuestos de Normalidad de la Serie No Diferenciada .....</b>	<b>76</b>
<b>Ilustración 3.34 Supuestos de Normalidad de la Serie Diferenciada.....</b>	<b>76</b>
<b>Ilustración 3.35 Pronóstico KC .....</b>	<b>77</b>
<b>Ilustración 3.36 Ventana de Inicio de la Aplicación .....</b>	<b>79</b>
<b>Ilustración 3.37 Opciones para el Análisis.....</b>	<b>80</b>
<b>Ilustración 3.38 Ventana de Análisis Preliminar .....</b>	<b>81</b>
<b>Ilustración 3.39 Ventana de Análisis Preliminar .....</b>	<b>81</b>
<b>Ilustración 3.40 Ventana de Diferenciación de la Serie.....</b>	<b>82</b>
<b>Ilustración 3.41 Ventana de Ajuste del Modelo .....</b>	<b>83</b>
<b>Ilustración 3.42 Ventana de Pronóstico .....</b>	<b>84</b>
<b>Ilustración 3.43 Archivo de Excel con valores del Pronóstico .....</b>	<b>85</b>

## INDICE DE TABLAS

<b>Tabla 1.1 Tabla identificación y selección del modelo .....</b>	<b>33</b>
<b>Tabla 3.1 Demanda Semanal CG Enero 2017-Junio 2019 .....</b>	<b>44</b>
<b>Tabla 3.2 Demanda Semanal KC Enero 2018-Junio 2019 .....</b>	<b>46</b>
<b>Tabla 3.3 Pronóstico Semanal CG Julio 2019-Junio 2020 .....</b>	<b>64</b>
<b>Tabla 3.4 Pronóstico Semanal KC Julio 2019-Junio 2020.....</b>	<b>78</b>

## GLOSARIO DE TERMINOS

**AUTOCORRELACIÓN:** Es la correlación entre dos variables que se encuentran en las observaciones de la serie separadas en periodos de tiempo.

**AUTOREGRESIÓN:** Es un tipo de modelo que representa a un proceso aleatorio, este muestra algunos procesos que pueden variar a través del tiempo como economía, transporte, naturaleza, etc.

**CORRELOGRAMA:** El correlograma es una representación gráfica de la autocorrelación, para nuestro caso será una gráfica de las autocorrelaciones de la muestra versus el tiempo.

**DETERMINÍSTICO:** Los datos de este modelo son conocidos con seguridad y al analizarlos se tendrá a disposición la información necesaria para la toma de decisiones.

**DEMANDA:** Es la cantidad total que la gente, o en este caso, consumidores, desea obtener ya sea de un bien o servicio.

**ERROR:** Lo podemos definir como la diferencia que se da entre una medición dada y la realidad.

**ESTACIONARIO:** Se refiere cuando las variables que muestran su comportamiento se mantienen en el mismo estado respecto al tiempo sin tener variaciones.

**ESTIMACIÓN:** Proceso con el cual se puede hallar una aproximación sobre alguna medida, esto puede servir para encontrar valores de datos que están incompletos.

**ESTOCÁSTICO:** Modelo donde es desconocido algún elemento con antelación, por ende, la incertidumbre crece.

**HOMOGENEIDAD:** Se la define a la igualdad mayor o menor de los valores de una variable o de una combinación de características en un conjunto.

**OPERADOR LOGÍSTICO:** Empresa encargada del diseño de la cadena de suministro ya sea en su totalidad o para ciertas etapas de estas como pueden ser el aprovisionamiento, transporte, almacenaje y distribución de mercancía.

**PLANEACIÓN:** Conjunto de acciones, procedimientos y lineamientos para poder resolver sin inconvenientes alguna investigación establecida.

**PRONÓSTICO:** Es el proceso donde se estima series de tiempo o en este caso datos que se requiere estudiar.

**REZAGOS:** Término para definir un atraso, residuo



# 1 CAPITULO.

## 1.1 INTRODUCCIÓN

En la actualidad y a lo largo de la historia, especialmente en empresas que trabajan en el sector logístico, la correcta administración de los procesos que se manejan dentro de la misma es primordial para cumplir con éxito los estándares requeridos por cada uno de los clientes, es por eso la necesidad de una buena planificación, la cual permita optimizar procesos dentro de la empresa, satisfacer la demanda y expectativas requerida por los clientes.

Por normas de confidencialidad se dará, un nombre distinto a la empresa donde se realizará el análisis y proyecto de tesis, se la denominará ASSOCIATES CO, la cual es un operador logístico dedicado al servicio de transporte de carga a grandes empresas de consumo masivo las cuales son muy conocidas y abarcan gran parte del mercado nacional.

Para este trabajo se implementará una aplicación, la cual permita planificar y pronosticar el número de vehículos de carga pesada que se necesiten utilizar para cada período de tiempo durante el año en curso, para aquello se tomarán en cuenta datos históricos que han sido facilitados; de esta manera se podrá contribuir a la optimización del proceso de planeación de la operación, mejoras en el nivel de servicio y reducción de contratación de vehículos eventuales cada fin de mes si así fuera el caso.

## **1.2 Descripción del Problema**

ASSOCIATES CO es un operador logístico 3PL, el cual se especializa en dar soluciones integrales en lo concerniente a la transportación de carga pesada de la industria en general, la empresa tiene un sistema de gestión mediante monitoreos, la cual permite controlar con eficacia los procesos de tránsito, seguimiento, entrega y facturación.

En cuanto a los procesos de planificación de la operación, para estimar el número de vehículos que se requieren tener disponibles no es eficiente, lo realizan empíricamente, especialmente cuando se tiene picos de demanda en fin de mes.

De aquí nace la necesidad de implementar una aplicación, la cual ayude a planificar de una manera anticipada el número de vehículos de transporte de carga pesada necesarios y evitar el no poder cumplir con lo que demanda los clientes y mantener un buen nivel de servicio.

## **1.3 Antecedentes**

Esta empresa nació en el año 1970 en Colombia tras la unión de dos empresas que ya tenían algún tiempo dedicándose al negocio del transporte de carga pesada, en vista de la creciente demanda en cuanto a proyectos de ingeniería, que en ese entonces se desarrollaba en dicho país, además de la necesidad de atender el dinámico intercambio internacional de mercancías que se movilizaban a través de la frontera norte con Venezuela.

Con el pasar del tiempo, la empresa se fue abriendo campos en otros ámbitos hasta llegar a prestar sus servicios a la industria aplicando los conocimientos adquirido durante años.

## **1.4 Situación Actual**

Actualmente la empresa cuenta con su oficina principal en la ciudad de Quito y sucursales en las ciudades de Guayaquil y Tulcán, para brindar sus servicio de transportación de carga pesada en la sierra y costa ecuatoriana.

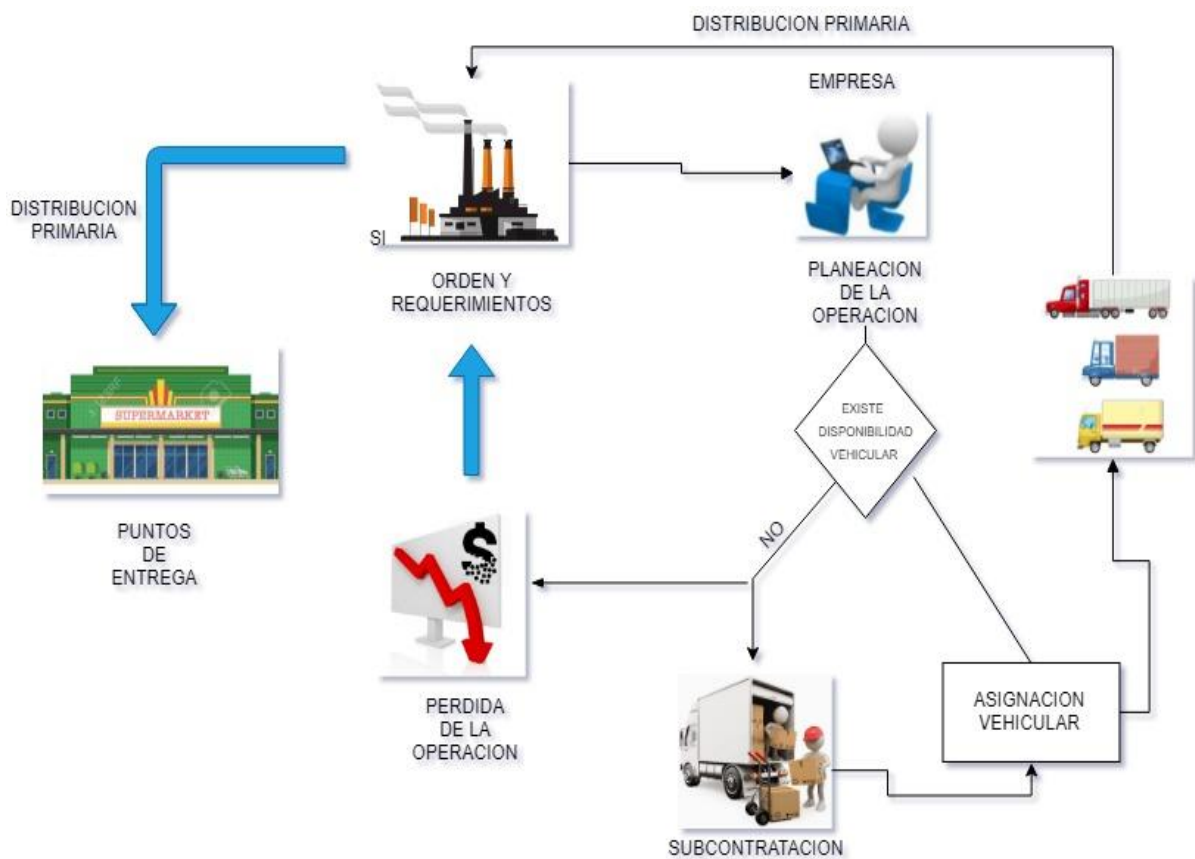
Cuenta con 6 vehículos de carga propios, el 99% de la flota pertenece a varias empresas que trabajan en conjunto, esto equivale a unos 200 vehículos de diferentes tipos.

El proceso de planeación de la operación se la realiza de manera empírica, sin ningún sustento ni herramienta que ayude a planificar y predecir la demanda de sus clientes, el encargado de este proceso lo, realiza en base a la experiencia que este tiene en el cargo.

## **1.5 Diagrama de la problemática.**

Dentro de la planeación estratégica de la empresa en el proceso de planeación de la operación es, donde se presentan inconvenientes ya que no poseen una aplicación, la cual ayude a predecir o pronosticar el número de vehículos de carga que se necesitan para satisfacer la demanda de sus clientes, sus principales clientes que además son clientes fijos son empresas dedicadas a la fabricación de productos de consumo masivo.

Al no poseer esta aplicación que realice un pronóstico adecuado, la empresa incurre en algunas ocasiones, en subcontratar para poder cumplir con el cliente y en algunos casos simplemente se pierde la operación, lo cual ocasiona gastos y perdidas a la empresa.



**Ilustración 1.1 Diagrama de la Problemática**  
**Elaboración: Propia**

Diagrama en el cual se muestra la problemática actual de la empresa, que comienza cuando el cliente emite su requerimiento, y esta es aceptada y verificada por la parte operativa, que a su vez confirma la disponibilidad de flota para cubrir esa demanda y envía de ser el caso la flota a los puntos que se acuerde con el cliente inicial.

## **1.6 Justificación**

La mala planificación en cuanto a la parte operacional de la empresa puede incurrir en gastos no presupuestados, clientes insatisfechos por un mal servicio y demás, esto se traduce finalmente en pérdidas económicas.

Poder predecir o anticiparse a lo que pueda suceder, en este caso poder predecir la demanda de sus clientes con ayuda de datos históricos que esta ha ido recabando es de gran importancia para que así la empresa pueda estar preparada y brinde un servicio adecuado con tiempos de respuesta rápida, es por aquello, la necesidad de realizar una aplicación la cual pueda ayudar a una buena planificación de sus operaciones como operador logístico.

## **1.7 Objetivos**

### **1.7.1 Objetivo General**

El objetivo general tiene como finalidad, describir lo que se quiere alcanzar al finalizar el proyecto.

El objetivo general de este proyecto es el siguiente:

- Conocer la cantidad de vehículos de carga pesada que requiere tener la empresa para satisfacer la demanda del servicio, mediante el diseño de una aplicación informática que ayude a pronosticar con análisis de series de tiempo.

### **1.7.2 Objetivo Específicos**

Los objetivos específicos son los pasos que se seguirán para poder llegar a la solución del proyecto y por ende alcanzar el objetivo general anteriormente descrito.

Los objetivos específicos son los siguientes:

- Analizar la situación histórica y actual del manejo de transporte de la empresa.
- Pronosticar la demanda de vehículos de carga pesada que se van a necesitar en períodos futuros, usando un estudio de series de tiempo.
- Desarrollar una aplicación informática que ayude en el proceso de planificación de manera oportuna basado en demandas anteriores de los clientes.

## 1.8 Marco Teórico

### 1.8.1 Revisión de la Literatura

Para el propósito de este proyecto se analizarán artículos que tengan relación con la problemática que hemos descrito anteriormente con el fin de que podamos sacar de los mismos, información valiosa que pueda ser de gran utilidad.

#### 1.8.1.1 Pronóstico de demanda de uso de aeropuertos en Argentina al 2022.

- **Autor:** José Ignacio López Sáez.
- **Origen:** Buenos Aires, Argentina.
- **Año:** 2018
- **Dirección Url:** [https://ri.itba.edu.ar/bitstream/handle/123456789/1230/TFI%20-%20Jose\\_%20Ignacio%20Lopez%20Sa\\_ez.pdf?sequence=1&isAllowed=y](https://ri.itba.edu.ar/bitstream/handle/123456789/1230/TFI%20-%20Jose_%20Ignacio%20Lopez%20Sa_ez.pdf?sequence=1&isAllowed=y)

Este documento nos muestra un análisis de series de tiempo, en la mayoría de los negocios, se desea ser capaz de estimar la demanda futura de un producto o servicio dado, y en este caso es de vital de importancia saber el numero de usuarios que circularan en la terminal aérea, y poder asignar los recursos necesarios.

En este estudio se han evaluado en total 4 modelos de proyección de series de tiempo: Holt-Winters, ARIMA, Prophet y redes neuronales (procedimientos de aprendizaje automático

o machine learning), para las cuales se probaron tres implementaciones distintas en R. Se obtiene así el resultado de proyección de pasajeros domésticos e internacionales para cada una de estas seis implementaciones y para todos los aeropuertos de la Argentina para un horizonte de 5 años (60 meses a partir del último disponible), con su error de ajuste.

El análisis sobre series temporales permite utilizar la información histórica para ofrecer un número aproximado de dicho valor, dentro de un rango de probabilidades determinado en el cual se pronostica mediante un estudio de información histórica, la demanda futura del uso de los aeropuertos en argentina,

Gracias a la ayuda de este análisis de series de tiempo se pudo modelar el comportamiento histórico de la demanda de transporte de carga pesada en estos aeropuertos y además poder pronosticar demandas futuras.

