



Universidad de San Carlos de Guatemala
Facultad de Ingeniería
Escuela de Estudios de Postgrado
Maestría en Estadística Aplicada

**PROPUESTA DE UN MODELO DE PRONÓSTICOS PARA OPTIMIZAR LA PLANIFICACIÓN
DE DEMANDA EN UNA EMPRESA COMERCIALIZADORA DE AROMATIZANTES PARA
VEHÍCULOS EN GUATEMALA**

Inga. Marilyn Lisbeth Calderón Fabian

Asesorado por el M.A. Ing. Oscar Efraín Quiñónez Reyes

Guatemala, marzo de 2024

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA



FACULTAD DE INGENIERÍA

**PROPUESTA DE UN MODELO DE PRONÓSTICOS PARA OPTIMIZAR LA PLANIFICACIÓN
DE DEMANDA EN UNA EMPRESA COMERCIALIZADORA DE AROMATIZANTES PARA
VEHÍCULOS EN GUATEMALA**

TRABAJO DE GRADUACIÓN

PRESENTADO A LA JUNTA DIRECTIVA DE LA
FACULTAD DE INGENIERÍA
POR

INGA. MARILYN LISBETH CALDERÓN FABIAN

ASESORADO POR EL M.A. ING. OSCAR EFRAÍN QUIÑÓNEZ REYES

AL CONFERÍRSELE EL TÍTULO DE

MAESTRA EN ESTADÍSTICA APLICADA

GUATEMALA, MARZO DE 2024

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA
FACULTAD DE INGENIERÍA



NÓMINA DE JUNTA DIRECTIVA

DECANO	Ing. José Francisco Gómez Rivera (a.i.)
VOCAL II	Ing. Mario Renato Escobedo Martínez
VOCAL III	Ing. José Milton de León Bran
VOCAL IV	Br. Kevin Vladimir Cruz Lorente
VOCAL V	Br. Fernando José Paz González
SECRETARIO	Ing. Hugo Humberto Rivera Pérez

TRIBUNAL QUE PRACTICÓ EL EXAMEN GENERAL PRIVADO

DECANO	Ing. José Francisco Gómez Rivera (a.i.)
EXAMINADORA	Inga. Aurelia Anabela Cordova Estrada
EXAMINADOR	Mtro. Ing. Edwin Adalberto Bracamonte Orozco
EXAMINADOR	Mtro. Ing. William Eduardo Fagiani Cruz
SECRETARIO	Ing. Hugo Humberto Rivera Pérez

HONORABLE TRIBUNAL EXAMINADOR

En cumplimiento con los preceptos que establece la ley de la Universidad de San Carlos de Guatemala, presento a su consideración mi trabajo de graduación titulado:

**PROPUESTA DE UN MODELO DE PRONÓSTICOS PARA OPTIMIZAR LA PLANIFICACIÓN
DE DEMANDA EN UNA EMPRESA COMERCIALIZADORA DE AROMATIZANTES PARA
VEHÍCULOS EN GUATEMALA**

Tema que me fuera asignado por la Dirección de la Escuela de Estudios de Postgrado, con fecha 28 de enero de 2022.



Inga. Marilyn Lisbeth Calderón Fabian

LNG.DECANATO.OI.119.2024

El Decano de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer la aprobación por parte del Director de la Escuela de Estudios de Posgrado, al Trabajo de Graduación titulado: **PROPUESTA DE UN MODELO DE PRONÓSTICOS PARA OPTIMIZAR LA PLANIFICACIÓN DE DEMANDA EN UNA EMPRESA COMERCIALIZADORA DE AROMATIZANTES PARA VEHÍCULOS EN GUATEMALA**, presentado por: **Inga. Marilyn Lisbeth Calderón Fabian**, que pertenece al programa de Maestría en artes en Estadística aplicada después de haber culminado las revisiones previas bajo la responsabilidad de las instancias correspondientes, autoriza la impresión del mismo.

IMPRÍMASE:


Ing. José Francisco Gómez Rivera
Decano a.i.



Guatemala, marzo de 2024

JFGR/gaoc



Guatemala, marzo de 2024

LNG.EEP.OI.119.2024

En mi calidad de Directora de la Escuela de Estudios de Postgrado de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer el dictamen del asesor, verificar la aprobación del Coordinador de Maestría y la aprobación del Área de Lingüística al trabajo de graduación titulado:

**“PROPUESTA DE UN MODELO DE PRONÓSTICOS PARA OPTIMIZAR
LA PLANIFICACIÓN DE DEMANDA EN UNA EMPRESA
COMERCIALIZADORA DE AROMATIZANTES PARA VEHÍCULOS EN
GUATEMALA”**

presentado por **Inga. Marilyn Lisbeth Calderón Fabian**
correspondiente al programa de **Maestría en artes en Estadística aplicada** ;
apruebo y autorizo el mismo.

Atentamente,

“Id y Enseñad a Todos”


Mtra. Inga. Aurelia Anabela Cordova Estrada
Directora
Escuela de Estudios de Postgrado
Facultad de Ingeniería





Guatemala, 29 de septiembre de 2022


M.A. Ing. Edgar Dario Alvarez Coti
Director
Escuela de Estudios de Postgrado
Presente

Estimado M.A. Ing. Alvarez Coti

Por este medio informo a usted, que he revisado y aprobado el **INFORME FINAL y ARTÍCULO CIENTÍFICO** titulado: **PROPUESTA DE UN MODELO DE PRONÓSTICOS PARA OPTIMIZAR LA PLANIFICACIÓN DE DEMANDA EN UNA EMPRESA COMERCIALIZADORA DE AROMATIZANTES PARA VEHÍCULOS EN GUATEMALA** del estudiante **Marilyn Lisbeth Calderón Fabian** quien se identifica con número de carné **200614955** del programa de Maestria En Estadística Aplicada.

Con base en la evaluación realizada hago constar que he evaluado la calidad, validez, pertinencia y coherencia de los resultados obtenidos en el trabajo presentado y según lo establecido en el **Normativo de Tesis y Trabajos de Graduación aprobado por Junta Directiva de la Facultad de Ingeniería Punto Sexto inciso 6.10 del Acta 04-2014 de sesión celebrada el 04 de febrero de 2014**. Por lo cual el trabajo evaluado cuenta con mi aprobación.

Agradeciendo su atención y deseándole éxitos en sus actividades profesionales me suscribo.



Msc. Ing. Edwin Adalberto Bracamonte Orozco
Coordinador
Maestria En Estadística Aplicada
Escuela de Estudios de Postgrado

Oficina Virtual




Guatemala, 29 de septiembre de 2022

M.A. Ing. Edgar Dario Alvarez Coti
Director
Escuela de Estudios de Postgrados
Presente

Estimado M.A. Ing. Alvarez Coti

Por este medio informo a usted, que he revisado y aprobado el Trabajo de Graduación y el Artículo Científico: **"PROPUESTA DE UN MODELO DE PRONÓSTICOS PARA OPTIMIZAR LA PLANIFICACIÓN DE DEMANDA EN UNA EMPRESA COMERCIALIZADORA DE AROMATIZANTES PARA VEHÍCULOS EN GUATEMALA"** del estudiante **Marilyn Lisbeth Calderón Fabian** del programa de **Maestria En Estadística Aplicada** identificado(a) con número de carné 200614955.

Agradeciendo su atención y deseándole éxitos en sus actividades profesionales me suscribo.



Oscar Efraín Quiñónez Reyes
Ingeniero Mecánico Industrial
Colegiado No. 12 383

Msc. Ing. Oscar Efraín Quiñónez Reyes
Colegiado No. 12383
Asesor de Tesis

ACTO QUE DEDICO A:

Dios	Por ser la luz de mi camino, por darme las fuerzas y sabiduría para alcanzar cada meta que me propongo.
Mis hijos	Martín y Marcela Fernández, por ser la inspiración y motor de mi vida, los amo infinitamente.
Mi esposo	Ricardo Fernández por ser el amor de mi vida, por el apoyo incondicional que me brinda todos los días, por ser mi mejor amigo y un padre excepcional para nuestro hijo.
Mis padres	Atilio Calderón y Verónica Fabian, por ser los pilares fundamentales en mi vida, por nuestro amor filial y por enseñarme a luchar siempre por lo que deseo. Este logro también es de ustedes.
Mis hermanas	Carol, Lucky e Ingrid Calderón Fabian, por nuestro amor fraternal y por ser mis mejores amigas.
Mis sobrinos	Eduardo, Andrea y Alexandra Balcárcel, Diego Arriaga, Andres, Javier y Angie López, porque los amo como si fueran mis hijos.

Mis abuelos

Emilio Fabian (q. e. p. d), Graciela Ramírez (q. e. p. d), Reynaldo Calderón (q. e. p. d) y Braulia Díaz por su amor y consejos.

Mis mejores amigos

Brenda Cermeño, Luis Castillo, Karen Orozco, Omar Ponce y Heidy Huertas, por su amistad incondicional, los quiero mucho mi familia por elección.

AGRADECIMIENTOS A:

Dios	Por ser el guía en mi camino, infinitas gracias por todas las bendiciones en mi vida.
Universidad de San Carlos de Guatemala	Por brindarme la oportunidad de estudiar en tan prestigiosa institución, siempre orgullosa de mi <i>alma mater</i> .
Escuela de Postgrados Facultad de Ingeniería	Por enseñarme las herramientas necesarias a través del conocimiento técnico y científico para desarrollarme en el ámbito del análisis de datos con enfoque estadístico.
Mi asesor de tesis	Ingeniero Efraín Quiñónez, por el apoyo y el seguimiento que me brindó durante el proceso de investigación.
Amigos de la maestría	En especial a Jenny Velásquez, Carlos Gramajo, Eric Ortega, Jorge García y Manuel Álvarez por el apoyo que me brindaron durante la maestría.
Docentes de la maestría	En especial a William Fagiani, Carlos Bolaños, Ezequiel López, Edwin Bracamonte y Aura Marina Rodríguez por las enseñanzas y el apoyo que me proporcionaron en la maestría.

ÍNDICE GENERAL

ÍNDICE DE ILUSTRACIONES	V
LISTA DE SÍMBOLOS	VII
GLOSARIO	IX
RESUMEN	XI
PLANTEAMIENTO DEL PROBLEMA.....	XIII
OBJETIVOS.....	XV
RESUMEN DEL MARCO METODOLÓGICO	XVII
INTRODUCCIÓN	XXI
1. MARCO REFERENCIAL	1
2. MARCO TEÓRICO	5
2.1. Estadística.....	5
2.1.1. Definición.....	5
2.1.2. Tipos de estadística.....	5
2.1.2.1. Estadística descriptiva	6
2.1.2.2. Estadística inferencial.....	6
2.1.2.2.1. Pruebas de hipótesis	6
2.2. Pronósticos.....	8
2.2.1. Definición	8
2.2.2. Clasificación.....	10
2.2.3. Métodos de pronósticos.....	11
2.2.3.1. Métodos cualitativos	11
2.2.3.2. Métodos cuantitativos	12
2.3. Series de tiempo.....	12

2.3.1.	Patrones o componentes.....	13
2.3.1.1.	Componente de tendencia	14
2.3.1.2.	Componente estacional.....	14
2.3.1.3.	Componente cíclico.....	14
2.3.1.4.	Componente aleatorio o irregular	15
2.3.2.	Clasificación	15
2.3.2.1.	Serie de tiempo estacionaria	15
2.3.2.2.	Serie de tiempo no estacionaria	16
2.3.3.	Supuestos estadísticos.....	16
2.3.4.	Procesos estocásticos.....	18
2.3.4.1.	El proceso de ruido blanco	18
2.3.4.2.	Caminata aleatoria o “ <i>Random Walk</i> ” ..	18
2.3.5.	Métodos para pronosticar	19
2.3.5.1.	Descomposición	19
2.3.5.2.	Promedios simples	20
2.3.5.3.	Promedios móviles	20
2.3.5.4.	Suavizado o alisado exponencial	22
2.3.5.4.1.	Suavizado o alisado exponencial simple.....	22
2.3.5.4.2.	Suavizado o alisado exponencial doble	23
2.3.5.4.3.	Suavizado o alisado exponencial triple	24
2.3.5.5.	<i>Box-Jenkins</i> (ARIMA)	26
2.3.6.	Medidas de error de pronóstico y criterios de información.....	34
2.3.6.1.	Desviación media absoluta (MAD)	35
2.3.6.2.	Error cuadrático medio (MSE)	35