#### **1.8.1.2 Pronóstico para minoristas: Investigación y Practica**

- **Autor:** Robert Fildes
- **Origen:** Tägerwilen, Suiza.
- **Año:** 2018
- **Dirección**
- **Url:** [https://mpra.ub.unimuenchen.de/89356/1/MPRA\\_paper\\_89356.pdf](https://mpra.ub.unimuenchen.de/89356/1/MPRA_paper_89356.pdf)

Este documento introduce los problemas que tienes los minoristas en pronosticar la demanda, tanto en lo estratégico como en la parte operativa, tener un entorno rico en datos y saber agruparlos de manera correcta mejoran los pronósticos, pero el éxito depende de las características de los datos y los factores comunes que influyen en las ventas y la demanda potencial.

El artículo concluye con alguna evidencia que describe la empresa, predicción práctica, ofreciendo conclusiones sobre las brechas de investigación, pero también las barreras para mejorar.

### **1.8.1.3 La Dinámica para evaluar los métodos de pronóstico para la demanda de pasajeros en el aeropuerto internacional de Nigeria.**

- **Autor:** Adeniran O, Sthephens M.
- **Origen:** Akure, Nigeria.
- **Año:** 2018
- **Dirección**
- **Url:** <https://www.longdom.org/open-access/the-dynamics-for-evaluating-forecasting-methods-for-international-airpassenger-demand-in-nigeria-2167-0269-1000366.pdf>

Este documento examina la dinámica para evaluar diferentes métodos de pronóstico para pasajeros aéreos internacionales en Nigeria. Se logro los objetivos pronosticando la demanda internacional de pasajeros aéreos en el año 2018. utilizando dos promedios móviles únicos, cuatro promedios móviles únicos y seis promedios móviles únicos; el mismo pronóstico era también se logra utilizando un suavizado exponencial simple, con constantes de suavizado de 0.7, 0.8 y 0.9 respectivamente.

El método de pronóstico más apropiado se determinó comparando todos los promedios móviles únicos con Suavización exponencial. Este estudio es muy esencial para la gestión aeroportuaria, la gestión de líneas aéreas, los concesionarios de Servicios aeronáuticos y no aeronáuticos, terceros, agencias gubernamentales y ministerios, reguladores económicos, analistas y planificadores de políticas de transporte, y otras agencias interesadas, para una planificación precisa que afecte a la Operaciones de transporte aéreo internacional y ayuda a prevenir problemas de exceso de transporte aéreo.



## **1.9 Marco Conceptual**

Para desarrollar este proyecto se utilizará los siguientes conceptos, los cuales nos darán información y serán de ayuda para el entendimiento del análisis y resolución del proyecto.

### **1.9.1 Demanda.**

Cantidad de unidades que se deberá obtener del inventario para un determinado fin, como ventas, producción, transporte en un periodo determinado de tiempo.

Si podemos planificar la demanda a futuro, podemos evitar la rotura de stock, aumentar las ventas, puesto que se podría satisfacer la demanda en todo momento, adquiriendo una mayor comprensión del mercado, que permitirá introducir mejoras e innovar y mejorar el nivel de servicio.

### **1.9.2 Pronósticos o Predicciones**

Los pronósticos o predicciones nos pueden ser de mucha utilidad en los procesos de toma de decisiones de una empresa, la aplicación de este ofrece ayudar a pequeñas y grandes empresas, por ejemplo, desde la determinación de los requerimientos de inventario de una pequeña tienda en un barrio hasta la estimación de ventas de teléfonos inteligentes en grandes empresas. Para que se pueda lograr un pronóstico de calidad se requiere que los datos históricos que se han recopilados lo hayan hecho de forma adecuada.

### **1.9.3 Series de Tiempo**

Las series de tiempo son datos estadísticos que se toman mediante observaciones, recopilaciones o registros en ciertos intervalos de tiempo, estos intervalos pueden ser diarios, semanales, semestrales, anuales y más.

El comportamiento de los datos que hayan sido recopilados es de diferentes maneras a través del tiempo, estos pueden presentar tendencia, o pueden no tener una forma definida

o aleatoria(ciclo), variaciones según la estacionalidad entre otras. Denotaremos a las observaciones de una serie de tiempo como  $\gamma_1, \gamma_2, \dots, \gamma_t$ , donde  $\gamma_t$  será el valor que tomará la serie en el instante t.

### 1.9.3.1 Modelo de Series de Tiempo

La orientación que tiene los modelos de series de tiempo es de orden predictivo, en estos casos los pronósticos son elaborados en base al comportamiento pasado de las variables que se están estudiando o hayan sido de interés. Son dos los tipos de modelos, estos son:

- **Modelos Deterministas**

Estos modelos son de menor precisión por su simplicidad relativa, son métodos de extrapolación sencillos. Como ejemplo de esta clase de modelos podemos tomar a los modelos de promedio móvil en los cuales se calcula el pronóstico de la variable promediando los n valores anteriores de la serie.

- **Modelos Estocásticos**

Estos modelos ayudan a la construcción de modelos aproximados que puedan servir para generar los pronósticos, asumiendo que la serie que ha sido observada fue extraída de un grupo de variables aleatorias con distribución parecida que es difícil de determinar.

La serie de tiempo  $\{\gamma_t\}_{t=1}^T$  puede ser estacionaria o no estacionaria:

- **No Estacionaria:**

En la serie no estacionaria, su media, varianza y covarianza cambian con el pasar del tiempo, esta característica hace que su modelamiento sea difícil.

- **Estacionaria:**

A diferencia de la serie no estacionaria, en la serie estacionaria, su media y su varianza no cambian con el pasar del tiempo, esta característica hace que su modelamiento sea a través de una ecuación con coeficientes fijos que han sido estimados en base a datos pasados.

### 1.9.3.2 Componentes de una Serie de Tiempo

Una serie de tiempo se puede descomponer en cuatro componentes. Estos componentes son los siguientes:

- **Tendencia (T):**

La tendencia es el componente que predomina en la serie de largo plazo, este componente representa el crecimiento o disminución de los datos de una serie de tiempo, este crecimiento o disminución permanecerá durante un lapso largo en el tiempo, quiere decir que no cambiara en un futuro lejano.

- **Ciclo (C):**


Este componente se caracteriza por ser un conjunto fluctuaciones en forma de onda llamados también oscilaciones, estas oscilaciones están alrededor de la tendencia, que permanecen por un largo y desconocido periodo (más de un año).

- **Estacionalidad (E):**

A diferencia de un ciclo, las fluctuaciones son estacionales, esto quiere decir que es un movimiento que permanece por un corto y además de conocido periodo, puede ser trimestre, mes o semanas.

- **Aleatorio (A):**

Este componente es impredecible ya que sus fluctuaciones no siguen un patrón y sus causas pueden ser diversas no predecibles o no periódicas.



**Ilustración 1.2 Componentes de una Serie de Tiempo**

**Elaboración: Series de Tiempo (Universidad de Chile 2008)**

#### **1.9.4 Modelos de Autoregresión.**

Los modelos ARIMA son conocidos también como metodología de Box-Jenkins, estos modelos son utilizados para realizar el análisis y predicciones de las series de tiempo.

Estos modelos nos dan la ventaja de poder realizar predicciones óptimas tanto a inmediato como a corto plazo, además, para su estimación y pronóstico no es imprescindible el tener varias series; con tal de tener la serie que se vaya a estudiar y sus rezagos es suficiente. Esta metodología nos permite la elección de entre varios modelos dependiendo de cómo se comporta la serie de tiempo que requiera estudiar.

### 1.9.4.1 Modelo ARMA(p,q)

Es un modelo lineal, con este modelo podemos realizar predicciones de futuros valores que puede ir tomando la serie. Tiene dos partes, la primera parte autorregresiva (AR) y la otra parte de media móvil (MA).

- **Componente Autorregresivo (AR):** Este componente se lo expresa con la letra **p** y nos muestra el número de observaciones pasadas que se van a utilizar para poder predecir la serie de tiempo, es decir es la variable dependiente con los valores de observaciones pasadas.
- **Componente de Media Móvil (MA):** Este componente se lo denota con la letra **q** y nos muestra los valores de los errores de períodos anteriores de los que se están analizando.

Siendo la serie  $\{\gamma_t\}$ . La expresión general para el modelo ARMA es:

$$\gamma_t = C + \beta_1\gamma_{t-1} + \dots + \beta_p\gamma_{t-p} + \alpha_1\epsilon_{t-1} + \dots + \alpha_q\epsilon_{t-q} + \epsilon_t$$

### 1.9.4.2 Modelo ARIMA(p,d,q)

Sus siglas significan modelo autorregresivo integrado de media móvil. El fin de este modelo es de buscar y encontrar los patrones para poder realizar la predicción.

Un modelo ARIMA(p,d,q) se edifica en base a los modelos ARMA(p,q) sobre la diferenciada d veces.

La expresión general para un modelo ARIMA es:

$$\gamma_t^{(d)} = C + \beta_1\gamma_{t-1}^{(d)} + \dots + \beta_p\gamma_{t-p}^{(d)} + \alpha_1\epsilon_{t-1}^{(d)} + \dots + \alpha_q\epsilon_{t-q}^{(d)} + \epsilon_t^{(d)}$$

Tenemos como  $\gamma_t^{(d)}$  a la serie de diferencias de orden d y  $\epsilon_t^{(d)}$  será la serie de los errores cometidos en la serie anterior.

### 1.9.4.2.1 ¿Cómo se identifican los modelos ARIMA(p,d,q)?

Para la identificación del modelo ARIMA que caracteriza a la serie se debe precisar lo siguiente:

- **Establecer el grado de homogeneidad de la serie:**

Al tratarse de datos estadísticos, se requiere como requisito que estos datos sean de la misma naturaleza y origen, por ende, que cuando estos hayan sido recopilados lo hayan hecho con procesos parecidos; si esto no se cumple es necesario que la serie sea ajustada, de este modo haremos que las estimaciones estadísticas sean lo más parecidas posibles.

Para poder establecer el grado de homogeneidad comúnmente se utiliza el correlograma y test de raíz unitaria.

- **Establecer el orden de las partes promedio móvil y autorregresivas del modelo:**

Para esto debemos realizar un análisis a las funciones de autocorrelación total y estimada.

**Función de autocorrelación simple:** En los procesos estacionarios, esta función es la siguiente:

$$h_k = \frac{g_k}{g_0} = \frac{Cov(X_t, X_{t+k})}{Var(X_t)} \quad \text{donde } h = \dots, -2, -1, 0, 1, 2, \dots$$

Para procesos que son reales debemos comprobar:

$$g_0 > 0, g_k = g_{-k}, h_k = h_{-k}, h_0 = 1 \text{ y } |h_k| \leq 1$$

En la gráfica de los correlogramas observaremos en el eje de las ordenadas a  $h_k$  y en las abscisas a  $k$ .

**Función de autocorrelación parcial:** Sea las observaciones  $(X_t)_{t=1,2,3,\dots,T}$ , concernientes a un proceso estocástico y estacionario, la estimación de su media será:

$$\bar{X} = \sum_{t=1}^T \frac{X_t}{T}$$

Por ende, la función de autocorrelación  $h_k$  la definiremos de la siguiente manera:

$$r_k = \frac{\sum_{t=1}^T (X_t - \bar{X})(X_{t-k} - \bar{X})}{\sum_{t=1}^T (X_t - \bar{X})^2}$$

Gráficamente a  $r_k$  se lo denomina como correlograma muestral, este gráfico es muy importante al momento del análisis de la serie de tiempo.

- **Ajuste de datos.**

Se debe verificar que sea un buen modelo para la serie de tiempo, para aquello, el modelo debe tener un buen ajuste, los residuos que tenga este ajuste deben comportarse como ruido blanco.

**Ruido Blanco:** Este proceso es netamente aleatorio y está definido de la siguiente manera:

$$\mu = E(X_t) = 0, g_0^2 = var(X_t), g_k = cov(X_t, X_{t+k}) = 0 \text{ donde } k = \dots, -2, -1, 0, 1, 2, \dots$$

Las expresiones descritas anteriormente quieren decir que su media debe ser cero, su varianza constante y simétrica.

## 1.9.5 Metodología Box-Jenkins

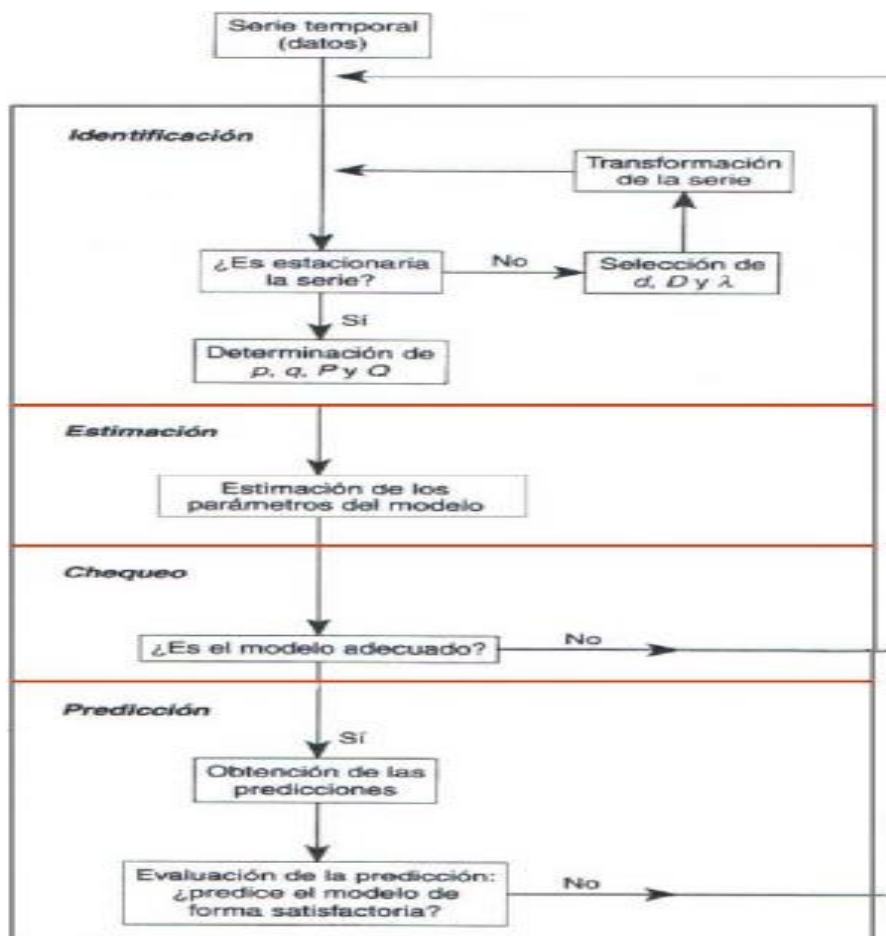
Esta metodología tiene como fin que las predicciones que se requieren hacer sean realizadas en base a un modelo estadístico factible, el cual ayude a generar la información

necesaria especialmente para eventos futuros, en consecuencia, este modelo debe ser estacionario o estable siempre y cuando las características de la serie sean constantes a lo largo del tiempo.

### 1.9.5.1 Etapas de la metodología.



**Ilustración 1.3 Etapas de la metodología Box-Jenkins.**  
Elaboración: Propia



**Ilustración 1.4 Metodología Box-Jenkins**  
Elaboración: Santiago de la Fuente Fernández-Universidad Autónoma de Madrid



### 1.9.5.1.1 Identificación y selección del modelo

Luego de la obtención de los datos debemos identificar los valores apropiados de **p**, **d** y **q**, para aquello, la herramienta que nos puede servir para identificarlos serán los correlogramas.

Para aquellas series que muestren tendencia, como primer paso se debe lograr que la serie sea estacionaria, para esto se debe usar diferenciación **d** veces hasta que esta logre ser estacionaria. A partir de que la serie sea estacionaria se puede usar los criterios FAC (función de autocorrelación simple) y FAP (función de autocorrelación parcial) para así poder obtener un modelo tentativo. En caso de que la serie tenga componentes estacionales, el modelo se convierte en SARIMA

TIPO DE MODELO	FAC	FAP
MA(q)	Los coeficientes q significativos son tan solo los primeros. A partir del rezago q se anulan abruptamente	Decrecimiento rápido de tipo exponencial atenuado u sinoidal.
AR(p)	Decrecimiento rápido de tipo exponencial atenuado u sinoidal.	Los coeficientes p significativos son tan solo los primeros. A partir del rezago p se anulan abruptamente
ARMA	Coefficientes p y q no son anulados abruptamente, además decrecen rápido.	Coefficientes p y q no son anulados abruptamente, además decrecen rápido.
ARMA (estacional)	Coefficientes p y q no son anulados abruptamente, además decrecen rápido conforme al período estacional.	Coefficientes p y q no son anulados abruptamente, además decrecen rápido conforme al período estacional.
ARIMA (p,d,q)	Se comporta de una manera no regular en los retardos (1,...q) con picos q, además de decrecimientos en retardos despues de q	Decrecimiento exponencial y sinoidal.
ARIMA (P,D,Q) (estacional)	Se comporta de una manera no regular en los retardos (1,...Q) con picos Q, además de decrecimientos en retardos despues de q conforme a su periodo estacional	Decrecimiento exponencial y sinoidal. No llega a cero rápidamente, dependiendo de su periodo estacional

**Tabla1.1** Tabla de identificación y selección del modelo  
Elaboración: Propia

### **1.9.5.1.2 Estimación del Modelo**

Luego de que la serie pudo ser identificada se debe estimar los parámetros que son desconocidos para los modelos identificados.

Para le estimar los parámetros coherentemente utilizaremos mínimos cuadrados o máxima verosimilitud. Generalmente se estiman mediante máxima verosimilitud ya que en el mayor de los casos los modelos contienen componentes AR y MA.

### **1.9.5.1.3 Verificación del Modelo**

Para esta etapa los residuos deben ser ruido blanco, quiere decir, con media cero, varianza constante y autocorrelaciones ceros, para aquello podemos asegurarnos mediante las funciones FAC y FAP.

En esta etapa de verificación se debe realizar el análisis de coeficientes del modelo, la evaluación de la bondad de ajuste y lo dicho anteriormente, el análisis de residuos (ruido blanco).

## **1.9.6 Modelos SARIMA**

Cuando las series de tiempo tienen un componente temporal o estacional autorregresivo, quiere decir, que se hace notar reiteradamente en todas las observaciones, es cuando los modelos ARIMA pasan a ser modelos SARIMA, para poder modelizar estos comportamientos asimismo se debe realizar las tres etapas descritas por Box y Jenkins: identificación, estimación y validación del modelo. Los modelos SARIMA son denotados de la siguiente manera:

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

### 1.9.7 Error Porcentual Absoluto Medio (MAPE).

En un pronóstico de demanda, el error porcentual absoluto indica el desempeño del mismo midiendo porcentualmente el tamaño del error absoluto, este indicador es utilizado comúnmente por su fácil interpretación.

Para el cálculo del error porcentual absoluto medio existe la siguiente fórmula:

$$MAPE = \frac{\sum_{t=1}^n \frac{|A_t - F_t|}{|A_t|}}{n}$$

Donde:

$$A_t = \text{Demanda Real}$$

$$F_t = \text{Pronóstico utilizando una regresión lineal.}$$

# 2 CAPITULO.

## 2 METODOLOGÍA DE TRABAJO

Este capítulo abarcará, las metodologías a seguir para poder alcanzar los objetivos que se han planteado, basados en los datos obtenidos en la empresa y las necesidades de la misma.

### 2.1 Procedimiento de extracción de Datos

Se realizo la extracción de información, a partir de la base de datos que manejaba la empresa para el diseño de una herramienta que permita estimar la demanda futura de cada cliente.

### 2.2 Depuración de datos

La empresa no cuenta con una base de datos eficiente, es por eso que se tomaran los principales clientes que abarcan casi la totalidad de las operaciones, los cuales son cuatro, además se totalizara el número de vehículos de carga pesada que ha requerido cada cliente por cada mes del año, desde enero 2016 hasta la presente fecha.

### 2.3 Análisis de información mediante el uso de series de tiempo.

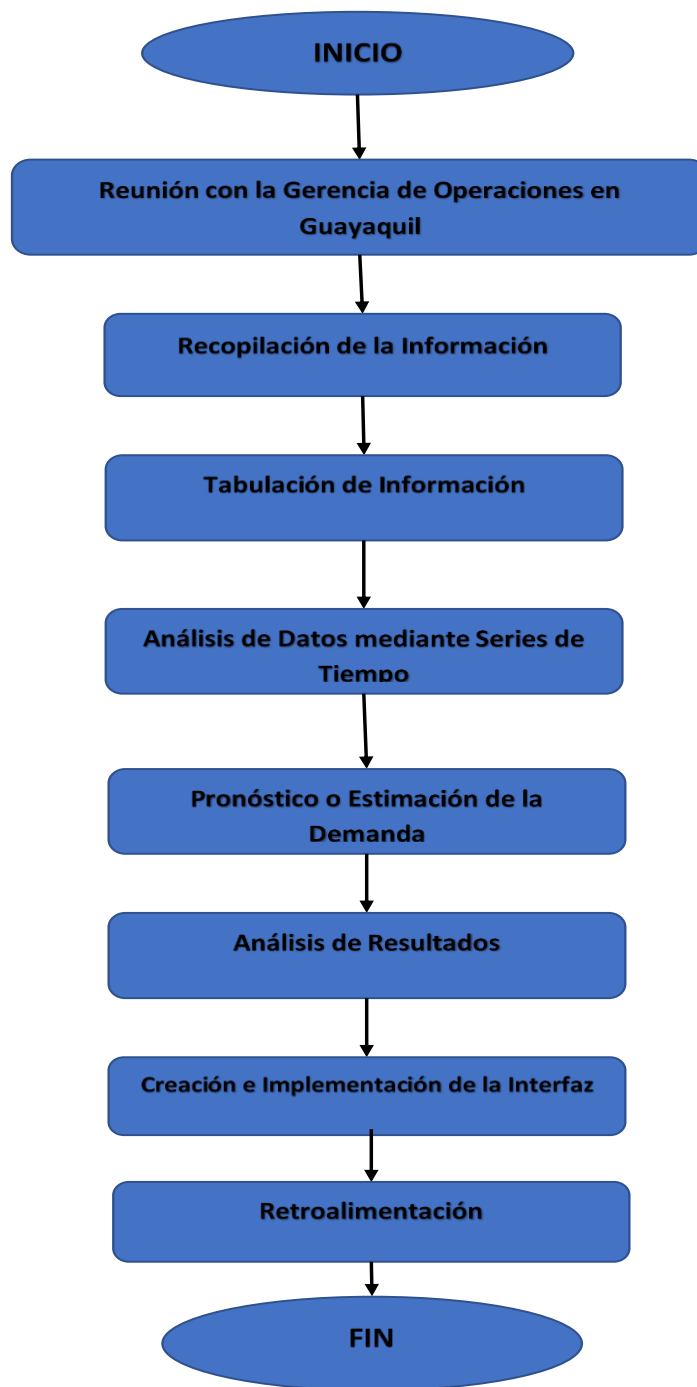
Para este proyecto se decidió realizar un estudio de series de tiempo utilizando el modelo SARIMA ya que se puede notar en los datos extraídos y depurados que existe un componente estacional.

Para poder modelizar los comportamientos que toman la demanda de los clientes a través del tiempo y posteriormente realizar los pronósticos, se lo hará con ayuda de las tres

etapas descritas por Box y Jenkins; identificación, estimación y validación del modelo (SARIMA) para posteriormente obtener el pronóstico.

## **2.4 Flujograma de actividades**

Presentamos las actividades que se realizarán por medio de un flujograma, nos muestra paso a paso que operaciones vamos a seguir para posteriormente obtener la solución al problema que hemos planteado.



**Ilustración 2.1** Flujograma de Actividades  
Elaboración: Propia

## 2.5 Cronograma de actividades

Este cronograma muestra todos los eventos o actividades que han sido realizados para poder elaborar este proyecto con sus fechas establecidas.

En la figura siguiente se mostrará las actividades:



**Ilustración 2.2 Cronograma de Actividades**  
Elaboración: Propia

## 2.6 Aplicaciones informáticas utilizadas

Para la solución de este proyecto se ha utilizado los siguientes softwares:

- **Microsoft Excel:** Es un programa informático, el cual nos facilita trabajar con datos numéricos, así como la realización de cálculos aritméticos, estadísticos sencillos y complejos, simplificando su ejecución, ya que este nos permite trabajar con hojas de cálculo, con ayuda de este programa se analizó la data facilitada por la empresa, se tabulo de acuerdo a los aspectos relevantes para nuestro problema y finalmente los datos fueron depurados para su posterior análisis.
- **R Studio:** Es una aplicación informática que facilita el uso del lenguaje de programación R, este lenguaje tiene un enfoque al análisis estadístico. Con ayuda de esta aplicación podemos realizar nuestro análisis de series de tiempo computacionalmente, para la obtención de los pronósticos. además de comunicarse con la aplicación que se creó en Visual Studio mediante R.net.
- **Visual Studio:** Es un entorno que posee las herramientas necesarias que facilitan el desarrollo de una interfaz que está conectada mediante R.Net a R Studio, la cual además de atractiva y amigable con el usuario, contiene funcionalidades necesarias para el análisis de datos y pronóstico adecuado



# 3 CAPITULO

## 3.1 Tratamiento y depuración de datos:

De acuerdo con los datos proporcionados por la empresa ASSOCIATES CO, se pudo obtener la información necesaria por medio de su base de datos de los cuatros clientes más representativos en cuanto al requerimiento del servicio.

Dado que el problema se da en cubrir la demanda de los clientes en las dos últimas semanas de cada mes, se decidió totalizar el número de vehículos que requiere cada cliente por semana, con la finalidad de observar los picos de demanda que se generan, para su análisis de series de tiempo, y posterior pronóstico.

A continuación, se muestran las tablas con los datos depurados.

### Demanda de cliente CG:

TRANSPORTE AS				
DEMANDA SEMANAL				
Año	Mes	Semana		CG
2017	Enero	1/1/2017	1/7/2017	16
		1/8/2017	1/14/2017	46
		1/15/2017	1/21/2017	54
		1/22/2017	1/31/2017	76
	Febrero	2/1/2017	2/7/2017	60
		2/8/2017	2/14/2017	57
		2/15/2017	2/21/2017	74
		2/22/2017	2/28/2017	69
	Marzo	3/1/2017	3/7/2017	67
		3/8/2017	3/14/2017	70
		3/15/2017	3/21/2017	71
		3/22/2017	3/31/2017	96
	Abril	4/1/2017	4/7/2017	63
		4/8/2017	4/14/2017	67
		4/15/2017	4/21/2017	54
		4/22/2017	4/30/2017	72
	Mayo	5/1/2017	5/7/2017	57
		5/8/2017	5/14/2017	72
		5/15/2017	5/21/2017	59

2018		5/22/2017	5/31/2017	<b>95</b>	
	Junio	6/1/2017	6/7/2017	91	
		6/8/2017	6/14/2017	86	
		6/15/2017	6/21/2017	71	
		6/22/2017	6/30/2017	<b>95</b>	
	Julio	7/1/2017	7/7/2017	51	
		7/8/2017	7/14/2017	85	
		7/15/2017	7/21/2017	65	
		7/22/2017	7/31/2017	<b>92</b>	
	Agosto	8/1/2017	8/7/2017	46	
		8/8/2017	8/14/2017	55	
		8/15/2017	8/21/2017	72	
		8/22/2017	8/31/2017	<b>115</b>	
	Septiembre	9/1/2017	9/7/2017	60	
		9/8/2017	9/14/2017	76	
		9/15/2017	9/21/2017	51	
		9/22/2017	9/30/2017	<b>114</b>	
	Octubre	10/1/2017	10/7/2017	45	
		10/8/2017	10/14/2017	57	
		10/15/2017	10/21/2017	70	
		10/22/2017	10/31/2017	<b>94</b>	
	Noviembre	11/1/2017	11/7/2017	31	
		11/8/2017	11/14/2017	63	
		11/15/2017	11/21/2017	77	
		11/22/2017	11/30/2017	<b>114</b>	
	Diciembre	12/1/2017	12/7/2017	68	
		12/8/2017	12/14/2017	65	
		12/15/2017	12/21/2017	<b>81</b>	
		12/22/2017	12/31/2017	43	
	2018	Enero	1/1/2018	1/7/2018	28
			1/8/2018	1/14/2018	58
			1/15/2018	1/21/2018	36
			1/22/2018	1/31/2018	<b>116</b>
		Febrero	2/1/2018	2/7/2018	61
			2/8/2018	2/14/2018	53
			2/15/2018	2/21/2018	69
			2/22/2018	2/28/2018	<b>98</b>
		Marzo	3/1/2018	3/7/2018	45
			3/8/2018	3/14/2018	54
			3/15/2018	3/21/2018	<b>92</b>
			3/22/2018	3/31/2018	91
		Abril	4/1/2018	4/7/2018	50
			4/8/2018	4/14/2018	52
			4/15/2018	4/21/2018	59
			4/22/2018	4/30/2018	<b>109</b>