2.3.6.3.	Error porcentual absoluto medio (MAPE)	36
2.3.6.4.	Error porcentual medio arcotangente (MAAPE).....	37
2.3.6.5.	Criterio de información de <i>Akaike</i> (AIC)	37
2.3.6.6.	Criterio de información <i>Akaike</i> corregido (AICc).....	37
2.3.6.7.	Criterio de información Bayesiano (BIC)	38
2.4.	Empresa	38
2.4.1.	Definición	38
2.4.2.	Clasificación.....	38
2.4.2.1.	Empresa comercializadora	39
2.4.2.1.1.	MYPYME.....	40
2.4.2.1.2.	Canales de distribución	40
2.4.3.	Planificación de la demanda	40
3.	PRESENTACIÓN DE RESULTADOS.....	43
3.1.	Diagnóstico del comportamiento de la serie temporal de las ventas históricas.....	43
3.2.	Evaluación de métodos de pronósticos	57
3.3.	Precisión de los modelos evaluados de pronóstico	62
3.4.	Propuesta de modelo de pronóstico	63
4.	DISCUSIÓN DE RESULTADOS.....	67
4.1.	Análisis interno	67
4.2.	Análisis externo	69

CONCLUSIONES.....73

RECOMENDACIONES75

REFERENCIAS.....77

APÉNDICES.....81

ÍNDICE DE ILUSTRACIONES

FIGURAS

Figura 1.	Descomposición de la serie temporal	15
Figura 2.	Promedios móviles simple y doble	22
Figura 3.	Proceso de construcción de un modelo de <i>Box-Jenkins</i>	28
Figura 4.	Coeficientes de autocorrelación y autocorrelación parcial de los modelos AR (1)	30
Figura 5.	Coeficientes de autocorrelación y autocorrelación parcial de los modelos MA (1) y MA (2)	31
Figura 6.	Coeficientes de autocorrelación y autocorrelación parcial de un modelo mixto ARMA (1, 1)	32
Figura 7.	Diagrama de dispersión del producto aromatizante para vehículos.....	45
Figura 8.	<i>Box-plot</i> de las ventas históricas-Aromatizante para vehículos	46
Figura 9.	Serie temporal-Ventas históricas 2018-2020	47
Figura 10.	Serie temporal-Ventas históricas 2018-2020 con sustitución de datos atípicos.....	48
Figura 11.	<i>Box-plot</i> de las ventas históricas-Aromatizante para vehículos con sustitución de datos atípicos	48
Figura 12.	Comportamiento de los residuos	53
Figura 13.	Descomposición de la serie temporal de ventas históricas.....	54
Figura 14.	Pruebas de estacionalidad y tendencia	55
Figura 15.	Estacionalidad aditiva	56
Figura 16.	Serie temporal de ventas históricas diferenciada.....	57

Figura 17. Gráfica de pronóstico de ventas con método de alisado exponencial triple.....	59
Figura 18. Gráfica de pronóstico de ventas con método Auto-ARIMA.....	60
Figura 19. Gráfica de pronóstico de ventas con método ARIMA (0,0,0), (1,1,0)[12]	62
Figura 20. Diagrama de dispersión de las ventas históricas con sustitución de datos atípicos	68

TABLAS

Tabla 1. Operativización de variables.....	XVIII
Tabla 2. Técnicas de pronósticos	9
Tabla 3. Resumen de FAC y FACP	34
Tabla 4. Resumen estadístico descriptivo	43
Tabla 5. Base de datos de las ventas históricas-Aromatizante para vehículos	44
Tabla 6. Prueba de <i>Dickey-Fuller</i> Aumentado	49
Tabla 7. Pruebas de Lagrange Multiplier y (SNHT)	50
Tabla 8. Prueba de <i>Epps</i>	51
Tabla 9. Pruebas de Box-Pierce y Ljung-Box	52
Tabla 10. Pronóstico de ventas con método de <i>Holt-Winters</i>	58
Tabla 11. Pronóstico de ventas con método Auto-ARIMA.....	60
Tabla 12. Pronóstico de ventas con método ARIMA (0,0,0),(1,1,0)[12].....	61
Tabla 13. Comparación de criterios de información y medidas de error de pronóstico	63
Tabla 14. Resumen de comprobación de supuestos de la serie temporal	64
Tabla 15. Resumen de pruebas de estacionalidad y tendencia de la serie temporal.....	65
Tabla 16. Ventas históricas con sustitución de datos atípicos.....	68

LISTA DE SÍMBOLOS

Símbolo	Significado
α	Alfa (constante de suavizado).
β	Beta (constante de suavizado correspondiente a la tendencia).
$\phi_0, \phi_1, \phi_2, \dots, \phi_p$	Coeficientes de estimación
$\omega_1, \omega_2, \dots, \omega_q$	Coeficientes de estimación
T_t	Componente de tendencia
S_t	Componente estacional
I_t	Componente irregular
$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$	Errores en períodos anteriores
γ	Gamma (constante de suavizado correspondiente a la estacionalidad).
i	Longitud de la estacionalidad en número de periodos
e_t	Modelado del componente estacional de la serie temporal para el período t.
b_t	Modelado de la pendiente de la serie temporal para el período t.
p	Número de períodos en el futuro, por pronosticar
k	Número de términos en el promedio móvil
M	Número de veces que se incrementa la pendiente a partir del primer valor de pronóstico calculado.
%	Porcentaje
μ	Promedio constante
F_t	Pronóstico de la serie temporal en el período t.

F_{t-1}	Pronóstico de la serie temporal para el período t-1.
Y_t	Serie de tiempo
ε_t	Término de error en el tiempo t
$\hat{Y}_t$	Valor del pronóstico en el período t
Y_{t-1}	Variable en el período t-1, es decir, con un rezago

GLOSARIO

Bondad de ajuste	Describe lo bien que se ajusta un modelo estadístico a un conjunto de observaciones.
Cadena de suministro	Es el conjunto de actividades, instalaciones y medios de distribución necesarios para llevar a cabo el proceso de venta de un producto en su totalidad.
Cliente	Es una persona o entidad que compra los bienes y servicios que ofrece una empresa.
Demanda	Es la cantidad total de un bien o servicio que la gente desea adquirir.
Diagrama de caja y bigotes	También llamados <i>box-plot</i> , son una presentación visual que describe varias características importantes, al mismo tiempo, tales como la dispersión y simetría.
Diagrama de dispersión	Es una presentación pictórica de la relación entre dos variables. Puede utilizarse para averiguar la correlación entre las variables.
Horizonte de tiempo	Es a cuánto tiempo se hace la predicción

Muestra	Es un subconjunto de datos perteneciente a una población de datos.
Parámetro	Es un número que resume la gran cantidad de datos que pueden derivarse del estudio de una variable estadística.
Población	Es el total de individuos o conjunto de ellos que presentan o podrían presentar el rasgo característico que se desea estudiar.
Q-Q Plot	Los gráficos Q-Q (cuantil-cuantil) comparan dos distribuciones de probabilidad mediante el trazado de sus cuantiles uno contra el otro.
Raíz unitaria	Es una característica de los procesos que evolucionan a través del tiempo y que puede causar problemas en inferencia estadística en modelos de series de tiempo.
Residuo	Es la diferencia entre el valor observado de la variable dependiente y el valor proyectado por la ecuación de regresión.
R Studio	Paquete de <i>software</i> estadístico
Rezago	Es un término que puede utilizarse para nombrar un retraso o un aplazamiento.

RESUMEN

El propósito de la presente investigación fue proponer un modelo de pronósticos para optimizar la planificación de demanda en una empresa comercializadora de aromatizantes para vehículos, en Guatemala, se considera la gran importancia que tienen los pronósticos en los negocios, ya que les ayuda a controlar su inventario y a planificar de forma óptima la demanda de cada producto. El estudio es de mucha utilidad ya que la empresa no planifica el abastecimiento oportuno ni conoce el comportamiento de la demanda en función del tiempo del producto en estudio.

La investigación fue de tipo cuantitativo, con diseño no experimental dado que se trabajó con la base de datos de las ventas históricas de los años 2018, 2019 y 2020, y el alcance fue descriptivo correlacional. Se aplicaron técnicas como análisis de estadística descriptiva, gráfica de dispersión de datos, comprobación de supuestos estadísticos y métodos de series temporales como el de suavización exponencial triple y ARIMA.

Se realizaron los pronósticos a corto plazo de su producto aromatizante para vehículos con el modelo Auto-ARIMA (1,1,0), (0,1,0)[12] AR de grado uno, con diferenciación de grado uno en la parte de tendencia y diferenciación de grado uno en la parte estacional, debido a que este modelo generó un criterio de información de *Akaike* de -41.34 y un error porcentual absoluto medio de 5.16 %.

Es necesario que la empresa realice un diagnóstico de la demanda de sus productos por lo menos cada tres meses, para poder pronosticar sus ventas históricas con el modelo que mejor se ajuste a los datos.

PLANTEAMIENTO DEL PROBLEMA

Contexto general

La empresa que se tomó de referencia para este estudio de investigación es una empresa familiar que opera desde el año 1998, se dedica a la comercialización y fabricación de productos automotrices, ubicada en zona 7 de la ciudad de Guatemala. Entre los grupos de familia de tipo automotriz que venden, se encuentran los lubricantes, aromatizantes, productos de limpieza y mantenimiento. Tienen las siguientes marcas de representación: Aromáticos LD España y Lubricantes Gonher de México.

La Gerencia Administrativa realiza la compra de materiales y productos bajo criterio personal, sin realizar una planificación de abastecimiento, por lo que se considera de gran importancia analizar el comportamiento de la demanda del producto líder del grupo de familia aromatizantes, el cual importan desde España, para proponer un modelo de series temporales que se adapte mejor a la demanda del producto.

Descripción del problema

La empresa no realiza una planificación de abastecimiento para la compra de sus materiales y productos; para esta situación se tomó la decisión de analizar el comportamiento de uno de sus productos de importación (aromatizante para vehículos) de la marca Aromáticos LD España, debido a que no han implementado un modelo para calcular su demanda futura, lo que provoca quiebres de *stock*, ventas pérdidas y altos costos de operación.

Debido a esto es necesario analizar el comportamiento de la demanda, conocer las técnicas de pronósticos que se utilizarán y con base a esto elegir el modelo estadístico que mejor se adapte, para poder pronosticar óptimamente la compra de este.

Formulación del problema

Pregunta central

¿Cuál es el modelo de pronósticos para optimizar la planificación de demanda en una empresa comercializadora de aromatizantes para vehículos en la Ciudad de Guatemala?

Preguntas auxiliares

- ¿Cuál es el diagnóstico del comportamiento de la demanda en función del tiempo de las ventas de los años 2018, 2019 y 2020?
- ¿Qué métodos de pronósticos se evaluarán en la serie de datos histórica de ventas?
- ¿Qué modelo genera el menor criterio de información y la menor medida de error de pronóstico?

Delimitación del problema

Se analizó la demanda del producto aromatizante para vehículos, y sus ventas de los años 2018, 2019 y 2020, de una empresa que comercializa en Guatemala.

OBJETIVOS

General

Proponer un modelo de pronósticos para optimizar la planificación de demanda en una empresa comercializadora de aromatizantes para vehículos en Guatemala.