	Mayo	5/1/2018	5/7/2018	34	
		5/8/2018	5/14/2018	50	
		5/15/2018	5/21/2018	73	
		5/22/2018	5/31/2018	<b>127</b>	
	Junio	6/1/2018	6/7/2018	58	
		6/8/2018	6/14/2018	58	
		6/15/2018	6/21/2018	76	
		6/22/2018	6/30/2018	<b>123</b>	
	Julio	7/1/2018	7/7/2018	32	
		7/8/2018	7/14/2018	58	
		7/15/2018	7/21/2018	46	
		7/22/2018	7/31/2018	<b>128</b>	
	Agosto	8/1/2018	8/7/2018	32	
		8/8/2018	8/14/2018	49	
		8/15/2018	8/21/2018	68	
		8/22/2018	8/31/2018	<b>145</b>	
	Septiembre	9/1/2018	9/7/2018	39	
		9/8/2018	9/14/2018	58	
		9/15/2018	9/21/2018	58	
		9/22/2018	9/30/2018	<b>104</b>	
	Octubre	10/1/2018	10/7/2018	22	
		10/8/2018	10/14/2018	43	
		10/15/2018	10/21/2018	51	
		10/22/2018	10/31/2018	<b>110</b>	
	Noviembre	11/1/2018	11/7/2018	14	
		11/8/2018	11/14/2018	30	
		11/15/2018	11/21/2018	72	
		11/22/2018	11/30/2018	<b>137</b>	
	Diciembre	12/1/2018	12/7/2018	30	
		12/8/2018	12/14/2018	73	
		12/15/2018	12/21/2018	<b>93</b>	
		12/22/2018	12/31/2018	34	
	<b>2019</b>	Enero	1/1/2019	1/7/2019	7
			1/8/2019	1/14/2019	42
			1/15/2019	1/21/2019	56
			1/22/2019	1/31/2019	<b>114</b>
		Febrero	2/1/2019	2/7/2019	41
			2/8/2019	2/14/2019	55
			2/15/2019	2/21/2019	74
			2/22/2019	2/28/2019	<b>96</b>
		Marzo	3/1/2019	3/7/2019	14
			3/8/2019	3/14/2019	49
			3/15/2019	3/21/2019	70
			3/22/2019	3/30/2019	<b>104</b>
		Abril	4/1/2019	4/7/2019	30

		4/8/2019	4/14/2019	44
		4/15/2019	4/21/2019	50
		4/22/2019	4/30/2019	<b>65</b>
	Mayo	5/1/2019	5/7/2019	25
		5/8/2019	5/14/2019	47
		5/15/2019	5/21/2019	66
		5/22/2019	5/31/2019	<b>109</b>
	Junio	6/1/2019	6/7/2019	59
		6/8/2019	6/14/2019	70
		6/15/2019	6/21/2019	57
		6/22/2019	6/30/2019	<b>94</b>

**Tabla 3.1 Demanda Semanal CG Enero 2017-Junio 2019**  
**Elaboración: Propia Fuente: Base de Datos de la empresa**

**Demanda de cliente KC:**

TRANSPORTE AS				
DEMANDA SEMANAL				
Año	Mes	Semana		KC
2018	Enero	1/1/2018	1/7/2018	24
		1/8/2018	1/14/2018	30
		1/15/2018	1/21/2018	33
		1/22/2018	1/31/2018	<b>148</b>
	Febrero	2/1/2018	2/7/2018	39
		2/8/2018	2/14/2018	34
		2/15/2018	2/21/2018	31
		2/22/2018	2/28/2018	<b>87</b>
	Marzo	3/1/2018	3/7/2018	29
		3/8/2018	3/14/2018	34
		3/15/2018	3/21/2018	25
		3/22/2018	3/31/2018	<b>117</b>
	Abril	4/1/2018	4/7/2018	12
		4/8/2018	4/14/2018	45
		4/15/2018	4/21/2018	33
		4/22/2018	4/30/2018	<b>80</b>
	Mayo	5/1/2018	5/7/2018	8
		5/8/2018	5/14/2018	38
		5/15/2018	5/21/2018	58
		5/22/2018	5/31/2018	<b>94</b>
Junio	6/1/2018	6/7/2018	14	
	6/8/2018	6/14/2018	28	
	6/15/2018	6/21/2018	43	
	6/22/2018	6/30/2018	<b>122</b>	

	Julio	7/1/2018	7/7/2018	6
		7/8/2018	7/14/2018	30
		7/15/2018	7/21/2018	33
		7/22/2018	7/31/2018	<b>107</b>
	Agosto	8/1/2018	8/7/2018	30
		8/8/2018	8/14/2018	30
		8/15/2018	8/21/2018	38
		8/22/2018	8/31/2018	<b>113</b>
	Septiembre	9/1/2018	9/7/2018	16
		9/8/2018	9/14/2018	33
		9/15/2018	9/21/2018	50
		9/22/2018	9/30/2018	<b>78</b>
	Octubre	10/1/2018	10/7/2018	6
		10/8/2018	10/14/2018	24
		10/15/2018	10/21/2018	24
		10/22/2018	10/31/2018	<b>124</b>
Noviembre	11/1/2018	11/7/2018	5	
	11/8/2018	11/14/2018	33	
	11/15/2018	11/21/2018	50	
	11/22/2018	11/30/2018	<b>100</b>	
Diciembre	12/1/2018	12/7/2018	12	
	12/8/2018	12/14/2018	30	
	12/15/2018	12/21/2018	<b>54</b>	
	12/22/2018	12/31/2018	35	
<b>2019</b>	Enero	1/1/2019	1/7/2019	2
		1/8/2019	1/14/2019	15
		1/15/2019	1/21/2019	28
		1/22/2019	1/31/2019	<b>114</b>
	Febrero	2/1/2019	2/7/2019	15
		2/8/2019	2/14/2019	34
		2/15/2019	2/21/2019	25
		2/22/2019	2/28/2019	<b>84</b>
	Marzo	3/1/2019	3/7/2019	11
		3/8/2019	3/14/2019	31
		3/15/2019	3/21/2019	42
		3/22/2019	3/30/2019	<b>96</b>
	Abril	4/1/2019	4/7/2019	6
		4/8/2019	4/14/2019	11
		4/15/2019	4/21/2019	23
		4/22/2019	4/30/2019	<b>93</b>
Mayo	5/1/2019	5/7/2019	10	
	5/8/2019	5/14/2019	28	
	5/15/2019	5/21/2019	51	
	5/22/2019	5/31/2019	<b>102</b>	
Junio	6/1/2019	6/7/2019	19	


		6/8/2019	6/14/2019	24
		6/15/2019	6/21/2019	42
		6/22/2019	6/30/2019	77

**Tabla 3.2 Demanda Semanal KC Enero 2018-Junio 2019**  
**Elaboración: Propia Fuente: Base de Datos de la empresa**

## 3.2 Análisis de datos mediante series de tiempo.

### 3.2.1 Análisis para la empresa CG

Como primer paso, para el análisis, trazamos la serie de tiempo para ver sus características; a continuación, se muestra la gráfica.

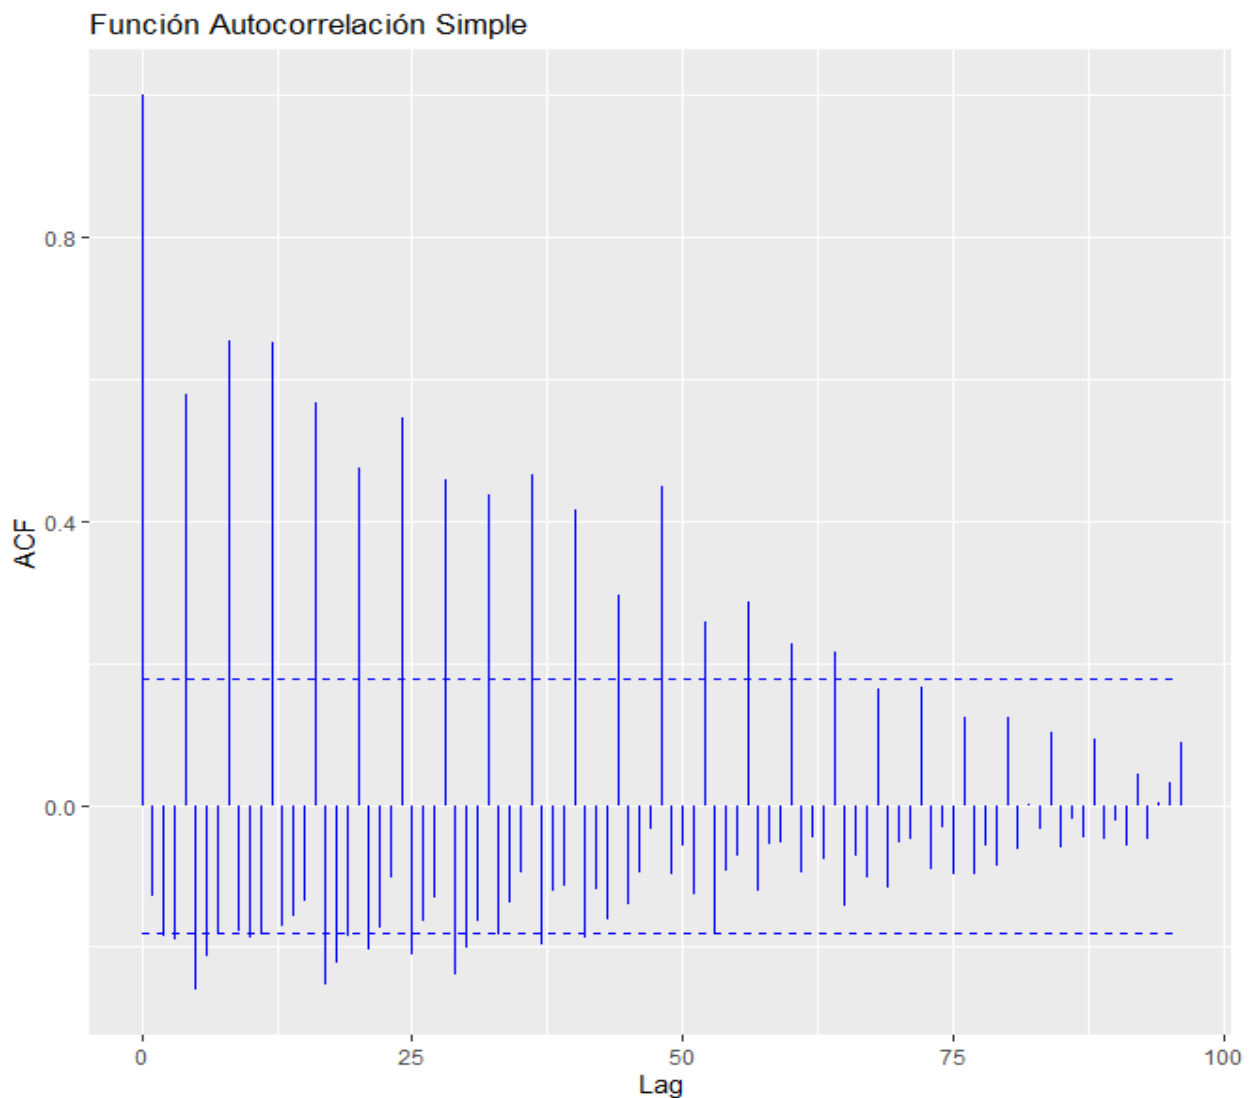


**Ilustración 3.1 Serie de tiempo semanal CG Enero 2017- Junio 2019**  
**Elaboración: Propia Fuente: RStudio**

Podemos darnos cuenta al ver la ilustración 3.1, que la serie presenta ciclos estacionales, quiere decir que tiene como característica, una estructura que se repite en la última semana de cada mes, por lo tanto, no es estacionaria, se puede percibir en cuanto a

su varianza que no hay una notable variación, por consiguiente, es estacionaria en su varianza (**ilustración 3.4**).


Para poder verificar lo dicho anteriormente trazamos la gráfica de la función de autocorrelación simple que se muestra a continuación.



**Ilustración 3.2 Función Autocorrelación Simple**  
**Elaboración: Propia Fuente: RStudio**

En la ilustración 3.2 podemos notar que la función de autocorrelación no tiene un decaimiento exponencial a medida que sus rezagos aumentan a través del tiempo, y que pasando cada cuatro períodos sus rezagos son mayores con relación a los demás.


Para realizar un mejor análisis de la serie, descomponemos la serie en sus componentes por separado



**Ilustración 3.3 Componentes de la Serie de Tiempo CG**  
Elaboración: Propia Fuente: RStudio



Para verificar si la serie tiene la necesidad de estabilizar su varianza se realiza la transformación Box-Cox logaritmos.



**Ilustración 3.4 Transformación Box-Cox/Logaritmo**  
Elaboración: Propia Fuente: RStudio

Se puede notar en la ilustración 3.4 que el valor de lambda se acerca a uno, por lo que no requiere una transformación logarítmica, para ser exactos en cuanto al posterior ajuste del modelo, se saca el valor de lambda con la función de RStudio llamada **BoxCox.lambda**, la cual nos da como resultado  $\lambda = 0.75$ .

### Modelado de la Serie:

Como se ha dicho anteriormente, la serie posee ciclos estacionales, por lo tanto el modelo autorregresivo integrado de media móvil (SARIMA) es el correcto a utilizar para el ajuste de la serie, para lograr que la serie sea estacionaria, esta debe ser diferenciada las d veces que sea necesario.


Con las funciones de RStudio **ndiffs** y **nsdiffs** calcularemos el número de diferenciaciones necesarias.

```
> #Modelado de la serie
> ndiffs(ts_s)
[1] 0
> nsdiffs(ts_s)
[1] 1
```

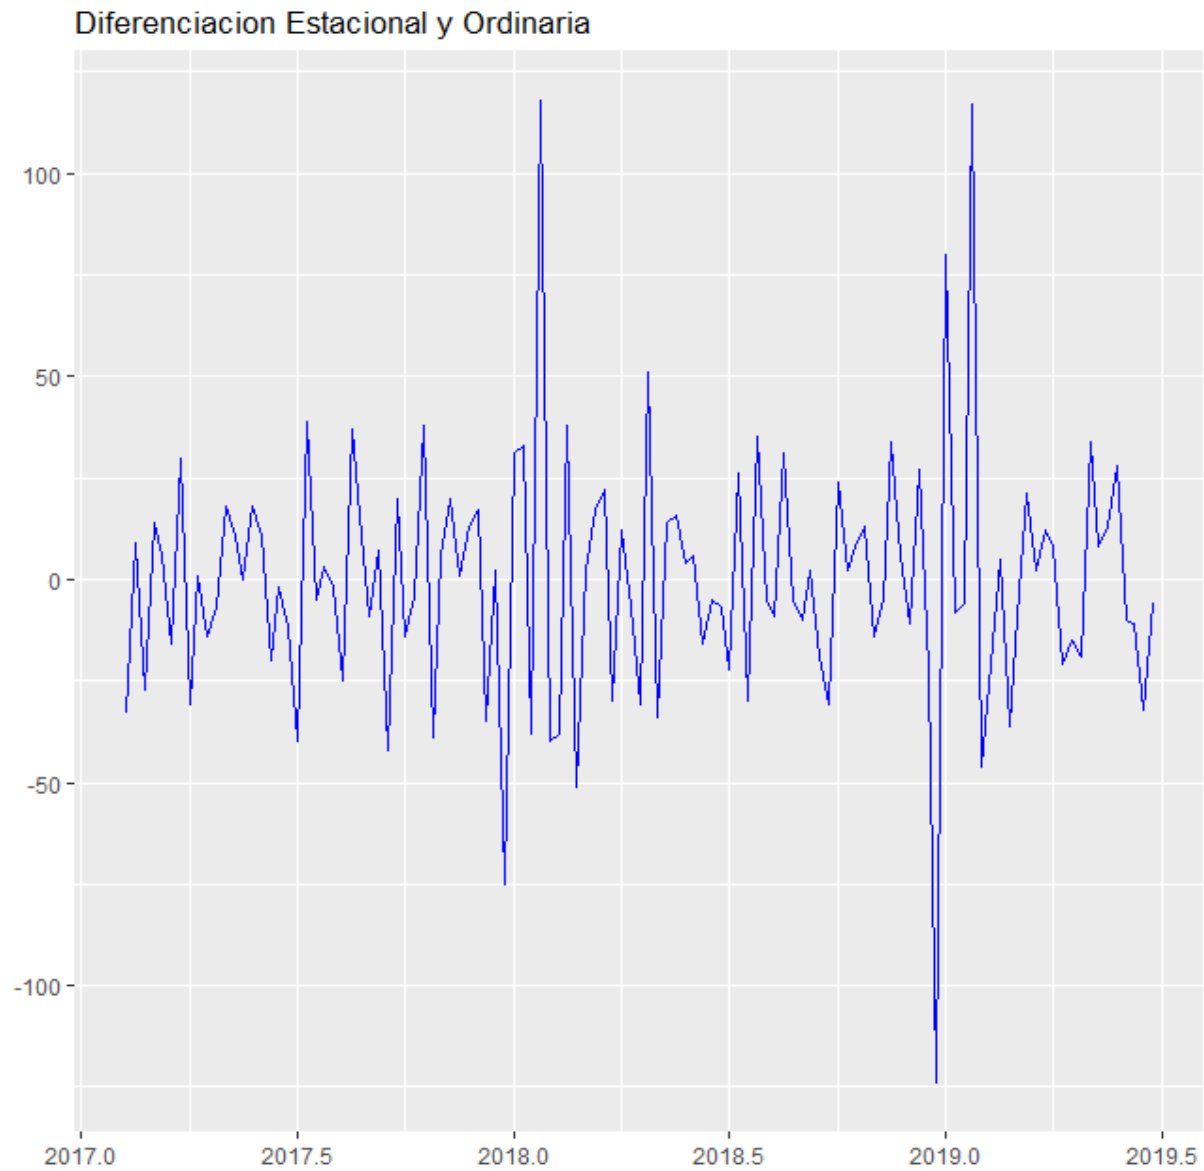
**Ilustración 3.5 Diferencias**  
**Elaboración: Propia Fuente: RStudio**