Específicos

1. Realizar un diagnóstico del comportamiento de la demanda en función del tiempo de las ventas históricas de los años 2018, 2019 y 2020.
2. Evaluar el histórico de ventas por medio del análisis de series temporales utilizando los métodos de pronósticos específicos según los patrones de la demanda.
3. Comprobar la precisión de los modelos específicos que se evaluarán, utilizando los criterios de información y las medidas de error de pronósticos.

RESUMEN DEL MARCO METODOLÓGICO

La presente investigación es de tipo cuantitativo, con diseño no experimental y alcance descriptivo correlacional.

Características del estudio

El enfoque de esta investigación es de tipo cuantitativo debido a que se analizó el comportamiento de la demanda del producto aromatizantes para vehículos.

El diseño del presente estudio es no experimental, debido a que se trabajó con base de datos de las ventas históricas de los años 2018, 2019 y 2020.

El alcance es descriptivo correlacional; descriptivo porque se estudiaron las causas, características y propiedades de la variable dependiente (ventas) y correlacional porque se analizó la relación que tiene la variable dependiente (ventas) con la variable independiente (tiempo) con el fin de pronosticar las ventas futuras.

La investigación es de tipo descriptivo correlacional debido a que se analizó la relación que tienen las variables de estudio.

Unidades de análisis

La población de estudio fueron las ventas históricas del producto aromatizantes para vehículos de los años 2018, 2019 y 2020.

Operativización de variables

Tabla 1.

Operativización de variables

Variable	Definición teórica	Definición operativa	Escala
Ventas en unidades (Y) variable dependiente	Una venta es toda actividad que lleva al intercambio de un bien o servicio por dinero. En este caso se estudiaron las ventas del producto aromatizante para vehículos.	Se realizó mediante una base de datos de ventas históricas en unidades, presentación tipo jarra que contiene 42 unidades del producto en estudio. El papel estadístico que juega dentro del estudio es como variable aleatoria que describió el modelo estadístico.	De razón
Tiempo en meses (X) variable independiente	El tiempo es el periodo en el que se analizaron las ventas.	El estudio tomó de referencia un período de tiempo de tres años de enero de 2018 a diciembre de 2020.	De razón

Nota. Se presentan las variables utilizadas. Elaboración propia, realizado con Microsoft Excel 2022.

Fases del estudio

En el presente estudio de investigación se estimaron las variables involucradas las cuales se desarrollaron en las siguientes cinco fases:

Fase 1: revisión de información documental

En esta fase se recolectó toda la bibliografía que fundamentó los temas que se analizaron en esta investigación, como lo son los pronósticos, las series

temporales, las PYME, la medición de criterios de información y la medición de errores de pronósticos.

Fase 2: recopilación de la información

En la segunda fase la empresa que se analizó proporcionó una base de datos en donde detallan las ventas mensuales del producto aromatizantes para vehículos desde el mes de enero del 2018 a diciembre de 2020, las cuales se registraron en su sistema interno cada vez que realizaban una venta del producto en estudio.

Fase 3: análisis exploratorio de los datos

Primero se realizó un diagnóstico del comportamiento de la demanda del producto en estudio a través del análisis de la estadística descriptiva, con gráficas de las ventas de enero de 2018 a diciembre de 2020 con diagrama de dispersión y diagrama de caja y bigotes, luego se realizó el análisis exploratorio, verificación de datos atípicos, descomposición de la serie temporal y por último se realizó la comprobación de los supuestos estadísticos de la serie temporal de las ventas históricas para evaluar los respectivos métodos de pronósticos.

Fase 4: interpretación de resultados

En esta fase se analizaron los resultados obtenidos en cada método de pronóstico en el lenguaje de programación R con el entorno R Studio, así como también se eligió el modelo de predicción que menor criterio de información y medida de error generaron para pronosticar las ventas futuras.

Fase 5: redacción de informe final

En esta fase se redactaron el informe final, la discusión de resultados, las conclusiones, las recomendaciones y el resumen.

INTRODUCCIÓN

El presente estudio de investigación fue una sistematización del proceso de planificación de la compra del producto aromatizantes para vehículos que importa la empresa representante de la marca Aromáticos LD España.

La empresa no planifica el abastecimiento oportuno, ni conoce el comportamiento de la demanda en función del tiempo del producto en estudio, por lo que se realizó un diagnóstico general de la serie de tiempo para evaluar los métodos de pronósticos correspondientes; se comprobó la precisión de los modelos para pronosticar las ventas futuras.

Los pronósticos de ventas son importantes para una empresa, ya que les ayuda a controlar su inventario y a planificar de forma óptima la demanda de cada producto, materia prima, material de empaque o insumos para que todas las áreas involucradas puedan tomar decisiones más acertadas que favorezcan la rentabilidad de la empresa.

La metodología de la investigación fue de tipo cuantitativo, con diseño no experimental y alcance descriptivo correlacional. Las variables que se analizaron fueron las ventas históricas del producto aromatizantes para vehículos como variable dependiente y, el periodo de tiempo de los años 2018 a 2020, se evaluaron como variable independiente.

Se propuso que la empresa realice análisis de series temporales a sus productos con el fin de que tengan óptimos inventarios en *stock* para poder abastecer a sus clientes y no incurrir en costos altos de operación, ya que pueden

generar mayor ganancia. Este procedimiento lo pueden replicar como referencia para otros productos que vendan con las mismas características.

Para realizar la presente investigación se comenzó con la revisión de la información documental, se buscó toda la bibliografía que fundamentó los temas que se mencionan en el presente estudio. Luego se recopiló la serie temporal de las ventas históricas de enero de 2018 a diciembre de 2020, de la base de datos que proporcionó la empresa. Seguidamente se realizó un diagnóstico del comportamiento de la demanda en función del tiempo y, según los patrones de la serie temporal se evaluaron los datos con los métodos específicos de pronósticos, luego se evaluó la precisión de cada modelo para lo que se utilizaron las medidas de error de pronósticos. Seguidamente se analizaron los resultados obtenidos en cada método de pronóstico, así como también se eligió el modelo de predicción que menor criterios de información y menor error de pronóstico generó para pronosticar las ventas futuras y por último se redactó el informe final.

El trabajo de investigación fue factible debido a que se contaron con todos los recursos necesarios para desarrollar todas las fases del estudio.

En el primer capítulo se describió el marco referencial de las investigaciones relacionadas con los temas que se abordaron en el presente estudio, las cuales se han sustentado con anterioridad, estas sirvieron de base para la investigación en curso.

En el segundo capítulo se describió el marco teórico, el cual se divide en dos partes, la primera contiene la parte estadística que detalla los conceptos, fundamentos, teorías y ecuaciones que sustentaron la investigación y, en la segunda parte se detallaron los conceptos en donde se realizó el estudio; en este caso la empresa en donde se hizo el análisis de las ventas históricas.

En el tercer capítulo se elaboró la presentación de resultados, en donde se realizó un diagnóstico general de la serie de tiempo de las ventas históricas, se graficaron los diagramas de dispersión y de caja y bigotes, luego se evaluó si la serie temporal de ventas contaba con datos atípicos, seguido de análisis exploratorio de los datos como comprobación de supuestos estadísticos, descomposición de la serie temporal, luego con el conocimiento del comportamiento de la demanda, se evaluaron los datos en los métodos de suavizado exponencial triple o de *Holt-Winters* y método de ARIMA, finalmente se comprobó la precisión de los modelos con los criterios de información y las medidas de error de pronósticos.

En el cuarto capítulo se realizó la discusión de resultados, una parte de análisis interno en donde se argumentó el motivo de la selección del modelo Auto-ARIMA y otra parte de análisis externo en donde se contrastó con los estudios que se han realizado con anterioridad.

Y por último se presentan las conclusiones y recomendaciones de la presente investigación.

1. MARCO REFERENCIAL

Los pronósticos de ventas son importantes para una empresa, ya que le ayuda a controlar su inventario y a planificar de forma óptima la demanda de cada producto, materia prima, material de empaque o insumos para que todas las áreas involucradas puedan tomar decisiones más acertadas, que favorezcan la rentabilidad de la empresa. Se tomaron de referencia las siguientes investigaciones y artículo que aportaron a la propuesta de análisis de comportamiento de la demanda que se realizó.

En la tesis de Gallegos (2019) titulada *Disminución de desabasto mediante un pronóstico de demanda y una política de inventarios*, el autor de la investigación redujo el desabasto del producto terminado de arneses automotrices, producido por las variaciones de demanda, y realizó el análisis de los datos históricos para los siguientes métodos de pronósticos: promedio móvil, promedio móvil ponderado, suavización exponencial, *Holt-Winters*, así como también evaluó la política de inventario. Concluyó que el mejor resultado obtenido para pronosticar la demanda fue con el modelo de suavización exponencial, en el cual se tenía el menor error porcentual. Esta investigación sirvió de referencia para evaluar la serie temporal de ventas históricas con los métodos de pronósticos indicados anteriormente, con el fin de comparar los resultados con métodos adicionales, para evaluar en conjunto los modelos de pronóstico y elegir el modelo con mejor precisión.

Gallegos (2019) indica:

Un punto clave en el correcto funcionamiento de la cadena de suministro es el pronóstico de demanda que un cliente le hace llegar a sus proveedores. Cuando este llega a ser incorrecto o inconsistente, se incurre en gastos que no se tenían contemplados, lo que causa una disrupción en los procesos. (p. 1)

En el artículo que trata sobre la aplicación de pronósticos en la toma de decisiones en las micro, pequeñas o medianas empresas, los autores hacen énfasis en que deben de implementar un adecuado pronóstico para que las personas que tomen las decisiones en las mismas puedan predecir de forma sistemática las decisiones para las áreas operativas. Uno de los criterios más importantes de este artículo es la elección del modelo que genera el menor margen de error.

Pérez, Cruz, Villalobos, & Juárez (2018) indican que:

Para aplicar un método de pronósticos, es fundamental contar con serie de datos que permitirán determinar aquel método cercano al futuro deseado, considerando el error que pudiera presentarse, mismo que será medido por las diferentes técnicas acercando al valor exacto del error cero. (p. 114)

Por lo que este artículo apoyó de referencia para la elección del método que generó el menor margen de error en los datos de estudio.

En la tesis de Frausto (2009) titulada *Pronósticos de ventas para la administración estratégica de los recursos en una empresa del sector automotriz*, cinco productos de una empresa de autopartes fueron evaluados con diferentes tipos de pronósticos, entre los cuales están los cualitativos, de análisis gráfico, cuantitativos, de descomposición de series, auto correlacionados, regresión múltiple y redes neuronales. Lo primero que se realizó en la investigación fue la clasificación y ordenamiento de la información, luego graficaron los datos, después se evaluaron los datos históricos para cada uno de los métodos indicados, luego se evaluaron los índices de error para cada modelo seleccionado y, por último, se comparó el mejor método para pronosticar las ventas.

De esta tesis se tomó de referencia la evaluación del método de los modelos de autocorrelación con el método ARIMA, según Frausto (2009) “la metodología *Box-Jenkins* para generar pronósticos es distinta de la mayoría de los métodos debido a que no supone un patrón particular en los datos históricos de las series que han de pronosticarse” (p. 42).

En la tesis de Ojeda (2017) enfocada al sector calzado, *Modelo de gestión para la planificación de las operaciones en las pymes del sector calzado y su impacto en el rendimiento de la inversión*, en donde evalúan el rendimiento de la inversión, los métodos de suavizamiento exponencial de Brown, suavizamiento exponencial lineal de Holt, suavizamiento exponencial de Winter, modelos auto regresivos de ARIMA, así como también se planificaron las operaciones en las áreas de ventas y producción tomando en cuenta la capacidad de instalación de la empresa, determinaron el *ROIC* de la empresa y propusieron acciones de mejora en la cadena de suministros.