Como resultado (ilustración 3.5), al ejecutar estas funciones, nos muestra que, no se necesitara diferenciación regular, pero si diferenciación estacional para la serie CG, aun así, al descomponer la serie, nos hemos dado cuenta de que la serie posee tendencia, por lo tanto, debemos probar si, además de diferenciarlo estacionalmente, con una diferencia ordinaria la serie se modela de una mejor manera.

## Diferenciación Estacional



**Ilustración 3.6 Diferenciación Estacional**  
Elaboración: Propia Fuente: RStudio



**Ilustración 3.7 Diferenciación Estacional y Ordinaria**  
Elaboración: Propia Fuente: RStudio

Se puede notar con las ilustraciones anteriores que al aplicar la diferenciación estacional (con  $\text{lag}=4$ ) y regular la serie se muestra más estable, pierde el patrón que tiene la serie original y su tendencia es más lineal, por lo tanto, es necesario diferenciarla estacional y ordinariamente.

## Test de Estacionariedad

Una vez ya eliminada la componente estacional y regular de la serie, para estar seguros, aplicamos el test de estacionariedad como el test ADF (Dickey-Fuller) y el test de KPSS (Kwiatkowski-Phillips-Schmidt-Shin).

1. Planteamiento de hipótesis.
2. Significancia  $\alpha=0.05$

$H_0$ : La serie es no estacionaria: tiene raíz unitaria

$H_1$ : La serie es estacionaria: no tiene raíz unitaria


```
> #Aplicamos el test de estacionalidad
> library(tseries)
> adf<-adf.test(difEstaOrdin)
Warning message:
In adf.test(difEstaOrdin) : p-value smaller than printed p-value
> adf$p.value
[1] 0.01
> kpss<-kpss.test(difEstaOrdin)
Warning message:
In kpss.test(difEstaOrdin) : p-value greater than printed p-value
> kpss$p.value
[1] 0.1
> |
```

**Ilustración 3.8 Test de Estacionariedad**  
Elaboración: Propia Fuente: RStudio


El valor 0.01 de la prueba muestra que la hipótesis nula  $H_0$  se puede rechazar indicando que la serie es estacionaria.

## Ajuste del Modelo

Parte Estacional:



**Ilustración 3.9 ACF-Residuos**  
Elaboración: Propia Fuente: RStudio



**Ilustración 3.10 PACF-RESIDUOS**  
**Elaboración: Propia Fuente: RStudio**

Primero tratamos de quitar los residuos de la parte estacional, por lo tanto, solo tomamos en cuenta el patrón que los rezagos tienen cada cuatro períodos. Vista las gráficas de las funciones autocorrelación simple y parcial podemos plantear algunos modelos en la parte estacional (P, Q).


- Modelo 1: SARIMA (0,1,0) (0,1,1)
- Modelo 2: SARIMA (0,1,0) (1,1,0)
- Modelo 3: SARIMA (0,1,1) (0,1,2)

Para cada uno de estos modelos se calcula los criterios, AIC (Criterio de Información de Akaike) y BIC (Criterio de Información Bayesiano), estos criterios determinan el ajuste o la capacidad que tienen los modelos para las predicciones, lo que se busca con esto es poder encontrar el modelo más estable entre los modelos que hemos planteado, para tamaños de muestra pequeños es aconsejable utilizar el criterio AIC.

	df	AIC
Modelo1	2	528.9251
Modelo2	2	528.9251
Modelo3	3	530.9251


El modelo que se va a tomar en cuenta será aquel que arroja menor valor, para este caso el modelo seleccionado es el modelo dos, SARIMA (0,1,0) (1,1,0) el cual solo tiene componentes autorregresivos (SAR). Para validar este modelo, se gráfica las funciones de autocorrelación (ACF, PACF) para escoger los parámetros de la parte ordinaria (p, q).

### Parte Ordinaria:



**Ilustración 3.11 ACF Residuos**  
**Elaboración: Propia Fuente: RStudio**






**Ilustración 3.12 PACF-Residuos**  
**Elaboración: Propia Fuente: RStudio**

. En la gráfica (ilustración 3.11) de la función autocorrelación simple (MA) se puede observar un decaimiento exponencial, mientras que en la función de autocorrelación parcial (AR) (ilustración 3.12), se observa tres rezagos significativos, por lo que, podemos plantear los siguiente modelos (p,q) que juntaremos al modelo que escogimos en la parte estacional:


- Modelo 4: SARIMA (0,1,1) (1,1,0)
- Modelo 5: SARIMA (3,1,0) (1,1,0)
- Modelo 6: SARIMA (4,1,0) (1,1,0)
- Modelo 7: SARIMA (3,1,1) (1,1,0)

	df	AIC
Modelo4	3	478.2904
Modelo5	5	451.0024
Modelo6	6	450.7260
Modelo7	6	450.5128

Los valores del criterio AIC con respecto a los primeros tres modelos han disminuido, esto quiere decir que la estabilidad de los modelos ha mejorado, se selecciona el modelo 7 SARIMA (3,1,1) (1,1,0) por tener el menor valor (AIC) con respecto a los demás. Graficamos los residuos de este modelo para verificar si se comportan como ruido blanco.



**Ilustración 3.13 ACF Residuos-Ruido Blanco**  
 Elaboración: Propia Fuente: RStudio



**Ilustración 3.14 PACF Residuos-Ruido Blanco**  
**Elaboración: Propia Fuente: RStudio**

En RStudio hay una función que llama **auto.arima**, con esta podemos calcular de manera automática cuál puede ser una de las combinaciones de los componentes para nuestro modelo, el modelo que sugiere es:

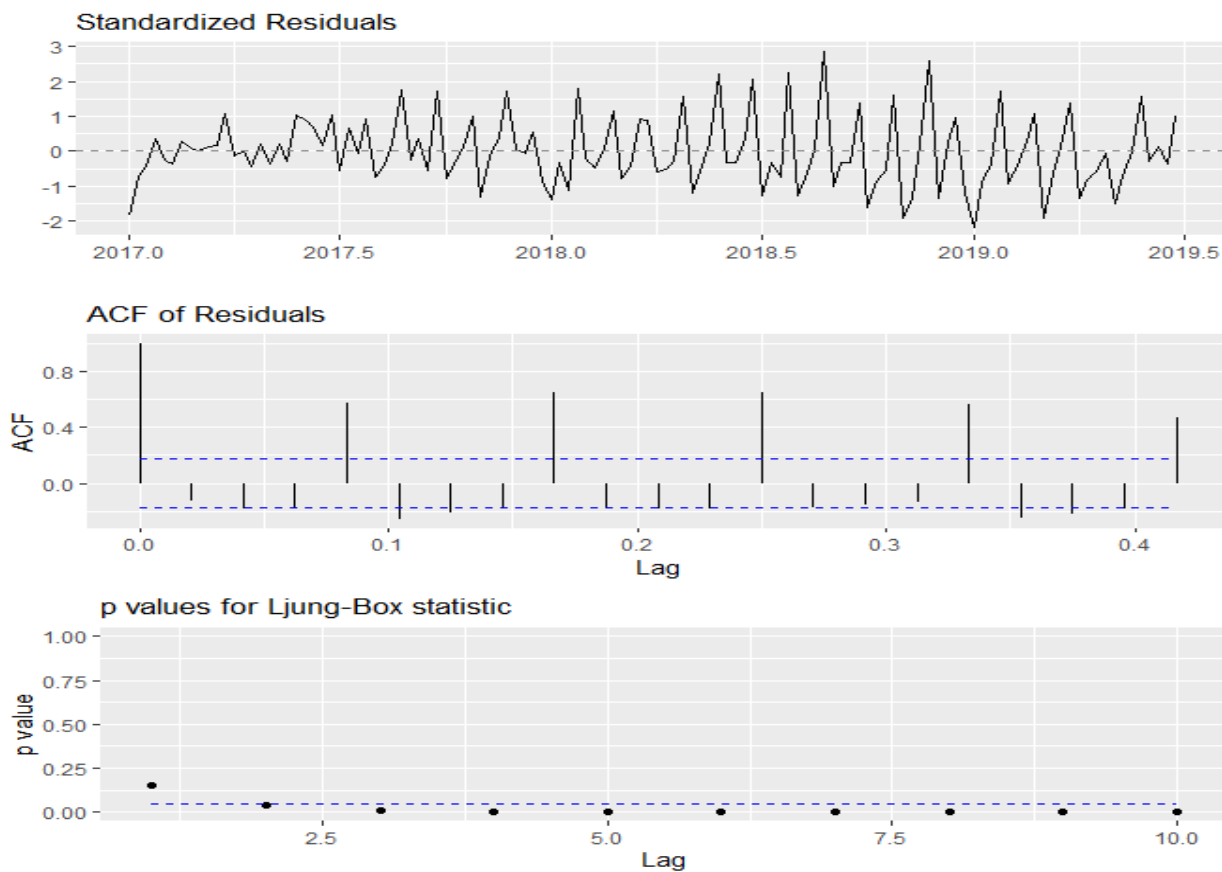
```
Series: ts_s
ARIMA(3,1,1)(0,1,0)[48]
```

**Ilustración 3.15 Auto-Arima**  
**Elaboración: Propia Fuente: RStudio**


Como resultado (ilustración 3.15) la función sugiere el modelo SARIMA (3,1,1) (0,1,0), para validar este modelo, aplicamos los criterios AIC y BIC como se lo hizo anteriormente y comparamos con el modelo que fue escogido anteriormente.

Los valores son, para el AIC = 453.23 y BIC=464.54, valores mayores que los del modelo que fue escogido, por lo tanto, el modelo que mejor se ajusta a la serie es el SARIMA (3,1,1) (1,1,0) y será el que utilizaremos para la predicción.

### Comparación de diagnóstico de la Serie Original vs Serie Ajustada

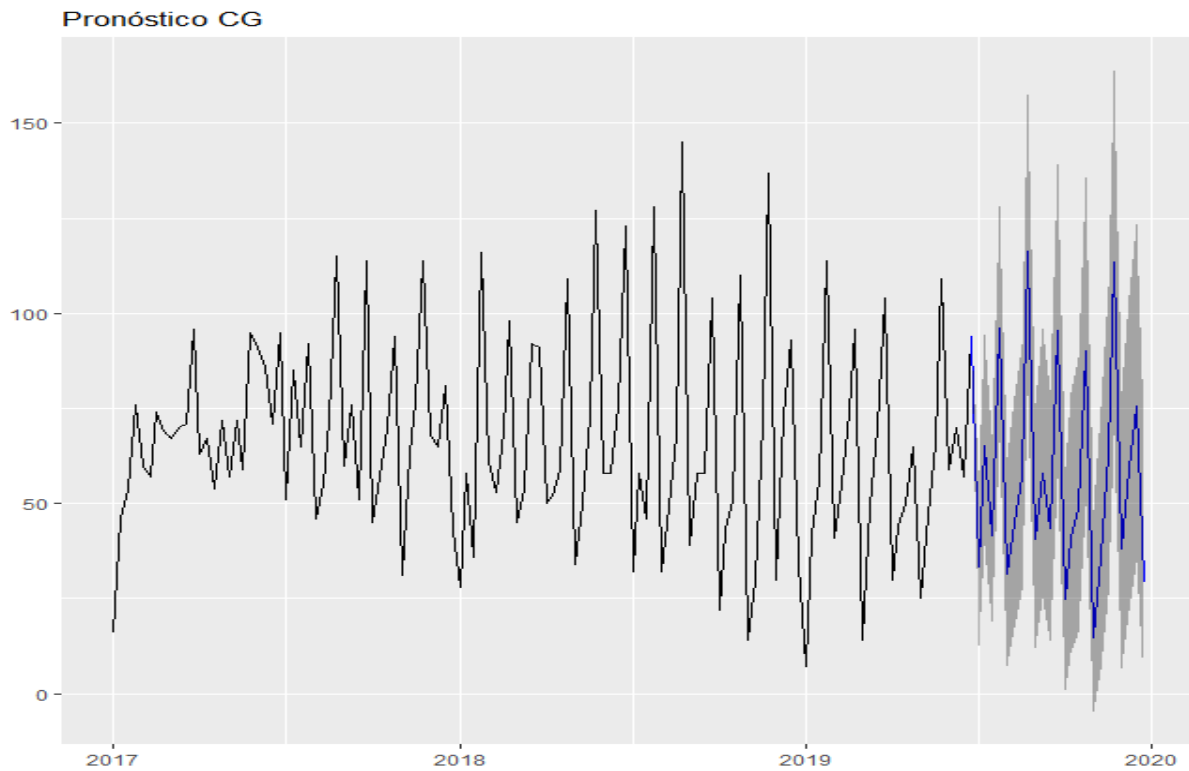


**Ilustración 3.16 Diagnóstico de la Serie Original**  
Elaboración: Propia Fuente: RStudio



**Ilustración 3.17 Diagnóstico de la Serie Ajustada**  
**Elaboración: Propia Fuente: RStudio**

## Predicción de la Serie



**Ilustración 3.18 Predicción CG**  
**Elaboración: Propia Fuente: RStudio**

El error porcentual absoluto (MAPE) del pronóstico es de 12.4466%; el MAPE nos indica el desempeño del pronóstico, el cual mide el tamaño del error absoluto en términos porcentuales.