Ojeda (2017) afirma: “Disponer de un modelo de gestión también genera enfoque en la administración de las operaciones ya que permite conocer exactamente en donde se debe concentrar los esfuerzos de mejora continua para maximizar el rendimiento del capital invertido por los accionistas” (p. 72).

De este trabajo de investigación se tomaron de referencia los procesos que recomiendan realizar para las PYMES.

En la tesis *Pronóstico de Demanda utilizando la metodología de Box-Jenkins*, Echegaray (2017) indica: “Hay dos enfoques al análisis de datos de series de tiempo, un enfoque basado en descomposición en bandas de frecuencia denominado análisis espectral y un enfoque basado en el modelado de la varianza mediante la estructura ARIMA” (p. 8). En este estudio se realizó el análisis del pronóstico de demanda con el método ARIMA en el cual se elaboró un gráfico para identificar los componentes o patrones de los datos, luego un análisis de autocorrelación de los datos, seguido de la transformación de la serie y por último se graficaron la FAC de la serie transformada y la FACP para la serie estacionaria. Cuando eligieron el modelo apropiado, evaluaron el modelo con base a los errores de los residuos para verificar las hipótesis requeridas. Este trabajo de investigación sirvió de guía para realizar el proceso al evaluar el método ARIMA en los datos de estudio.

2. MARCO TEÓRICO

2.1. Estadística

Ciencia que estudia la recolección, organización, planificación y análisis de los datos, con el objetivo de tomar decisiones eficaces y realizar estimaciones futuras.

2.1.1. Definición

“Ciencia por medio de la cual se recogen, organizan, presentan, analizan e interpretan datos con el fin de propiciar una toma de decisiones más eficaz” (Lind, Marchal y Wathen, 2015, p. 3).

Salazar y Del Castillo (2018) afirman: “Es la ciencia que se encarga de la recolección, ordenamiento, representación, análisis e interpretación de datos generados en una investigación sobre hechos, individuos o grupos de estos, para deducir de ello conclusiones precisas o estimaciones futuras” (p. 13).

2.1.2. Tipos de estadística

“Básicamente la estadística se divide en dos grandes ramas: estadística descriptiva o matemática y estadística inferencial, estas dos divisiones se articulan adecuadamente mediante las probabilidades” (Salazar y Del Castillo, 2018, p. 14).

2.1.2.1. Estadística descriptiva

“Métodos para organizar, resumir y presentar datos de manera informativa” (Lind, *et al.*, 2015, p. 4).

Salazar y Del Castillo (2018) afirman “Es la parte de la estadística que permite analizar todo un conjunto de datos, de los cuales se extraen conclusiones valederas, únicamente para ese conjunto. Para realizar este análisis se procede a la recolección y representación de la información obtenida” (p. 14).

2.1.2.2. Estadística inferencial

“Métodos que se emplean para determinar la propiedad de una población con base en la información de una muestra de esta” (Lind, *et al.*, 2015, p. 5).

Salazar y Del Castillo (2018) indican “entonces se puede concluir que la estadística inferencial analiza o investiga a una población, valiéndose de los datos y resultados que se obtienen de una muestra” (p. 14).

2.1.2.2.1. Pruebas de hipótesis

“Procedimiento basado en evidencia de la muestra y la teoría de la probabilidad para determinar si la hipótesis es una afirmación razonable” (Lind, *et al.*, 2015, p. 283). Se refiere a la afirmación o a la suposición sobre un parámetro de la población.

Walpole, Myers, Myers y Ye (2012) confirman:

La estructura de la prueba de hipótesis se establece usando el término hipótesis nula, el cual se refiere a cualquier hipótesis que se desea probar y se denota con H_0 . El rechazo de H_0 conduce a la aceptación de una hipótesis alternativa, que se denota con H_1 . La comprensión de las diferentes funciones que desempeñan la hipótesis nula (H_0) y la hipótesis alternativa (H_1) es fundamental para entender los principios de la prueba de hipótesis. La hipótesis alternativa H_1 por lo general representa la *pregunta que se responderá o la teoría que se probará*, por lo que su especificación es muy importante. La hipótesis nula H_0 *anula o se opone a H_1* y a menudo es el complemento lógico de H_1 (p. 320).

- Prueba de P

Molina (2017) afirma:

Y este es el valor de p: la probabilidad de obtener, por azar, una diferencia tan grande o mayor de la observada, cumpliéndose que no haya diferencia real en la población de la que proceden las muestras. Así, por convenio suele establecerse que si este valor de probabilidad es menor del 5 % (0,05) es lo suficientemente improbable que se deba al azar como para rechazar con una seguridad razonable la H_0 y afirmar que la diferencia es real. Si es mayor del 5 %, no tendremos la confianza necesaria como para poder negar que la diferencia observada sea obra del azar. (p. 378)

2.2. Pronósticos

Sirven para estimar eventos de incertidumbre, ayudan para planificar la demanda de algún producto o servicio en específico para generar pronósticos en los negocios.

2.2.1. Definición

Un pronóstico es la estimación del comportamiento futuro de alguna variable en función del tiempo en situaciones de incertidumbre. Los pronósticos también se enfocan en la planificación de la demanda, en donde aportan información valiosa para un óptimo abastecimiento de los productos o servicios de alguna empresa o para la realización de nuevos proyectos. Cuando se realiza un adecuado análisis de pronósticos, las siguientes áreas se benefician: presupuestos, finanzas, compras, planificación, producción, bodega, mercadeo y ventas, así como también el cliente externo.

Schroeder, Meyer y Rungtusanatham (2011) afirman:

El pronóstico es un insumo para todos los tipos de planeación y control de los negocios, tanto dentro como fuera de la función de operaciones. El marketing recurre a los pronósticos para la planeación de los productos, la promoción y el establecimiento de precios. Finanzas los usa como un insumo para la planeación financiera. El pronóstico es un insumo para las decisiones de operaciones relacionadas con el diseño del proceso, la planeación de la capacidad y los inventarios. (p. 239)

Lo que se debe realizar luego de identificar la serie temporal con la que se trabajará es lo siguiente:

- Recopilación de datos de la serie de tiempo
- Limpieza de los datos
- Evaluación de las técnicas de pronósticos
- Implementación del modelo de pronóstico
- Evaluación del modelo de pronóstico

Para elegir una técnica de pronósticos, se detallan en la siguiente tabla las técnicas o métodos que se deben evaluar, según los componentes de la serie temporal, indica el horizonte que puede pronosticar cada modelo, el método y los datos mínimos requeridos para evaluar según sean estacionales o no estacionales:

Tabla 2.

Técnicas de pronósticos

Método	Patrón de datos	Horizonte de tiempo	Tipo de modelo
Promedios simples	Estacionario	Corto plazo	Serie de tiempo
Promedios móviles	Estacionario	Corto plazo	Serie de tiempo
Suavizamiento exponencial	Estacionario	Corto plazo	Serie de tiempo
Suavizamiento exponencial simple	De tendencia	Corto plazo	Serie de tiempo
Suavizamiento exponencial doble o de Holt	De tendencia	Corto plazo	Serie de tiempo
Suavizamiento exponencial triple o de Holt-Winters	Estacional y de tendencia	Corto plazo	Serie de tiempo
Regresión simple	De tendencia	Mediano plazo	Causal
Descomposición	Estacional	Corto plazo	Serie de tiempo

Continuación tabla 2.

Box-Jenkins (ARIMA)	Estacionario, de tendencia, estacional y cíclico	Corto plazo	Serie de tiempo
---------------------	---	-------------	-----------------

Nota. Se presentan las técnicas de pronósticos. Elaboración propia, realizado con Microsoft Excel basado en Hanke y Wichern (2010). *Pronósticos en los negocios.*

2.2.2. Clasificación

Los pronósticos se clasifican según su horizonte de tiempo, Montemayor (2013) los describe como sigue:

- De corto plazo (máximo 3 meses): son más precisos que los de mediano y largo plazo, se utilizan en las empresas para tomar decisiones en el área de producción como compras, mano de obra y niveles de producción.
- De mediano plazo (de 3 meses a 3 años): se utilizan en la planificación para la elaboración de presupuestos estimando las ventas y flujos de efectivo.
- De largo plazo (más de 3 años): se utilizan para predecir las ventas de nuevos productos, las ganancias de la introducción de nuevas tecnologías, o bien los beneficios de la expansión a nuevos mercados. (p. 9)

2.2.3. Métodos de pronósticos

Schroeder, *et al.*, (2011) señalan “Los tres tipos de métodos de pronóstico que existen son: cualitativos, series de tiempo y causales” (p. 240).

2.2.3.1. Métodos cualitativos

Los pronósticos cualitativos deben usarse cuando los datos históricos no son indicadores confiables de las condiciones futuras; si eso sucede, los datos históricos deben templanse mediante el criterio antes de que pueda desarrollarse un pronóstico. Asimismo, los pronósticos cualitativos deben emplearse para introducciones de nuevos productos para los cuales no se dispone de una base de datos histórica; en este caso, pueden aplicarse métodos cualitativos para desarrollar un pronóstico por analogía o por el uso selectivo de datos de investigación del mercado (Schroeder, *et al.*, 2011, p. 241).

- Método Delphi

Este método se basa en reunir a un grupo de personas expertas en donde los participantes no tienen contacto, ya que realizan los pronósticos anónimamente, lo realizan en una serie de etapas iterativas, el objetivo es retroalimentar a cada representante y lograr llegar a un consenso. En la primera etapa el moderador recibe los pronósticos de cada experto con sus respectivos argumentos, seguidamente el moderador realiza estimaciones estadísticas calculan el primer cuartil, la mediana y el tercer cuartil, los resultados los

comparte con los expertos. Como segunda etapa los expertos realizan una valoración de sus pronósticos y los vuelven a enviar al moderador para el análisis estadístico, el cual sirve de base para la tercera etapa. Las etapas siguientes son similares, esta iteración controlada y retroalimentada estadísticamente, busca reducir la variabilidad en los pronósticos para llegar a un consenso. La desventaja de este método es que algunas veces no logran llegar a un consenso (Montemayor, 2013).

2.2.3.2. Métodos cuantitativos

Hay dos tipos de métodos cuantitativos de pronóstico: el análisis de series de tiempo y los pronósticos causales. En general, los métodos cuantitativos manejan un modelo matemático fundamental para llegar a un pronóstico. El supuesto básico de todos los métodos cuantitativos de pronóstico es que los datos históricos y los patrones de los datos son instrumentos de predicción confiables del futuro. (Schroeder, *et al*, 2011, p. 240)

2.3. Series de tiempo

Las series de tiempo forman parte de los métodos cuantitativos. Hanke y Wichern (2010) afirman “Una serie de tiempo consiste en datos que se recopilan, registran u observan durante incrementos sucesivos de tiempo” (p. 62).

Nájera (2020) indica:

Una serie de tiempo como tal puede ser descrita como una colección de datos reunidos sobre la misma variable a lo largo de un periodo de tiempo establecido. Esto significa que la información deberá de recopilarse en intervalos regulares, es decir, ya sea de manera diaria, semanal, mensual, trimestral, cuatrimestral, o de manera anual, sin cambiar la periodicidad en que se recopilan nuevos datos. (Nájera, 2020, p. 7)

Sánchez (2012) afirma “Una Serie Cronológica es una secuencia de valores de una variable, observados y ordenados en el tiempo” (p. 81).

La notación que se utiliza para una serie temporal suele ser la siguiente:

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-k}) \text{ (Ec. 01)}$$

Lo que significa que la variable Y_t está en función del tiempo, en períodos rezagados. Las variables pueden ser datos históricos que cambian a través de un determinado período de tiempo.

2.3.1. Patrones o componentes

Las series de tiempo se dividen generalmente en 4 patrones o componentes.

Nájera (2020) indica:

Una práctica muy común en el manejo de pronósticos es suponer que los datos de una serie de tiempo están integrados por componentes individuales que pueden ser “eliminados” o “calculados” para facilitar el análisis de las series. Estos componentes normalmente son: tendencia, estacionalidad, cíclico (en algunos casos) y componente aleatorio. (p. 9)

2.3.1.1. Componente de tendencia

Nájera (2020) afirma “Se puede comprender la tendencia de una serie de tiempo como el comportamiento a largo plazo de una serie. Es vista como el resultado de factores que intervienen de manera estructural en la serie” (p. 12).

2.3.1.2. Componente estacional

“El componente estacional de una serie de tiempo representa, en su esencia más básica, la variabilidad presente en los datos de la serie ocasionada por influencia de las estaciones o periodos de tiempo en específico” (Nájera, 2020, p. 13).

2.3.1.3. Componente cíclico


Lind, *et al.* (2015) detallan “El componente cíclico como el aumento y reducción de una serie de tiempo durante periodos mayores de un año” (p. 569).

2.3.1.4. Componente aleatorio o irregular

“El componente aleatorio o irregular. Este es causado principalmente por factores a corto plazo, los cuales son a su vez imprevisibles y no recurrente. El cálculo de este componente ayuda a explicar la variabilidad aleatoria de la serie” (Nájera, 2020, p. 15).

Figura 1.

Descomposición de la serie temporal



Nota. Se presenta la descomposición de la serie temporal. Obtenido de Schroeder, Meyer y Rungtusanatham. (2011). *Administración de operaciones: Conceptos y casos contemporáneos*. (p. 243). McGraw-Hill/Interamericana editores, S.A. de C.V.

2.3.2. Clasificación

Las series temporales se clasifican en series estacionarias y series no estacionarias.

2.3.2.1. Serie de tiempo estacionaria

“Una serie de tiempo estacionaria es aquella cuyas propiedades estadísticas básicas, como la media y la varianza, permanecen constantes a través del tiempo” (Hanke y Wichern, 2010, p. 87).

2.3.2.2. Serie de tiempo no estacionaria

“Una serie de tiempo es no estacionaria si la serie parece crecer o declinar en el tiempo y las autocorrelaciones de la muestra no se desvanecen rápidamente” (Hanke y Wichern, 2010, p. 408).

Se puede realizar la prueba de raíz unitaria, prueba de Dickey-Fuller Aumentada para validar las siguientes pruebas de hipótesis:

Ho: La serie temporal no es estacionaria

Ha: La serie temporal es estacionaria

2.3.3. Supuestos estadísticos

Antes de evaluar una serie temporal de datos con alguna técnica de pronósticos, se deben analizar los siguientes supuestos estadísticos para poder seleccionar el método con el que se debe trabajar.

- Normalidad

Es la distribución de probabilidad determinada o distribución normal, su gráfica es la famosa campana de Gauss. Se caracteriza por la distribución de los datos alrededor de una media, la cual coincide con la mediana, además de otras características propias.

Se puede realizar la prueba de *Epps* para validar las siguientes pruebas de hipótesis:

Ho: La serie temporal se ajusta a una distribución normal.

Ha: La serie temporal no se ajusta a una distribución normal.

- Homocedasticidad

Indica si la variabilidad de la varianza es constante a lo largo del tiempo.

- Heterocedasticidad

Indica si la variabilidad de la varianza aumenta o disminuye a lo largo del tiempo.

Se pueden realizar las pruebas de *Lagrange Multiplier* o la de *Estándar Normal Homogeneity (SNHT)*, para validar las siguientes pruebas de hipótesis:

Ho: la serie temporal es heterocedástica.

Ha: la serie temporal es homocedástica.

- Independencia

indica que la serie temporal no posee autocorrelación.

Hanke y Wichern (2010) indican: “Autocorrelación es la correlación que existe entre una variable retrasada uno o más periodos consigo misma” (p. 64).

Se pueden realizar las pruebas de *Box-Pierce* o de *Ljun-Box* para validar las siguientes pruebas de hipótesis:

Ho: la serie temporal se distribuye de forma independiente.

Ha: la serie temporal no se distribuye de forma independiente.

2.3.4. Procesos estocásticos

“Un proceso estocástico es aquel que involucra variables que cambian aleatoriamente con el tiempo (al menos parcialmente)” (Casparri, M., García, V., y Masci, M., 2016, p.159). Un proceso estocástico es sinónimo de aleatoriedad, por lo que se puede decir que es un sistema que permite darle seguimiento a un fenómeno aleatorio a través del tiempo. Las series temporales son un caso particular de este tipo de procesos.

2.3.4.1. El proceso de ruido blanco

Monsalve, A. y Harmath, P. (2015) afirman:

Un proceso $\{\varepsilon_t\}$ se denomina ruido blanco (white noise) de media 0 y varianza σ^2 si satisface

$$E(\varepsilon_t) = 0, Var(\varepsilon_t) = \sigma^2 < \infty, \text{ (Ec. 02)}$$

$$Cov(\varepsilon_t, \varepsilon_{t-k}) = 0, \text{ para todo } k \neq 0 \text{ (Ec. 03)}$$

En particular una sucesión de variables aleatorias independientes e idénticamente distribuidas, con media 0 y varianza σ_ε^2 representa un caso especial de un proceso de ruido blanco.

2.3.4.2. Caminata aleatoria o “Random Walk”

“Random Walk inicialmente se refiere a una serie temporal que no capta tendencia ni estacionalidad, dicho de otra forma, únicamente se encuentra la

serie temporal con el error (ϵ_t). Si Y_t sigue una caminata aleatoria, entonces no es estacionaria” (Massó y Pons, 2018, párr. 4).

2.3.5. Métodos para pronosticar

A continuación, se detallan algunos de los métodos que se utilizan para pronosticar series temporales, los cuales contemplan los componentes estacionales, de tendencia y ruido blanco.

2.3.5.1. Descomposición

La técnica por descomposición, como su nombre lo indica, descompone la serie temporal en cada uno de sus componentes. Hanke y Wichern (2010) afirman: “Un modelo que trata los valores de la serie de tiempo como una suma de los componentes se llama modelo aditivo de los componentes” (p. 167).

“Un modelo que trata los valores de las series de tiempo como el producto de los componentes se llama modelo multiplicativo de los componentes” (Hanke y Wichern, 2010, p. 167).

A continuación, se detallan las ecuaciones de los modelos de componentes aditivo y multiplicativo:

$$Y_t = T_t + S_t + I_t \quad (\text{Ec. 04})$$

$$Y_t = T_t \times S_t \times I_t \quad (\text{Ec. 05})$$

2.3.5.2. Promedios simples

Hanke y Wichern (2010) afirman: “Los datos históricos pueden suavizarse de muchas maneras. El objetivo es usar los datos pasados para desarrollar un modelo de pronóstico para periodos futuros” (p. 111).

$$\hat{Y}_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i \quad (\text{Ec. 06})$$

“El método de *promedios simples* es una técnica adecuada cuando los factores que producen la serie que se va a pronosticar se han estabilizado y el ambiente en el cual se encuentra la serie generalmente permanece sin cambios” (Hanke y Wichern, 2010, p. 111).

2.3.5.3. Promedios móviles

Esta técnica se basa en los valores más recientes, cada vez que especifica un valor constante, calcula la media de los nuevos valores. La siguiente ecuación genera el pronóstico de un promedio móvil simple:

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k} \quad (\text{Ec. 07})$$

“Un *promedio móvil* de orden k es el valor de la media de k observaciones consecutivas. El valor del promedio móvil más reciente indicará el pronóstico del siguiente periodo” (Hanke y Wichern, 2010, p. 114).

Los promedios móviles dobles, sirven para pronosticar las series de datos que tienen tendencia lineal. “Este método hace lo que indica su nombre: se calcula un conjunto de promedios móviles y luego se calcula un segundo conjunto

como un promedio móvil del primer conjunto” (Hanke y Wichern, 2010, p. 116).
La siguiente ecuación calcula el segundo promedio móvil:

$$M'_t = \frac{M_t + M_{t-1} + \dots + M_{t-k+1}}{k} \quad (\text{Ec. 08})$$

La siguiente ecuación sirve para realizar un pronóstico que suma el promedio móvil simple más la diferencia del segundo promedio y el primer promedio móvil:

$$a_t = M_t + (M_t - M'_t) = 2M_t - M'_t \quad (\text{Ec. 09})$$

La siguiente ecuación es parecida al cambio de la medida a lo largo de la serie de tiempo, por lo que es un factor que se ajusta adicionalmente:

$$b_t = \frac{2}{k-1}(M_t - M'_t) \quad (\text{Ec. 10})$$


Y la siguiente ecuación realiza el pronóstico de p períodos en el futuro:

$$\hat{Y}_{t+p} = a_t + b_t p \quad (\text{Ec. 11})$$

Para ejemplificar las técnicas o métodos de promedio móvil simple y promedio móvil doble, se presenta la siguiente figura:

Figura 2.

Promedios móviles simple y doble



Nota. Ejemplo de las técnicas o métodos de los promedios. Obtenido de Hanke y Wichern (2010). *Pronósticos en los negocios*. (p. 117). Prentice Hall.

2.3.5.4. Suavizado o alisado exponencial

“La suavización exponencial es un procedimiento para revisar de forma continua un pronóstico a la luz de la experiencia más reciente” (Hanke y Wichern, 2010, p. 120).

2.3.5.4.1. Suavizado o alisado exponencial simple

Método de suavizado exponencial simple, es un caso especial del promedio móvil ponderado, fue creado por Robert G. Brown durante la segunda guerra mundial, se le conoce como el padre del suavizado exponencial. Su principio se basa en que las ventas más recientes se

ponderan con una constante de suavizado para el cálculo del pronóstico, mientras que los pesos para los otros valores varían a una tasa exponencial a medida que las observaciones son más antiguas. (Da Silva, 2018, p. 28)

La ecuación que utiliza este método de pronósticos en función de una constante de suavizado alfa (α) es la siguiente:

$$F_t = \alpha Y_t + (1 - \alpha) F_{t-1} \quad (\text{Ec. 12})$$

Este método se debe de utilizar cuando se quiere suavizar la serie temporal de elementos aleatorios, se recomienda cuando los datos no tienen ni estacionalidad, ni tendencia.

2.3.5.4.2. Suavizado o alisado exponencial doble

El método de suavizado exponencial doble, es una variación del suavizado exponencial simple que introduce el cálculo de la tendencia. Fue creado por Holt, también se conoce con el nombre de método lineal de Holt. Su principio se basa en agregar a la modelación de las aleatoriedades a través de la ponderación exponencial generada por el suavizado exponencial, la modelación del componente de la tendencia. (Da Silva, 2018, p. 30)

La ecuación que utiliza este método de pronósticos en función de dos constantes: alfa (α) que es la constante de suavizado y beta (β) que es la constante de suavizado de tendencia:

Suavizado:

$$S_t = \alpha Y_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (\text{Ec. 13})$$

Tendencia (pendiente):

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (\text{Ec. 14})$$

Pronóstico:

$$F_t(m) = S_t + mb_t \quad (\text{Ec. 15})$$

Este método se debe de utilizar cuando la serie de tiempo presenta tendencia, pero no estacionalidad y si se desea suavizar la serie de tiempo de elementos aleatorios.

2.3.5.4.3. Suavizado o alisado exponencial triple

El método de suavizado exponencial triple es una variación del suavizado exponencial doble de Holt que introduce como variante la estacionalidad. Se conoce como el método de *Holt-Winters*, y fue desarrollado por Winters en 1960. Este método se basa en tres ecuaciones de suavizado, una para el suavizado de ruidos, otra para la tendencia y otra para la estacionalidad. Existen dos variantes del método de *Holt-Winters*, en función de cómo es

modelada la estacionalidad de forma aditiva o multiplicativa (Da Silva, 2018, p. 31).