A partir del modelo se ha estimado los valores de la demanda además de sus intervalos de predicción con un 95%, los cuales permiten prepararse para un escenario optimista (Hi 95) y pesimista (Lo 95), esto dará pautas para saber cuántos vehículos de transporte de carga tener en esos casos. En la siguiente tabla se muestran los valores estimados de demanda a partir del modelo escogido anteriormente:

**TRANSPORTE SP**

**ESTIMACIÓN DE LA DEMANDA SEMANAL**


<b>Año</b>	<b>Mes</b>	<b>Semana</b>	<b>Predicción</b>	<b>Lo 95%</b>	<b>Hi 95%</b>
<b>2019</b>	Julio	Semana 25	33	12	59
		Semana 26	65	39	94
		Semana 27	42	19	68
		Semana 28	96	66	128
	Agosto	Semana 29	31	7	62
		Semana 30	45	17	78
		Semana 31	57	27	92
		Semana 32	116	78	158
	Septiembre	Semana 33	41	12	76
		Semana 34	58	25	96
		Semana 35	43	14	80
		Semana 36	96	57	139
	Octubre	Semana 37	25	1	60
		Semana 38	41	11	79
		Semana 39	49	16	88
		Semana 40	90	50	136
	Noviembre	Semana 41	15	0	48
		Semana 42	36	6	75
		Semana 43	63	26	107
		Semana 44	113	68	164
Diciembre	Semana 45	38	7	79	
	Semana 46	59	22	105	
	Semana 47	76	35	124	
	Semana 48	29	1	69	
<b>2020</b>	Enero	Semana 1	9	0	44
		Semana 2	40	7	84
		Semana 3	37	5	80
		Semana 4	103	56	157
	Febrero	Semana 5	41	7	86
		Semana 6	45	9	91
		Semana 7	61	20	110
		Semana 8	86	40	139
	Marzo	Semana 9	20	0	61
		Semana 10	42	6	89
		Semana 11	69	26	122
		Semana 12	87	39	142
	Abril	Semana 13	30	0	76
		Semana 14	38	3	86
		Semana 15	44	7	94
		Semana 16	74	28	129

	Mayo	Semana 17	21	0	66
		Semana 18	39	3	89
		Semana 19	59	16	113
		Semana 20	105	52	167
	Junio	Semana 21	49	8	102
		Semana 22	54	12	109
		Semana 23	55	12	110
		Semana 24	96	43	157

**Tabla 3.3 Pronóstico Semanal Julio 2019- Junio 2020**  
**Elaboración: Propia**

### 3.2.2 Análisis para la Empresa KC

Para facilitar el análisis, trazamos la serie de tiempo para denotar sus características como a continuación se muestra.

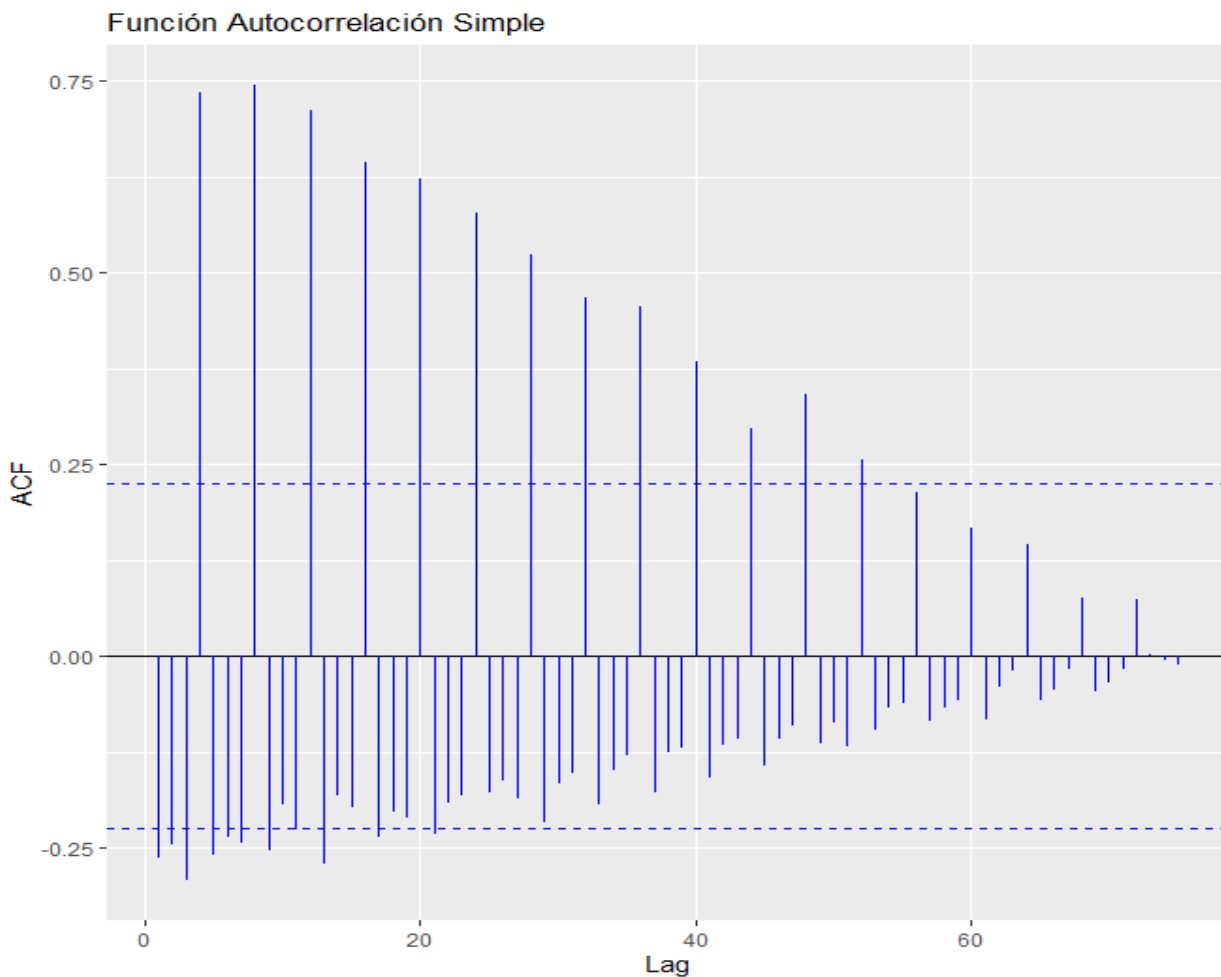


**Ilustración 3.19 Serie de tiempo semanal KC Enero 2018- Julio 2019**  
**Elaboración: Propia Fuente: RStudio**



Se puede notar en la ilustración 3.19 que la serie presenta picos cada cuatro semanas, quiere decir, que la serie presenta estacionalidad, por lo tanto, no es estacionaria; también podemos notar que no presenta una tendencia pronunciada o muy visible.

Para seguir analizando la serie, trazamos la gráfica de la función autocorrelación simple que se muestra a continuación:




**Ilustración 3.20 Función Autocorrelación Simple Enero 2018- Julio 2019**  
**Elaboración: Propia Fuente: RStudio**

En la ilustración 3.20 podemos verificar lo dicho con anterioridad, esta serie muestra rezagos o retardos notables cada cuatro semanas.

Lo ideal sería descomponer la serie, pero para esta empresa no se pudo recolectar suficientes datos (mínimo dos períodos) por lo que no se puede realizar la descomposición.

Para comprobar si la serie tiene la necesidad de estabilizar su varianza, se debe realizar la transformación Box-Cox logaritmos que se muestra a continuación.



**Ilustración 3.21 Transformación Box-Cox/Logaritmo**  
Elaboración: Propia Fuente: RStudio

Al realizar la prueba en RStudio con la función **BoxCox.lambda**, la lambda arroja un valor de uno, esto significa que la serie no necesita una transformación de tipo logarítmica. En la ilustración 3.21 se puede denotar aquello.


## Modelado de la Serie

Primero verificamos si la serie de ser diferenciada, para esto, se utiliza las funciones de RStudio `ndiffs` y `nsdiffs`, al ejecutarlas, nos muestra el número de diferenciaciones que la serie necesita.


```
> ndiffs(ts_s)
[1] 0
> nsdiffs(ts_s)
[1] 0
```

**Ilustración 3.22 Prueba de Diferencias**  
Elaboración: Propia Fuente: RStudio

Al ejecutar estas funciones, nos muestra (ilustración 3.22) que la serie no debe ser diferenciada ni regular ni estacionalmente, aun así, es necesario y se debe probar visualmente si la serie necesita ser diferenciada ordinaria y estacionalmente para que el modelo pueda ajustarse de mejor manera.



**Ilustración 3.23 Diferenciación Estacional**  
Elaboración: Propia Fuente: RStudio



**Ilustración 3.24 Diferenciación Estacional y Ordinaria**  
**Elaboración: Propia Fuente: RStudio**

Al verificar las gráficas de las series diferenciadas, se puede notar, que la media es más estable y tiene una variabilidad más constante al ser diferenciada estacional y ordinariamente, por lo tanto probaremos más adelante para el ajuste de nuestros modelos con un  $d=1$  y  $D=1$ .

## Test de Estacionariedad

Aplicamos el test de estacionariedad como es el test ADF (Dickey-Fuller) y el test de KPSS (Kwiatkowski-Phillips-Schmidt-Shin), luego de que la serie ha sido diferenciada, para aquello se plantean las hipótesis.

$H_0$ : La serie es no estacionaria: tiene raíz unitaria

$H_1$ : La serie es estacionaria: no tiene raíz unitaria


```
> #Aplicamos el test de estacionariedad
> library(tseries)
> adf<-adf.test(ts_s)
warning message:
In adf.test(ts_s) : p-value smaller than printed p-value
> adf$p.value
[1] 0.01
> kpss<-kpss.test(ts_s)
warning message:
In kpss.test(ts_s) : p-value greater than printed p-value
> kpss$p.value
[1] 0.1
```

### Ilustración 3.25 Test de Estacionariedad Elaboración: Propia Fuente: RStudio

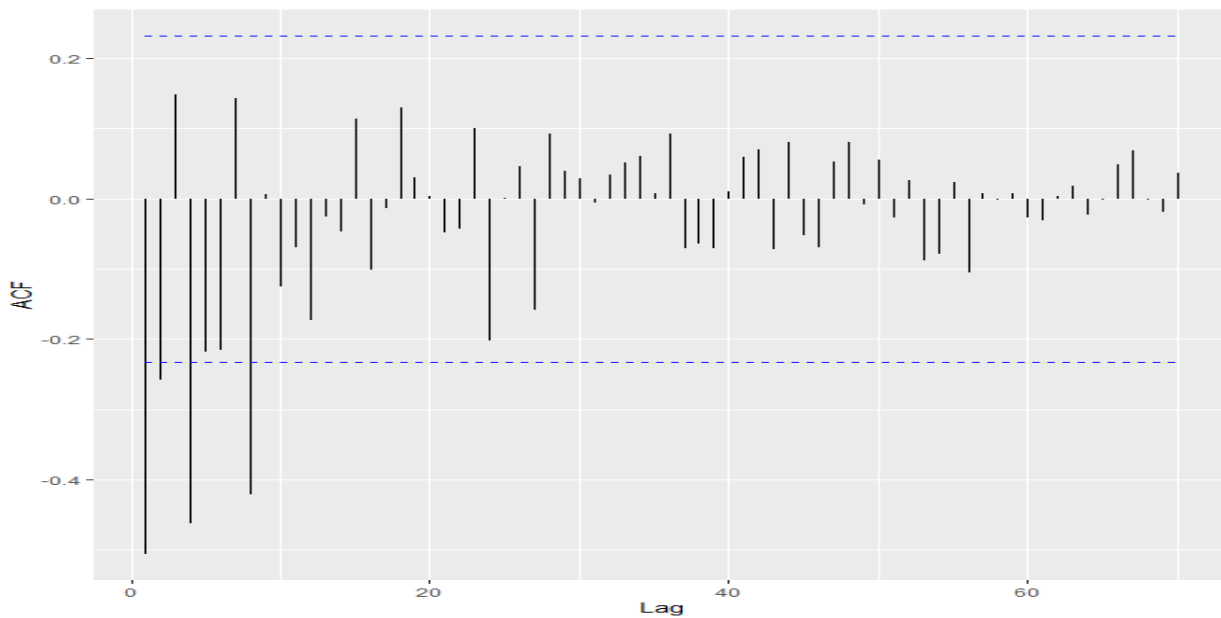
El valor 0.01 de la prueba muestra que la hipótesis nula  $H_0$  se puede rechazar indicando que la serie es estacionaria.

## Ajuste del Modelo.

**Parte Estacional:**



**Ilustración 3.26 Función autocorrelación simple de la serie diferenciada**  
**Elaboración: Propia Fuente: RStudio**



**Ilustración 3.27 Función autocorrelación parcial**  
**Elaboración: Propia Fuente: RStudio**

Debemos eliminar los residuos de la parte estacional, por lo tanto, solo tomamos en cuenta el patrón que los rezagos tienen cada cuatro períodos. Vista las gráficas de las


funciones autocorrelación simple y parcial podemos plantear algunos modelos en la parte estacional (P, Q) con  $d=1$  y  $D=1$ .

- Modelo 1: SARIMA (0,1,0) (0,1,1)
- Modelo 2: SARIMA (0,1,0) (0,1,0)
- Modelo 3: SARIMA (0,1,0) (0,1,2)


Para cada uno de estos modelos se calcula los criterios, AIC (Criterio de Información de Akaike) y BIC (Criterio de Información Bayesiano), estos criterios determinan el ajuste o la capacidad que tienen los modelos para las predicciones, lo que se busca con esto es poder encontrar el modelo más estable entre los modelos que hemos planteado, para tamaños de muestra pequeños es aconsejable utilizar el criterio AIC.

<b>Modelo1</b>	<b>2</b>	<b>242.8459</b>
<b>Modelo2</b>	<b>1</b>	<b>240.8459</b>
<b>Modelo3</b>	<b>3</b>	<b>244.8459</b>

El modelo que se va a tomar en cuenta será aquel que arroja menor valor, para este caso el modelo seleccionado es el modelo dos, SARIMA (0,1,0) (0,1,0) el cual solo tiene una diferenciación estacional y otra ordinaria. Para validar este modelo, se gráfica las funciones de autocorrelación (ACF, PACF) para escoger los parámetros de la parte ordinaria (p, q).