La fórmula que utiliza este método de pronósticos en función de cuatro ecuaciones con tres constantes: Alfa (α) que es la constante de suavizado, Beta (β) que es la constante de suavizado de tendencia y lambda (γ) que es la constante de suavizado de estacionalidad, siempre y cuando la estacionalidad sea aditiva es:

Suavizado:

$$S_t = \alpha(Y_t - e_{t-i}) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (\text{Ec. 16})$$

Tendencia (pendiente):

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (\text{Ec. 17})$$

Estacionalidad:

$$e_t = \gamma(Y_t - S_t) + (1 - \gamma)e_{t-i} \quad (\text{Ec. 18})$$

Pronóstico:

$$F_{t+1}(m) = S_t + mb_t + e_{t-i+m} \quad (\text{Ec. 19})$$

La ecuación que se utiliza cuando la estacionalidad es multiplicativa debe ser:

Suavizado:

$$S_t = \alpha \frac{Y_t}{e_{t-i}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (\text{Ec. 20})$$

Tendencia (pendiente):

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (\text{Ec. 21})$$

Estacionalidad:

$$e_t = Y \frac{Y_t}{S_t} + (1 - Y)e_{t-i} \quad (\text{Ec. 22})$$

Pronóstico:

$$F_{t+1}(m) = (S_t + mb_t)e_{t-i+m} \quad (\text{Ec. 23})$$

Este método se debe de utilizar cuando la serie de tiempo presenta tendencia, estacionalidad y si se desea suavizar o alisar la serie de tiempo de elementos aleatorios.

2.3.5.5. Box-Jenkins (ARIMA)

Los modelos ARIMA autorregresivos integrados de promedio móvil, son modelos lineales que pueden pronosticar datos de series temporales estacionarias como series temporales no estacionarias. Hanke y Wichern (2010) afirman: “La *metodología Box-Jenkins* para generar pronósticos es diferente de


la mayoría de los métodos porque no *supone* ningún patrón particular en los datos históricos de las series que se van a pronosticar” (p. 399).

Para corroborar que el modelo esté bien ajustado, se verifica que los residuos sean los más pequeños posibles, si el modelo no cumple con todos los supuestos estadísticos, automáticamente se repite el proceso, lo que genera otro modelo que mejora el original. Este procedimiento es iterativo y se repite hasta encontrar el mejor modelo.

La siguiente figura representa el proceso de construcción de un modelo de *Box-Jenkins*:

Figura 3.

Proceso de construcción de un modelo de Box-Jenkins



Nota. Se plantea el proceso de construcción. Obtenido de Hanke y Wichern (2010). *Pronósticos en los negocios*. (p. 400). Prentice Hall.

“La *metodología Box-Jenkins* se refiere a un conjunto de procedimientos para identificar, ajustar y verificar modelos ARIMA con los datos de la serie de tiempo. Los pronósticos se derivan directamente de la forma de un modelo ajustado” (Hanke y Wichern, 2010, p. 400).

En la figura 4 se observan los coeficientes de autocorrelación y autocorrelación parcial de los modelos AR(1) y AR(2). En la figura 5 se observan

los coeficientes de autocorrelación y autocorrelación parcial de los modelos MA(1) y MA(2) y en la figura 6 se observan los coeficientes de autocorrelación y autocorrelación parcial de un modelo mixto ARMA(1,1).

Las funciones de autocorrelación que se pueden interpretar en series temporales son:


- Función de autocorrelación (FAC) o (ACF) por sus siglas en inglés.
- Función de autocorrelación parcial (FACP) o (PACF) por sus siglas en inglés.

La función de autocorrelación simple mide la correlación entre dos variables separadas por k periodos, o, en otras palabras, el grado de asociación lineal que existe entre dos variables del mismo proceso aleatorio.

La función de autocorrelación parcial, por otra parte, mide la correlación entre dos variables separadas por k periodos cuando no se considera la presencia de la dependencia creada por los retardos intermedios que hay entre ambas. (Nájera, 2020, p. 21)

Figura 4.


Coefficientes de autocorrelación y autocorrelación parcial modelos AR (1)



Nota. Coeficientes de autocorrelación y autocorrelación parcial Hanke y Wichern (2010). Pronósticos en los negocios. (p. 401). Prentice Hall.

Figura 5.


Coeficientes de autocorrelación y autocorrelación modelos MA (1) y MA (2)



Nota. Presentación de los coeficientes modelos MA (1) y (2). Obtenido de Hanke y Wichern (2010). *Pronósticos en los negocios*. (p. 402). Prentice Hall.

Figura 6.

Coefficientes de autocorrelación y autocorrelación modelo mixto ARMA (1, 1)



Nota. Modelo mixto ARMA 1,1. Obtenido de Hanke y Wichern (2010). *Pronósticos en los negocios.* p. 403. Prentice Hall.

“Los modelos autorregresivos son modelos adecuados para series de tiempo estacionarias, y el coeficiente ϕ_0 está relacionado con el nivel constante de la serie. Si los datos varían alrededor de cero, no se requiere el coeficiente ϕ_0 ” (Hanke y Wichern, 2010, p. 404)

A continuación, se detalla la ecuación de un modelo autorregresivo:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (\text{Ec. 24})$$

A continuación, se detalla la ecuación de un modelo de promedio móvil de q -ésimo orden:

$$Y_t = \mu + \varepsilon_t - \omega_1 \varepsilon_{t-1} - \omega_2 \varepsilon_{t-2} - \dots - \omega_q \varepsilon_{t-q} \quad (\text{Ec. 25})$$

Hanke y Wichern (2010) indican “Un modelo con términos autorregresivos se puede combinar con un modelo que tenga términos de promedio móvil para obtener un modelo mixto de promedio móvil autorregresivo” (p. 407).

“Para representar estos modelos, es conveniente utilizar la notación ARMA (p, q) , donde p es el orden de la parte autorregresiva y q es el orden de la parte del promedio móvil. Un modelo ARMA (p, q) tiene la forma general” (Hanke y Wichern, 2010, p. 407).

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \omega_1 \varepsilon_{t-1} - \omega_2 \varepsilon_{t-2} - \dots - \omega_q \varepsilon_{t-q} \quad (\text{Ec. 26})$$

Tabla 3.

Resumen de FAC y FACP

	<i>Autocorrelaciones</i>	<i>Autocorrelaciones parciales</i>
$MA(q)$	Terminan después del orden q del proceso	Se desvanecen
$AR(p)$	Se desvanecen	Terminan después del orden p del proceso
$ARMA(p,q)$	Se desvanecen	Se desvanecen

Nota. Resumen de los componentes del modelo ARMA: Obtenido de Hanke y Wichern (2010). *Pronósticos en los negocios*. (p. 407). Prentice Hall.

Hanke y Wichern (2010) señalan:

Los modelos de las series no estacionarias se llaman modelos de promedio móvil *integrados* autorregresivos y se denotan por ARIMA (p, d, q) p indica el orden de la parte autorregresiva, d indica el número de diferenciaciones, y q el orden de la parte de promedio móvil. Si la serie original es estacionaria, entonces $d = 0$, y los modelos se denominarían ARMA. (Hanke y Wichern, 2010, p. 408)

2.3.6. Medidas de error de pronóstico y criterios de información

Para comprobar la precisión de los modelos de pronósticos, se debe medir el error del pronóstico en cada método y los criterios de información, esto con el fin de seleccionar el método que genere tanto el menor error como la menor medida de los criterios de información, ya que será el modelo que se ajusta mejor a los datos.

A continuación, se muestra la notación básica para pronósticos:

Y_t valor de una serie temporal en el periodo t.

$\hat{Y}_t$ valor pronosticado de Y_t .

$e_t = Y_t - \hat{Y}_t$; residuo.

“Un residuo es la diferencia entre un valor real observado y su valor de pronóstico” (Hanke y Wichem, 2010, p. 82). La ecuación que calcula el error de cada periodo pronosticado es:

$$e_t = Y_t - \hat{Y}_t \quad (\text{Ec. 27})$$

2.3.6.1. Desviación media absoluta (MAD)

“La desviación media absoluta (MAD), mide la exactitud del pronóstico promediando las magnitudes de los errores del pronóstico (los valores absolutos de los errores)” (Hanke y Wichem, 2010, p. 82).

La ecuación que describe a la desviación media absoluta es la siguiente:

$$MAD = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (\text{Ec. 28})$$

2.3.6.2. Error cuadrático medio (MSE)

El error cuadrático medio (MSE), este enfoque sanciona errores grandes en la elaboración de pronósticos, ya que los errores están elevados al cuadrado, lo cual es importante porque una técnica que produce errores

moderados es preferible a una que usualmente tenga pequeños errores.

(Hanke y Wichem, 2010, p. 82)

La ecuación que describe al error cuadrático medio es la siguiente:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (\text{Ec. 29})$$

La raíz cuadrada del *MSE* también sanciona los grandes errores.

La ecuación es la siguiente:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (\text{Ec. 30})$$

2.3.6.3. Error porcentual absoluto medio (MAPE)

“El error porcentual absoluto medio (MAPE) se calcula obteniendo el error absoluto de cada periodo, divide este entre el valor real observado y promedia estos errores porcentuales absolutos. El resultado final se multiplica después por 100 y se expresa como porcentaje” (Hanke y Wichem, 2010, p. 83).

La ecuación que describe al error porcentual absoluto medio es la siguiente:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{|Y_t|} \quad (\text{Ec. 31})$$

El MAPE no se puede calcular si alguna de las Y_t es cero.

2.3.6.4. Error porcentual medio arcotangente (MAAPE)

El error porcentual medio arcotangente (MAAPE) es una medida de actualización del *MAPE*.

La ecuación que describe al error porcentual medio arcotangente es la siguiente:

$$MAAPE = \arctan \arctan \frac{|y_t - \hat{y}_t|}{|y_t|} \quad (\text{Ec. 32})$$

Los siguientes criterios sirven de ayuda para indicar la estimación de la información que se pierde al emplear alguno de los métodos de pronósticos:

2.3.6.5. Criterio de información de Akaike (AIC)

Es una medida de bondad de ajuste. “El criterio de información de Akaike (1974), o *AIC*, selecciona el mejor modelo de un grupo de modelos candidatos que minimiza” (Hanke y Wichem, 2010, p. 431). Su ecuación se expresa como:

$$AIC = 2k - 2\ln(L) \quad (\text{Ec. 33})$$

2.3.6.6. Criterio de información Akaike corregido (AICc)

Criterio de información de Akaike corregido (AICc), se utiliza cuando el tamaño de la muestra es finito:

$$AIC_c = AIC + \frac{2k^2 + 2k}{n - k - 1} \quad (\text{Ec. 34})$$

2.3.6.7. Criterio de información Bayesiano (BIC)

Criterio de información Bayesiano o BIC, se utiliza para encontrar el número de periodos rezagados que minimizan el modelo, se centra en la suma de los cuadrados de residuos. Es una medida de bondad de ajuste. Su ecuación se expresa como:

$$BIC(p) = \ln \left[\frac{SCR(p)}{N} \right] + (p + 1) \times \frac{\ln(N)}{N} \quad (\text{Ec. 35})$$

2.4. Empresa

Es integrada por personas y materiales, su objetivo es obtener utilidades a través del intercambio de bienes o servicios, por lo cual utiliza los factores productivos como trabajo, capital y tierra.

2.4.1. Definición

“Una empresa es una organización o institución dedicada a actividades o persecución de fines económicos o comerciales para satisfacer las necesidades de bienes y servicios de la sociedad, a la par de asegurar la continuidad de la estructura” (Mero, 2018, p. 86).

2.4.2. Clasificación

Las empresas se clasifican según su actividad, su forma jurídica, su tamaño y según su ámbito como sigue:

Según su actividad: “sector primario, sector secundario, sector terciario, sector cuaternario (agricultura, ganadería, industria y servicios” (Mero, 2018, p. 86).

Según su forma jurídica: como sociedad anónima, cooperativas, sociedad individual y sociedad de responsabilidad limitada.

Según su tamaño: empresas grandes, empresas pequeñas y medianas (PYMES o MYPES. Según el número de trabajadores en: Mediana, cuando constan de 50 a 250 trabajadores; pequeña, entre 10 a 50 trabajadores y Microempresa, de 1 a 10 trabajadores; son empresa que cuenta con ciertos límites ocupacionales y financieros prefijados por los Estados o regiones, estas pymes son agentes con lógicas, culturas, intereses y un espíritu emprendedor específicos, y las grandes empresas que cuentan con más de 250 trabajadores. (Mero, 2018, p. 86)

Según su ámbito: empresas locales, empresas nacionales y empresas transnacionales o multinacionales.

2.4.2.1. Empresa comercializadora

“Es aquella que, como su mismo nombre lo dice, se encarga de comercializar un producto finalizado. Podríamos decir entonces, que la razón de ser de una empresa comercializadora es mercadear un producto y servicio ya existente o manufacturado” (Yirda, 2021, párr. 1).

2.4.2.1.1. MYPYME

La Micro, Pequeña y Mediana Empresa (MIPYME) en América Latina juega un papel muy importante en la cohesión social, ya que contribuye significativamente a la generación de empleo, de ingresos, erradicación de la pobreza y dinamiza la actividad productiva de las economías locales. Adicionalmente, representan una cuota importante en el tejido empresarial de los países; así en el istmo centroamericano se estima que la MIPYME representa más del 90 % de la estructura empresarial de la región; si bien es cierto que los estudios difieren en la estimación de la contribución al Producto Interno Bruto, se estima que en promedio contribuyen con el 20 % del PIB y que, en algunos casos, esta contribución llega a alcanzar el 50 %. (Álvarez y Durán, 2009, p. 5)

2.4.2.1.2. Canales de distribución

Son el medio por el cual el consumidor final recibe el producto. Los canales de distribución se dividen en directos e indirectos. La empresa comercializadora puede realizar la entrega del producto al cliente o consumidor final por medio de un distribuidor, un minorista o un mayorista.

2.4.3. Planificación de la demanda

Es el conjunto de acciones y técnicas de cálculo necesarias para aprovisionar producto (*stock*) a uno o varios centros de consolidación o

almacenaje y cuyo objetivo principal es mantener unos niveles de *stock* adecuados para atender la demanda media solicitada por el conjunto de clientes en un periodo de tiempo. (Parker, 2020, párr. 3)

3. PRESENTACIÓN DE RESULTADOS

De acuerdo con los objetivos propuestos se presentan los siguientes resultados:

Objetivo 1: realizar un diagnóstico del comportamiento de la demanda en función del tiempo de las ventas históricas de los años 2018, 2019 y 2020.

3.1. Diagnóstico del comportamiento de la serie temporal de las ventas históricas

En la siguiente tabla se observa el resumen estadístico de la serie temporal de las ventas históricas de los años 2018, 2019 y 2020, en donde se muestra un promedio de 681 unidades mensuales en presentación jarra, con una mediana igual de 681 unidades, una desviación estándar de 282 unidades de un total de 36 datos observados (ventas históricas).

Tabla 4.

Resumen estadístico descriptivo

Resumen estadístico	
Media	681
Mediana	681
Desviación estándar	282
n	36

Nota. Resumen estadístico de la serie temporal. Elaboración propia, realizado con Microsoft Excel 2022.

Tabla 5.

Base de datos de las ventas históricas-Aromatizante para vehículos

Mes	Año 2018	Año 2019	Año 2020	Promedio	Mediana
Enero	474	540	625	546	540
Febrero	650	695	764	703	695
Marzo	345	435	529	436	435
Abril	435	510	105	350	435
Mayo	580	667	165	471	580
Junio	760	820	278	619	760
Julio	564	750	225	513	564
Agosto	645	715	548	636	645
Septiembre	749	927	730	802	749
Octubre	820	1,128	978	975	978
Noviembre	795	956	1,146	966	956
Diciembre	1,030	1,324	1,095	1,150	1,095


Nota. se detallan las ventas históricas de enero de 2018 a diciembre de 2020 con sus respectivos promedios y medianas por mes. Elaboración propia, realizado con Microsoft Excel.

- Diagrama de dispersión de los datos

Según la siguiente figura se detalla la demanda de la serie temporal de ventas históricas del producto aromatizante para vehículos en presentación jarra con fragancias surtidas, en donde se puede observar un alza en el año 2019 en comparación con el año 2018, sin embargo, claramente se observa un descenso en la demanda en los meses de marzo a agosto del año 2020.

Figura 7.

Diagrama de dispersión del producto aromatizante para vehículos




Nota. Determinación de la serie temporal de ventas. Elaboración propia, realizado con Microsoft Excel.

Interpretación de la caja y bigotes (*Box-plot*)

En la siguiente figura se puede observar evidentemente el desfase que se observa en el diagrama de dispersión, en los meses abril, mayo, junio, julio y agosto, debido a que las medianas no se encuentran a la mitad del *box-plot* en su respectivo mes, también se observa que la serie temporal tiene componente estacional, el cual se detallará con mejor precisión más adelante. En el diagrama se visualiza el cuartil 1, cuartil 3 y los respectivos límites inferior y superior de los datos.

Figura 8.

Box-plot de las ventas históricas-Aromatizante para vehículos




Nota. Desfase en el diagrama de dispersión. Elaboración propia, realizado con R Studio 4.2.0.

- Análisis exploratorio de los datos

Se convirtió la base de datos de las ventas históricas del producto aromatizante para vehículos en una serie temporal, para poder realizar el diagnóstico de los datos en el lenguaje de programación R versión 4.2.0 con el entorno R Studio, la gráfica de la serie temporal se muestra en la figura, en donde se confirma lo que se muestra en otra figura y en el *Box-plot* de la figura 8, que la demanda tiene un alza en el año 2,019 en comparación con el año 2,018, pero en el año 2020 se observó una baja en los meses de abril a agosto, incrementando su demanda en el último trimestre del año en mención. Adicionalmente se observa visualmente una estacionalidad aditiva, la cual se comprobará más adelante.

Figura 9.

Serie temporal-ventas históricas 2018-2020



Fuente: elaboración propia, realizado con R Studio 4.2.0.


Detección de valores atípicos

Se analizó con la librería “*tsoutliers*” de R Studio si la serie temporal presentaba datos atípicos en las observaciones, en donde se encontraron en las posiciones siguientes: (10, 27, 28, 29, 30, 31 y 35), por lo que se sustituyeron las siguientes cantidades en las posiciones indicadas: (875, 443, 477, 602, 717, 638 y 899) respectivamente.

Luego de sustituir los valores indicados como valores atípicos, se convirtieron nuevamente los datos en serie temporal. Así como también se observa el diagrama de caja y bigotes con la sustitución de los valores atípicos.

Figura 10.


Serie temporal-Ventas históricas 2018-2020 con sustitución de datos atípicos



Nota. Diagrama de caja y bigotes con la sustitución de los valores atípicos. elaboración propia, realizado con R Studio 4.2.0.

Figura 11.

Box-plot de las ventas para vehículos con sustitución de datos atípicos



Nota. Ventas para vehículos con datos atípicos. Elaboración propia, realizado con R Studio 4.2.0.

- Comprobación de supuestos estadísticos

Este apartado es de gran importancia, ya que se comprobaron los resultados de los supuestos estadísticos para escoger los métodos de pronósticos adecuados para pronosticar.

- Prueba de estacionariedad

Se utilizó la prueba de *Dickey-Fuller Aumentado* para comprobar la estacionariedad de la serie temporal, en donde se observó un estadístico de -3.1207 con un valor de probabilidad de 0.1371, lo que significa que se acepta la hipótesis nula y por ende se confirma que la serie temporal de ventas históricas del producto aromatizante para vehículos no es estacionaria.

Ho: La serie temporal no es estacionaria.

Ha: La serie temporal es estacionaria.

Tabla 6.

Prueba de Dickey-Fuller Aumentado

Unit root test for stationarity:

Augmented Dickey-Fuller Test

data: y

Dickey-Fuller = -3.1207, Lag order = 3, p-value = 0.1371

alternative hypothesis: stationary

Nota. Prueba de Dickey-fuller aumentado para comprobar la estacionariedad. Elaboración propia, realizado con R Studio 4.2.0. y Microsoft Excel.

- Prueba de homocedasticidad

Se aplicaron las pruebas de *Lagrange Multiplier* y la de *Standard Normal Homogeneity* (SNHT) para comprobar la homocedasticidad en varianzas de la serie temporal, en donde se observó un estadístico de -10.061 con una probabilidad de contraste cercana a 1 en la prueba de *Lagrange Multiplier* y un estadístico de 5.8926 con un valor de probabilidad de 0.1753 en la prueba de (SNHT), lo que significa que se acepta la hipótesis nula en ambas pruebas y por ende confirman que la serie temporal de ventas históricas del producto aromatizante para vehículos es homocedástica.

Ho: La serie temporal es homocedástica.

Ha: La serie temporal es heterocedástica.

Tabla 7.

Pruebas de Lagrange Multiplier y (SNHT)

arch test for heteroscedasticity:
<i>Lagrange Multiplier test</i>
data: y
LM = -10.061, df = 1, p-value = 1
alternative hypothesis: y is heteroscedastic
conclusion: y is homoscedastic
<i>Standard Normal Homogeneity Test (SNHT)</i>
data: ventas.ts
T = 5.8926, n = 36, p-value = 0.1753
alternative hypothesis: true delta is not equal to 0
sample estimates:
probable change point at time k
5

Nota. Pruebas para para comprobar la homocedasticidad. Elaboración propia, realizado con R Studio 4.2.0.

- Prueba de normalidad

Se aplicó la prueba de *Epps*, para comprobar la normalidad de los datos en la serie temporal, en donde se observó un estadístico de 2.0885 y un valor de probabilidad de 0.352, según la Tabla 8, lo que significa que se acepta la hipótesis nula y por ende se confirma que la serie temporal de ventas históricas del producto aromatizante para vehículos sigue una distribución normal.

Ho: La serie temporal se ajusta a una distribución normal.

Ha: La serie temporal no se ajusta a una distribución normal.

Tabla 8.

Prueba de Epps

Goodness of fit test for Gaussian Distribution:

Epps test

data: y

epps = 2.0885, df = 2, p-value = 0.352

alternative hypothesis: y does not follow a Gaussian Process

conclusion: y follows a Gaussian Process

Nota. Se aplicó prueba de normalidad de Epps. Eelaboración propia, realizado con R Studio 4.2.0.

- Prueba de independencia

Se aplicaron las pruebas de *Box-Pierce* y la de *Ljung-Box* para comprobar la independencia en los residuos de la serie temporal, en donde se observó un estadístico de 6.5204 con un valor de probabilidad de 0.01066 en la prueba de *Box-Pierce* y un estadístico de 7.0793 con un valor de probabilidad de 0.007798 en la prueba de *Ljung-Box* según la Tabla 9, lo que significa que se rechaza la

hipótesis nula en ambas pruebas y por ende confirman que la serie temporal de ventas históricas del producto aromatizante para vehículos no se distribuye de forma independiente o la serie de residuos recibe autocorrelación.

Ho: La serie de residuos no exhibe autocorrelación

Ha: La serie de residuos recibe autocorrelación

Tabla 9.

Pruebas de Box-Pierce y Ljung-Box


<i>Box-Pierce test</i>
data: ventas.ts
X-squared = 6.5204, df = 1, p-value = 0.01066
<i>Box-Ljung test</i>
data: ventas.ts
X-squared = 7.0793, df = 1, p-value = 0.007798

Nota. Se aplicaron las pruebas de *Box-Pierce* y la de *Ljung-Box*. Elaboración propia, realizado con R Studio 4.2.0.