**Ilustración 3.28 ACF-Residuos**  
 Elaboración: Propia Fuente: RStudio



**Ilustración 3.29 PACF-Residuos**  
 Elaboración: Propia Fuente: RStudio

. En la gráfica (ilustración 3.28) de la función autocorrelación simple (MA) se puede observar solo un rezago significativo o distinto de cero, mientras que en la función de




autocorrelación parcial (AR) (ilustración 3.29), se observa entre dos a tres rezagos significativos, por lo que, podemos plantear los siguientes modelos (p, q) que juntaremos al modelo que escogimos en la parte estacional:


- Modelo 4: SARIMA (0,1,1) (0,1,0)
- Modelo 5: SARIMA (2,1,0) (0,1,0)
- Modelo 6: SARIMA (2,1,1) (0,1,0)
- Modelo 7: SARIMA (3,1,0) (0,1,0)
- Modelo 8: SARIMA (3,1,1) (0,1,0)

	df	AIC
Modelo4	2	226.9160
Modelo5	3	235.7783
Modelo6	4	230.8848
Modelo7	4	235.0418
Modelo8	5	232.5323

Los valores del criterio AIC con respecto a los primeros tres modelos han disminuido, esto quiere decir que la estabilidad de los modelos ha mejorado, se selecciona el modelo 4 SARIMA (0,1,1) (0,1,0) por tener el menor valor (AIC) con respecto a los demás. Graficamos los residuos de este modelo para verificar si se comportan como ruido blanco.



**Ilustración 3.30 ACF-Ruido Blanco**  
 Elaboración: Propia Fuente: RStudio



**Ilustración 3.31 PACF Ruido Blanco**  
 Elaboración: Propia Fuente: RStudio

Con la función de RStudio, llamada **auto.arima**, se calcula de manera automática cuál puede ser la combinación de componentes para nuestro modelo.

ARIMA(4,0,0) with non-zero mean  
Box Cox transformation: lambda= 1


**Ilustración 3.32 Auto-ARIMA**  
**Elaboración: Propia Fuente: RStudio**

Como resultado (ilustración 3.32) la función sugiere que el modelo para ajustar la serie es de un ARIMA (4,0,0) sin componentes estacionales ni ordinarios, para verificar si el modelo es más estable que el modelo 4 planteado anteriormente calculamos los criterios AIC y BIC, los cuales dan como resultado, para AIC=684.45 y BIC=685.67, valores más altos en relación con los anteriores.

El modelo que se utilizará para realizar el pronóstico será el de SARIMA (0,1,1) (0,1,0)


**Otras verificaciones (Supuestos de Normalidad).**

**Serie No Diferenciada:**




**Ilustración 3.33 Supuestos de Normalidad Serie No Diferenciada**  
Elaboración: Propia Fuente: RStudio

**Serie Diferenciada Regular y Estacionalmente:**



**Ilustración 3.34 Supuestos de Normalidad Serie Diferenciada**  
Elaboración: Propia Fuente: RStudio

## Predicción de la Serie



**Ilustración 3.35 Pronóstico KC**  
**Elaboración: Propia Fuente: RStudio**

El error porcentual absoluto (MAPE) del pronóstico es del 16%, el cual nos indica el desempeño del pronóstico.

TRANSPORTE SP			
DEMANDA SEMANAL PRONOSTICADO			
Año	Mes	Semana	KC
<b>2019</b>	Julio	Semana 25	21
		Semana 26	21
		Semana 27	29
		Semana 28	<b>104</b>
	Agosto	Semana 29	7
		Semana 30	24
		Semana 31	41
		Semana 32	<b>69</b>
	Septiembre	Semana 33	0
		Semana 34	15
		Semana 35	15

<b>2020</b>	Octubre	Semana 36	<b>115</b>	
		Semana 37	14	
		Semana 38	24	
		Semana 39	41	
	Noviembre	Semana 40	<b>91</b>	
		Semana 41	3	
		Semana 42	21	
		Semana 43	45	
	Diciembre	Semana 44	<b>26</b>	
		Semana 45	12	
		Semana 46	6	
		Semana 47	<b>19</b>	
		Enero	Semana 48	105
			Semana 1	6
			Semana 2	25
			Semana 3	16
Febrero		Semana 4	<b>75</b>	
		Semana 5	2	
		Semana 6	22	
		Semana 7	33	
Marzo		Semana 8	<b>87</b>	
		Semana 9	0	
		Semana 10	2	
		Semana 11	14	
Abril		Semana 12	<b>84</b>	
		Semana 13	1	
		Semana 14	19	
		Semana 15	42	
Mayo		Semana 16	<b>93</b>	
		Semana 17	10	
		Semana 18	15	
		Semana 19	33	
Junio		Semana 20	<b>68</b>	
		Semana 21	0	
		Semana 22	8	
		Semana 23	21	
	Semana 24	<b>89</b>		

**Tabla 3.4 Pronóstico Semanal Julio 2019- Junio 2020**  
Elaboración: Propia

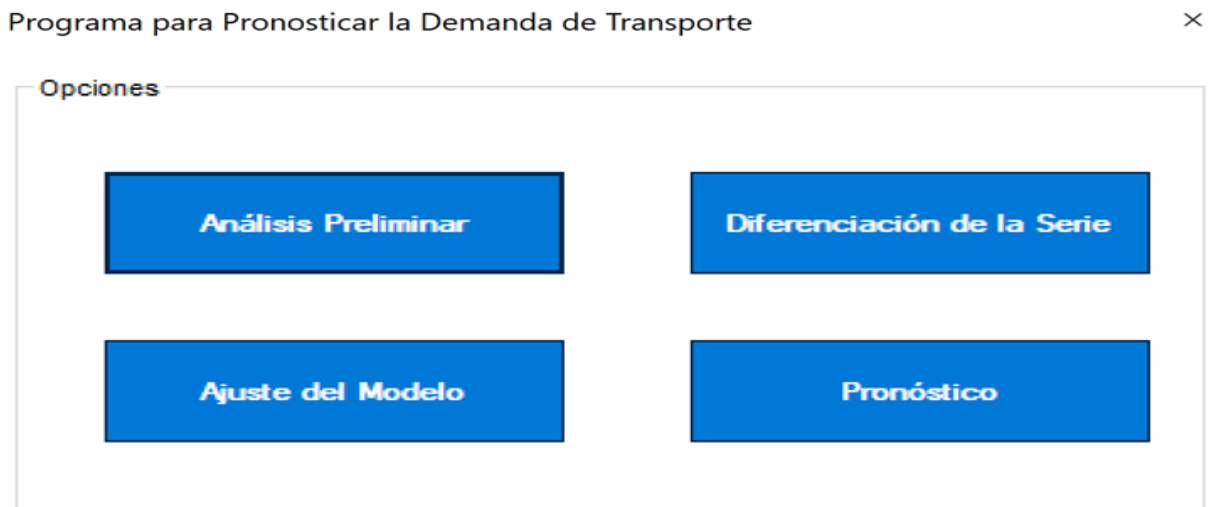
### 3.3 Interfaz

Como parte de la solución a la problemática de la empresa, se diseñó una interfaz la cual permite realizar el análisis del comportamiento de la demanda de los clientes mediante series de tiempo, para su posterior pronóstico. La interfaz se presenta a continuación con su ventana de inicio:



**Ilustración 3.36 Ventana de Inicio de la Aplicación**

Al ingresar al sistema se muestra una ventana con cuatro opciones, estas son: Análisis Preliminar, Diferenciación de la Serie, Ajuste del Modelo, y finalmente el Pronóstico, como se muestra a continuación:



**Ilustración 3.37 Opciones para el Análisis**

### **Análisis Preliminar**

Dentro de la opción de Análisis Preliminar, el usuario puede cargar los datos a ser analizados, visualizar los gráficos de la serie original, función autocorrelación simple y función autocorrelación parcial, además, calcular el lambda del test Box-Cox para la transformación logarítmica, como se muestra a continuación:



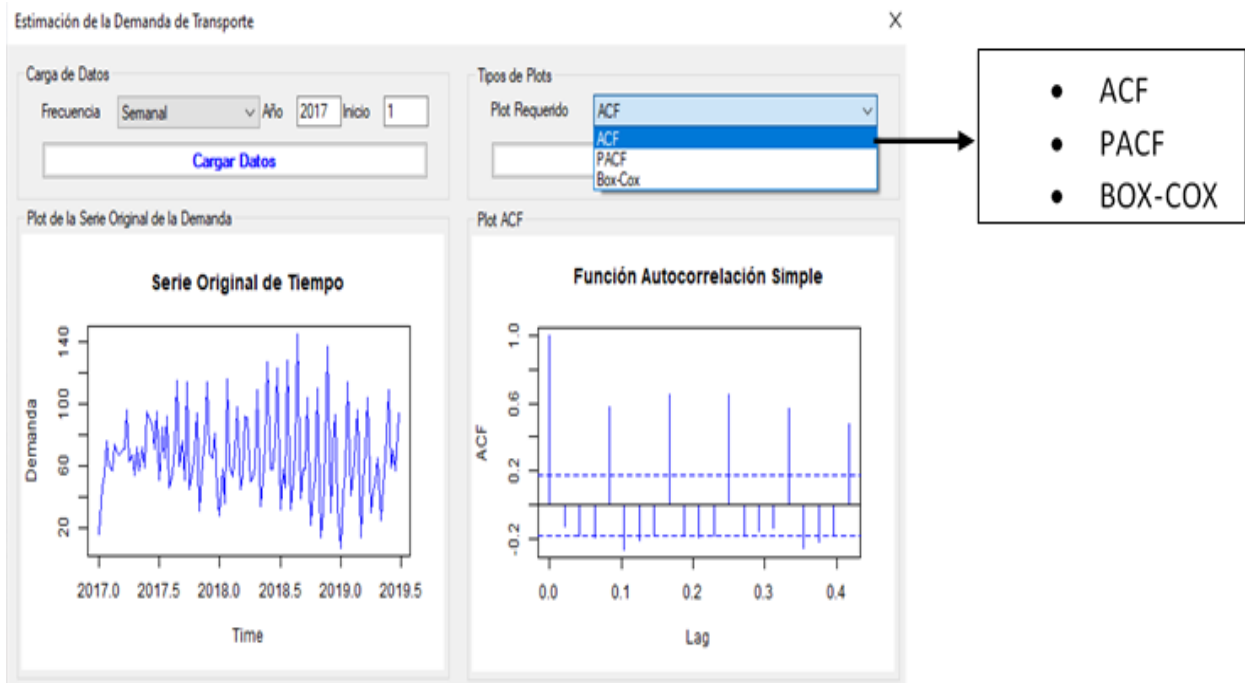


Ilustración 3.38 Ventana de Análisis Preliminar

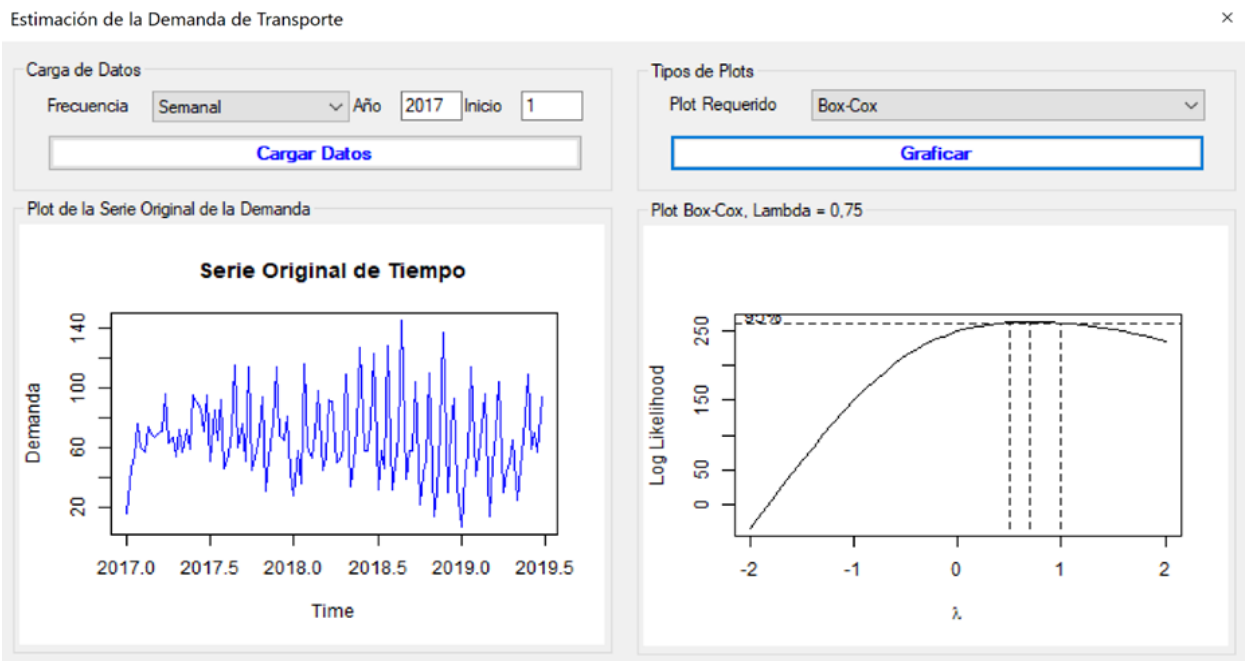
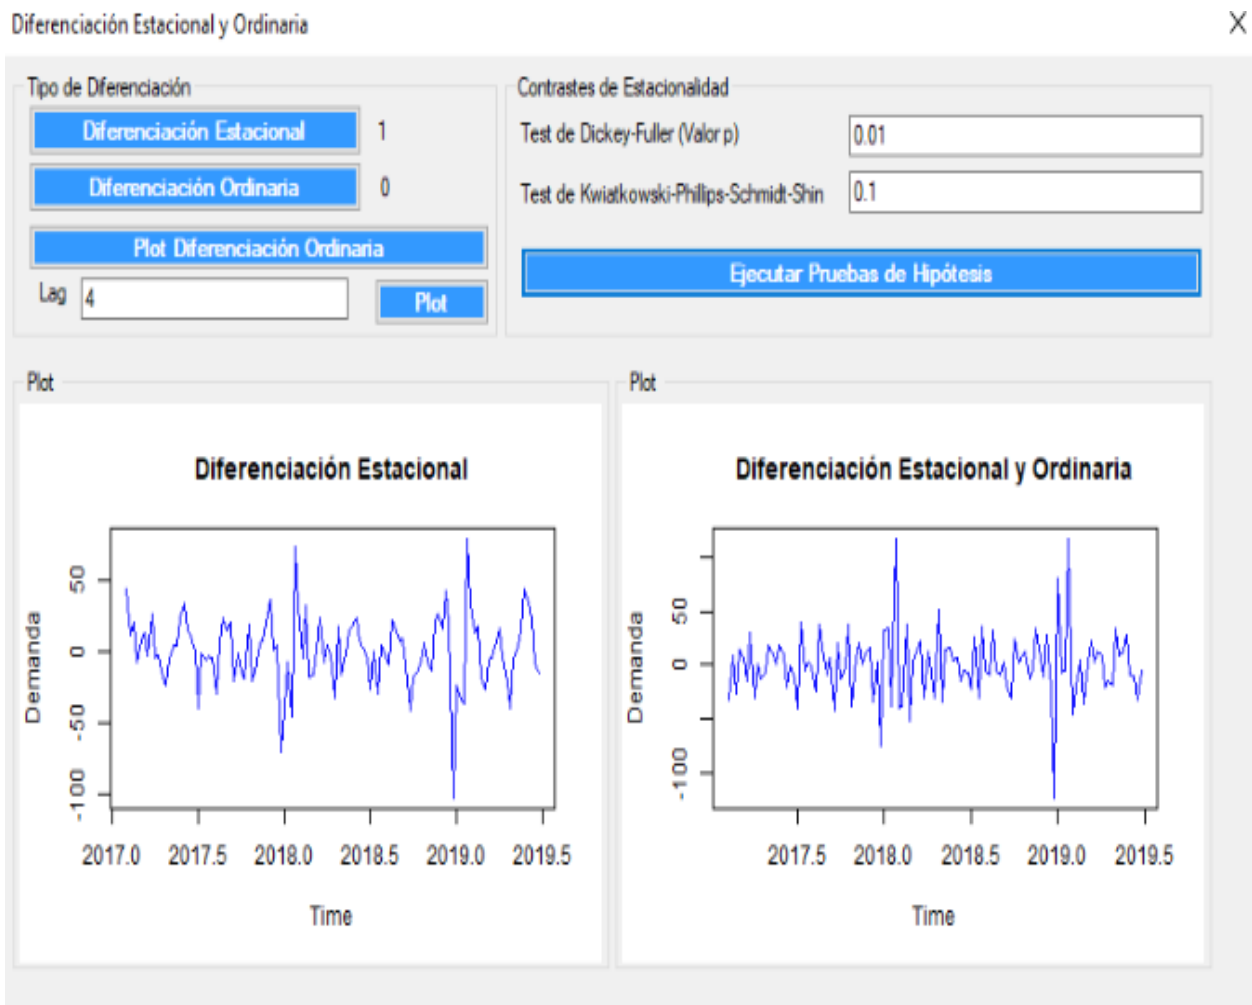


Ilustración 3.39 Ventana de Análisis Preliminar

## Diferenciación de la Serie:

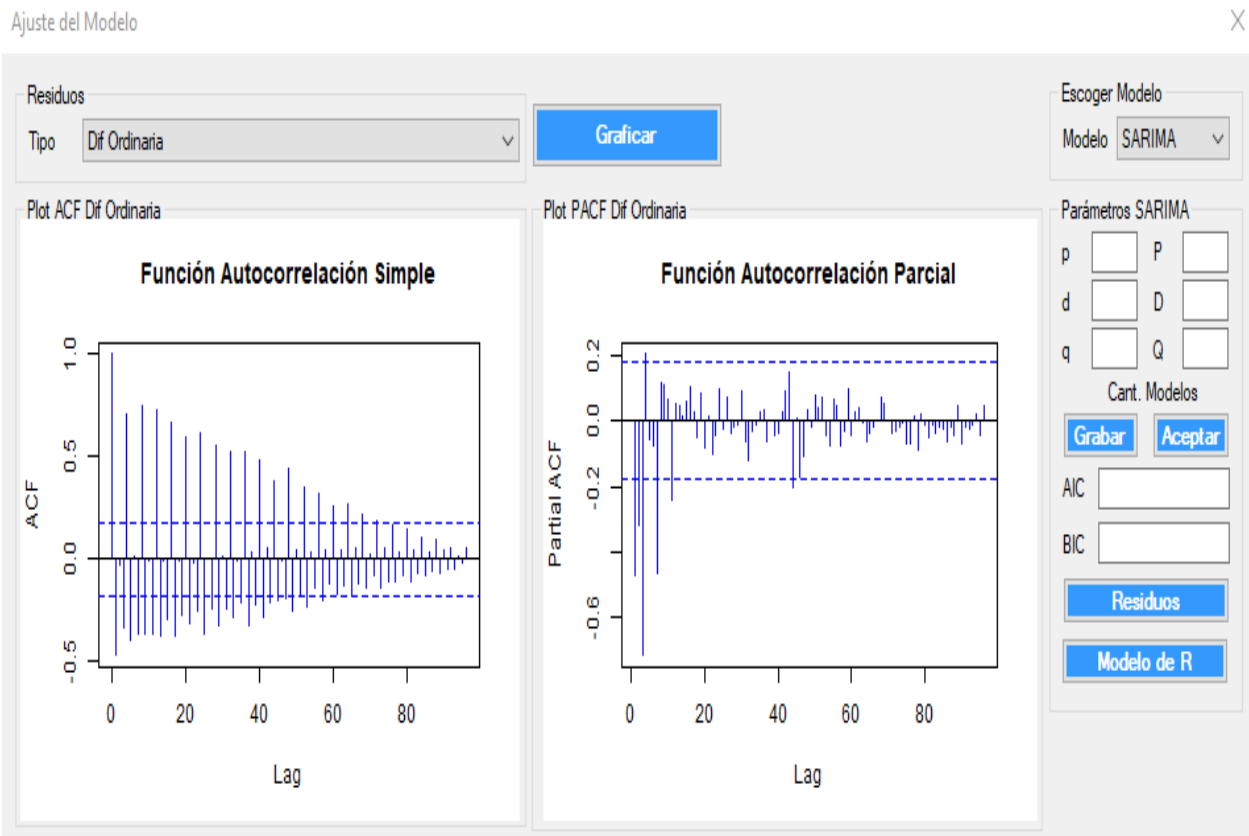
Para la opción de Diferenciación de la Serie, el usuario podrá verificar automáticamente el tipo de diferenciación que necesita la serie, además comprobar visualmente la diferenciación más conveniente según sea el caso; por último, el usuario puede constatar si la serie es estacionaria mediante las pruebas de hipótesis.



**Ilustración 3.40 Ventana de Diferenciación de la Serie Ajuste del Modelo**

La opción de Ajuste del Modelo permitirá de acuerdo a los análisis previos elegir el modelo a usar, ya sea ARIMA, o SARIMA, así como también sus parámetros y visualizar los gráficos de las funciones de autocorrelación (Residuos).

Para probar diferentes modelos, se da clic en la opción “Grabar”, al dar clic en la opción “Aceptar” se muestra el mejor modelo elegido según el criterio AIC. Adicionalmente la opción “Modelo de R”, arroja el modelo que R recomienda utilizar según su análisis

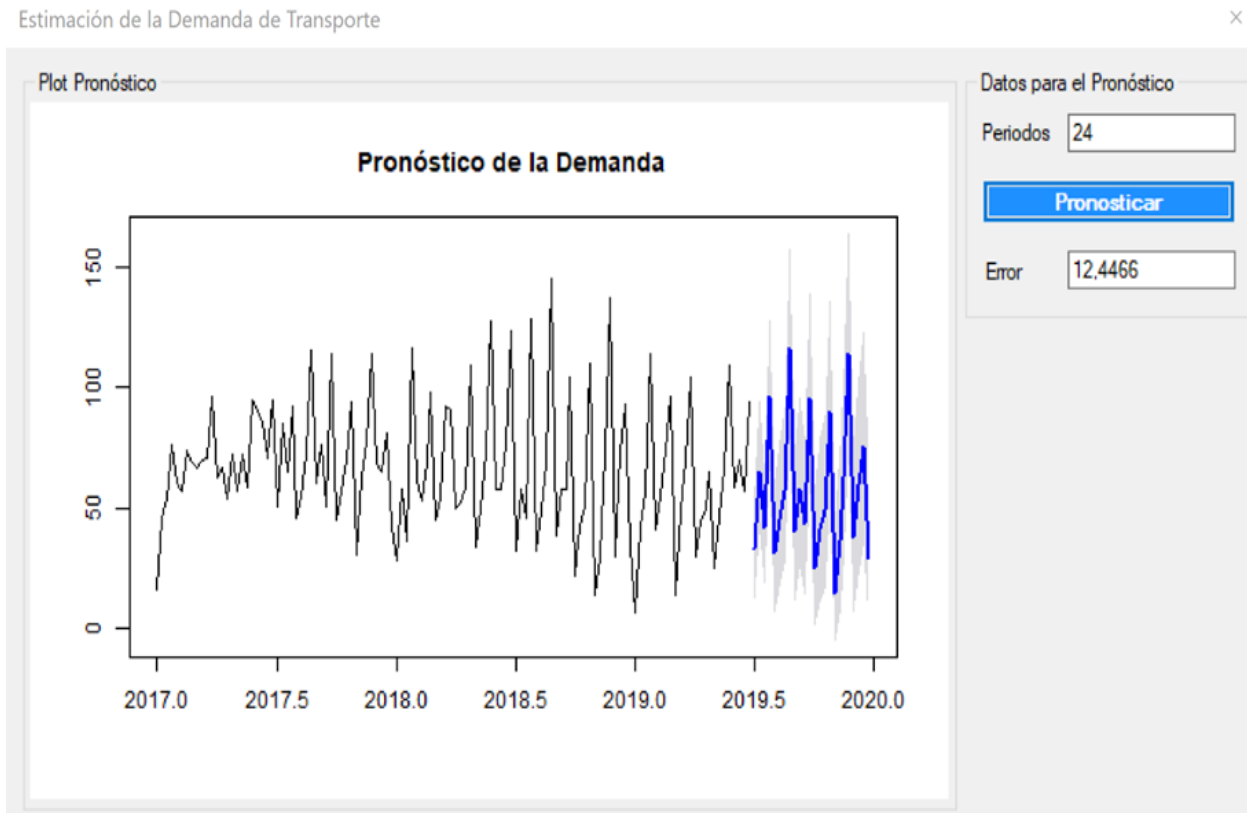


automático.

**Ilustración 3.41 Ventana de Ajuste del Modelo**

## Pronóstico

Finalmente, de acuerdo con el mejor modelo elegido en la opción anterior, la aplicación pronosticará los periodos que el usuario requiera con su respectivo error y gráfica del pronóstico.



**Ilustración 3.42 Ventana de Pronóstico**

Automáticamente se alzará un archivo Excel, mostrando los valores por cada periodo del pronóstico con su escenario pesimista y optimista respectivamente (Probabilidad 95%).

	A	B	C	D	E	F
1						
2		<b>Estimación de la Demanda</b>				
3						
4		<b>Pronóstico</b>	<b>Escenario Pesimista</b>	<b>Escenario Optimista</b>		
5	<b>Periodo 1</b>	33	12	59		
6	<b>Periodo 2</b>	65	39	94		
7	<b>Periodo 3</b>	42	19	68		
8	<b>Periodo 4</b>	96	66	128		
9	<b>Periodo 5</b>	31	7	62		
10	<b>Periodo 6</b>	45	17	78		
11	<b>Periodo 7</b>	57	27	92		
12	<b>Periodo 8</b>	116	78	158		
13	<b>Periodo 9</b>	41	12	76		
14	<b>Periodo 10</b>	58	25	96		
15	<b>Periodo 11</b>	43	14	80		
16	<b>Periodo 12</b>	96	57	139		
17						
18						
19						
20						
21						
22						
23						
24						
25						

**Ilustración 3.43 Archivo Excel con valores del Pronóstico**

# 4 CAPÍTULO

## 4.1 Conclusiones y Recomendaciones

A continuación, presentaremos las conclusiones y recomendaciones luego de haber analizado los resultados en el capítulo anterior.

### 4.1.1 Conclusiones

- Mediante el análisis de la demanda utilizando los datos históricos obtenidos de la empresa, se pudo determinar que en la última semana de cada mes existen picos en cuanto a los requerimientos del servicio por parte del cliente.
- Se utilizan modelos ARIMA estacionales (SARIMA) para la realización de los pronósticos debido a los picos de demanda antes mencionado (estacionalidad).
- Se debe estudiar todas las opciones posibles en cuanto al análisis de la serie de tiempo, para poder encontrar el modelo que se ajuste mejor y luego obtener un pronóstico aceptable, para aquello se debe analizar las diferentes gráficas que la interfaz permitirá visualizar.
- Se concluye que el modelo SARIMA que mejor se ajusta en cuanto a la demanda del cliente CG, fue el SARIMA  $(3,1,1) (1,1,0)_{48}$ , con un error porcentual absoluto del pronóstico (MAPE) del 12%.
- El mejor modelo que se ajusta en relación a la demanda del cliente KC es el de SARIMA  $(0,1,1) (0,1,0)_{48}$ , con un error porcentual absoluto del pronóstico (MAPE) del 16%.
- Es claro, que los pronósticos y resultados que se han presentado en este trabajo pueden ser mejorados mediante el aumento de nuevos datos, para su posterior análisis de series de tiempo.

- La interfaz que se realizó permite que se realice un estudio de series de tiempo exhaustivo, con visualizaciones de gráficas claves para encontrar el modelo que se pueda ajustar mejor y así obtener el pronóstico.

#### **4.1.2 Recomendaciones**

- Se recomienda a la empresa estandarizar la plantilla de Excel, donde se registran los pedidos de los clientes, ya que actualmente se maneja una plantilla distinta para cada uno y llevar un estándar ayudara a un mejor manejo de la información.
- Sugerimos a la empresa la actualización continua de los datos de cada cliente, ya que cuenta con muy pocas observaciones para ciertos clientes, así como una evaluación semestral de los modelos que se ajusten con los nuevos datos obtenidos.
- Recomendamos para el uso de la aplicación, que la empresa designe esta herramienta a una persona con las actitudes, capacidades y destrezas que implican el manejo de pronósticos de demanda.

# BIBLIOGRAFÍA

Gonzalo Ríos, (14 de Noviembre del 2018). *Universidad de Chile*. Obtenido de:

[https://www.u-cursos.cl/ingenieria/2010/1/CC52A/1/material\\_docente](https://www.u-cursos.cl/ingenieria/2010/1/CC52A/1/material_docente)

De la Fuente, S. (2008). *Series Temporales: Modelo ARIMA* Obtenido de Universidad

Autónoma de Madrid:

<http://www.estadistica.net/ECONOMETRIA/SERIES-TEMPORALES/modelo-arima.pdf>

Rosales, R. (Segundo Semestre del 2008). *Metodología Box-Jenkins*. Obtenido de

Universidad de los Andes-Facultad de Economía:

[https://economia.uniandes.edu.co/files/profesores/ramon\\_rosales\\_alvarez/docs/econometria2/Salidas%20y%20Ejercicios/EJC202220Metodologa20Box20-20Jenkins.pdf](https://economia.uniandes.edu.co/files/profesores/ramon_rosales_alvarez/docs/econometria2/Salidas%20y%20Ejercicios/EJC202220Metodologa20Box20-20Jenkins.pdf)

Alarcón Valverde, A. (2012). *Evaluación de Modelos Econométricos Alternativos de Series de Tiempo Para el Pronóstico de la Inflación en el Ecuador en el Corto Plazo*.

Obtenido de: <http://dspace.ucuenca.edu.ec/bitstream/123456789/1042/1/teco737.pdf>

Salazar, P. (2004). *Capítulo 15-Series de Tiempo y Pronósticos*.

Minchón Medina, Carlos A. (2011). *Modelo SARIMA para la llegada mensual de visitantes extranjeros por el Aeropuerto Internacional "Jorge Chávez"* Obtenido de:

<https://dialnet.unirioja.es/servlet/articulo?codigo=6181486>