En la siguiente figura se observan los comportamientos de los residuos, en el primer apartado se detalla los datos observados de las ventas históricas con la sustitución de los datos atípicos, en el segundo apartado se confirma que los datos se ajustan a una distribución normal según se observa en el histograma y Q-Q *plot* y, por último, en el tercer apartado se detallan los gráficos (ACF) función de autocorrelación (PACF) y función de autocorrelación parcial de los residuos.

Figura 12.

Comportamiento de los residuos




Nota. Se evidencia el comportamiento de los residuos. Elaboración propia, realizado con R Studio 4.2.0.

- Descomposición de la serie temporal

En la siguiente figura se detallan los componentes de la serie temporal de las ventas históricas de 2018 al 2020. Se observan los componentes de tendencia, estacionalidad y aleatorio.

Figura 13.

Descomposición de la serie temporal de ventas históricas



Nota. Componentes de la serie temporal de las ventas históricas de 2018 al 2020. Elaboración propia, realizado con R Studio 4.2.0.

- Pruebas de estacionalidad y tendencia

En la siguiente figura se muestra gráficamente la estacionalidad de la serie de tiempo, así como los valores de probabilidad de 0.001 para el componente estacional, lo que significa que se rechaza la hipótesis nula y por ende se confirma que la serie temporal es estacional y el valor de probabilidad de 0.048 para el componente de tendencia, lo que significa que se rechaza la hipótesis nula y por ende se confirma que la serie temporal tiene tendencia.

Ho: La serie de tiempo no es estacional.


Ha: La serie de tiempo es estacional.

Ho: La serie de tiempo no tiene tendencia.

Ha: La serie de tiempo tiene tendencia.

Figura 14.

Pruebas de estacionalidad y tendencia



Nota. Se muestra la estacionalidad de la serie de tiempo. Elaboración propia, realizado con R Studio 4.2.0.


En la siguiente figura se muestra el valor de probabilidad de 0.2514 para comprobar el tipo de estacionalidad de la serie temporal, por lo que el resultado indica que se acepta la hipótesis nula y por ende se confirma que se tiene una estacionalidad aditiva.

Ho: La serie de tiempo no tiene estacionalidad multiplicativa.

Ha: La serie de tiempo tiene estacionalidad multiplicativa.

Figura 15.

Estacionalidad aditiva



Nota. Se muestra el valor de probabilidad de 0.2514 para comprobar el tipo de estacionalidad de la serie temporal. Elaboración propia, realizado con R Studio 4.2.0.

Diferenciación de la serie temporal


Para poder pronosticar la serie temporal de ventas históricas, se deben eliminar el componente de tendencia y el componente estacional. En este caso se realizó la transformación de la serie temporal de las ventas históricas por medio de la diferenciación, tanto en el componente de tendencia, como en el componente estacional.

Se utilizó la prueba “seas” de la función “*nsdiff*” en donde indica que únicamente se necesita una diferenciación para eliminar el componente estacional de la serie temporal y la de la función “*ndiff*” en donde indica también

que únicamente se necesita una diferenciación para eliminar el componente de tendencia o regular de la serie temporal.

Figura 16.

Serie temporal de ventas históricas diferenciada



Nota. Se observa la serie temporal diferenciada. Elaboración propia, realizado con R Studio 4.2.0.

Objetivo 2: Evaluar el histórico de ventas por medio del análisis de series temporales utilizando los métodos de pronósticos específicos según los patrones de la demanda.

3.2. Evaluación de métodos de pronósticos

Se evaluaron los siguientes métodos de pronósticos:

- Método de alisado exponencial triple o de *Holt-Winters*

En la siguiente tabla se detalla el pronóstico de ventas de los meses de enero a junio del año 2021, con sus respectivos límites superiores e inferiores con un intervalo del 95 % de confianza y en la figura posterior se detalla la gráfica del pronóstico que calcula el modelo, con un Alfa de 0.6451, Beta de 0.0001 y Gamma de 0.0002.

Tabla 10.


Pronóstico de ventas con método de Holt-Winters

Fecha	Pronóstico	Intervalo de confianza 95%	
		Límite Inferior	Límite Superior
ene-21	534	401	667
feb-21	678	519	836
mar-21	401	221	581
abr-21	467	268	666
may-21	591	374	808
jun-21	728	495	961

Nota. Pronóstico de ventas de los meses de enero a junio del año 2021. Elaboración propia, realizado con Microsoft Excel 2022 y con R Studio 4.2.0.

Figura 17.

Gráfica de pronóstico de ventas con método de alisado exponencial triple



Nota. Se presenta el pronóstico de ventas. elaboración propia, realizado con R Studio 4.2.0.

- Método de Auto-ARIMA

En la siguiente tabla se detalla el pronóstico de ventas de los meses de enero a junio del año 2021, con sus respectivos límites superiores e inferiores con un intervalo del 95% de confianza. El modelo que generó automáticamente el Auto-ARIMA fue $(1,1,0)(0,1,0)[12]$, lo que significa un AR de grado uno, con una diferenciación de grado uno en el componente de tendencia y una diferenciación de grado uno en el componente estacional y en la Figura 18 se detalla la gráfica del pronóstico que calcula el modelo.

Tabla 11.


Pronóstico de ventas con método Auto-ARIMA

Fecha	Pronóstico	Intervalo de confianza 95%	
		Límite Inferior	Límite Superior
ene-21	544	455	650
feb-21	652	529	802
mar-21	381	297	488
abr-21	409	309	540
may-21	516	380	702
jun-21	615	441	857

Nota. Pronóstico de ventas de los meses de enero a junio del año 2021. Elaboración propia, realizado con Microsoft Excel 2022 y con R Studio 4.2.0.

Figura 18.

Gráfica de pronóstico de ventas con método Auto-ARIMA



Nota. Ventas con método Auto-Arima. Elaboración propia, realizado con R Studio 4.2.0.

- Método de ARIMA (0,0,0), (1,1,0) [12]

En la siguiente tabla se detalla el pronóstico de ventas de los meses de enero a junio del año 2021, con sus respectivos límites superiores e inferiores con un intervalo del 95 % de confianza. El modelo que se generó es (0,0,0)(1,1,0)[12], lo que significa un AR de grado uno, con una diferenciación de grado uno en el componente estacional y en la figura posterior se detalla la gráfica del pronóstico que calcula el modelo.

Tabla 12.


Pronóstico de ventas con método ARIMA (0,0,0),(1,1,0)[12]

Fecha	Pronóstico	Intervalo de confianza 95%	
		Límite Inferior	Límite Superior
ene-21	557	391	722
feb-21	708	543	874
mar-21	437	272	602
abr-21	504	338	669
may-21	654	489	819
jun-21	800	635	965

Nota. Pronóstico de ventas de los meses de enero a junio del año 2021. Elaboración propia, realizado con Microsoft Excel 2022 y con R Studio 4.2.0.

Figura 19.

Gráfica de pronóstico de ventas con método ARIMA (0,0,0), (1,1,0)[12]



Nota. Pronóstico de ventas ARIMA. Elaboración propia, realizado con R Studio 4.2.0.

Objetivo 3: Comprobar la precisión de los modelos específicos que se evaluarán, utilizando los criterios de información y medidas de error de pronósticos.

3.3. Precisión de los modelos evaluados de pronóstico

Para comprobar la precisión de los modelos que se evaluaron en el inciso anterior, se calcularon los criterios de información de *Akaike* (AIC), *Akaike* Corregido (AICc), Bayesiano (BIC) y las medidas de error de pronósticos como el error porcentual absoluto medio (MAPE) y el error porcentual medio arcotangente (MAAPE) como se muestra en la siguiente tabla.

Tabla 13.*Comparación de criterios de información y medidas de error de pronóstico*

Modelo	Holt-Winters	Auto-ARIMA (1,1,0),(0,1,0)[12]	ARIMA (0,0,0),(1,1,0)[12]
AICc	49.4157	-41.3358	297.0168
BIC	472.3355	-39.6648	298.8015
MAPE	6.5302	5.1555	6.3802
MAAPE	6.5067	5.1373	6.3406

Nota. Comparación de criterios de información. Elaboración propia, realizado con Microsoft Excel 2022 y con R Studio 4.2.0.

Objetivo general: proponer un modelo de pronósticos para optimizar la planificación de demanda en una empresa comercializadora de aromatizante para vehículos en Guatemala.

3.4. Propuesta de modelo de pronóstico

En la siguiente tabla se resumen los estadísticos y valores de probabilidad de las pruebas de estacionariedad, homocedasticidad, normalidad de los datos e independencia de la serie temporal de ventas históricas del producto aromatizante para vehículos.

Tabla 14.*Resumen de comprobación de supuestos de la serie temporal*

Supuesto	Prueba	Estadístico	P-Valor	Significado
Estacionariedad	Dickey-Fuller Aumentada	-3.1207	0.1371	No es estacionaria en media
Homocedasticidad	Lagrange Multiplier	-10.061	1	Es homocedástica
Homocedasticidad	Standar Normal Homogeneity (SNHT)	5.8926	0.1753	Es homocedástica
Normalidad	Epps	2.0885	0.352	Se ajusta a una distribución normal
Independencia	Box-Pierce	6.5204	0.01066	La serie de residuos recibe autocorrelación
Independencia	Ljung-Box	7.0793	0.007798	La serie de residuos recibe autocorrelación

Nota. Resumen los estadísticos y valores de probabilidad. Elaboración propia, realizado con Microsoft Excel 2022 y con R Studio 4.2.0.

Tabla 15.

Resumen de pruebas de estacionalidad y tendencia de la serie temporal de las ventas históricas

Componente	Prueba	P-Valor	Significado
Tendencia	<i>tsutils</i>	0.0480	La serie de tiempo tiene tendencia
Estacionalidad	<i>tsutils</i>	0.0010	La serie de tiempo es estacional
Estacionalidad Multiplicativa	<i>mseastest</i>	0.2514	La serie de tiempo tiene estacionalidad aditiva

Fuente: Se resumen los valores de probabilidad de las pruebas de los componentes estacional y de tendencia de la serie de tiempo de ventas históricas. Elaboración propia, realizado con Microsoft Excel 2022 y con R Studio 4.2.0.

Según el análisis exploratorio que se realizó a la serie de datos de ventas históricas, con la comprobación de los supuestos estadísticos, la verificación de la precisión de los criterios de información y las medidas de error de pronósticos de los modelos evaluados, se propone utilizar el modelo Auto-ARIMA, que utiliza transformación logarítmica $(1,1,0)(0,1,0)[12]$, debido a que es el modelo que se ajusta mejor a los datos y es el que genera las menores cantidades de los criterios de información de *Akaike* corregido (AICc) de -41.3358 y Bayesiano (BIC) de -39.6648, así como también, un error porcentual medio arcotangente (MAAPE) de 5.1373 lo que genera un 5.1555 % de error porcentual medio en el modelo.

4. DISCUSIÓN DE RESULTADOS

Esta investigación surge de la importancia del manejo y control adecuado de los inventarios, especialmente en las MIPYMES de Guatemala, para que puedan crecer como empresa, tengan mayores oportunidades de expandirse tanto a nivel nacional como a nivel internacional. En el presente estudio se propone que la empresa utilice un modelo de ARIMA (1,1,0),(0,1,0)[12] como el modelo que se ajusta mejor a los datos para el producto aromatizante para vehículos.

4.1. Análisis interno

Al realizar el diagnóstico de la demanda del producto en estudio se observó en el diagrama de dispersión y en el de cajas y bigotes (*box-plot*) que se evidencian datos atípicos, especialmente de abril a julio de 2020, se concluye que fueron los meses en donde las ventas fueron afectadas por la pandemia de Covid-19, debido a este inconveniente se utilizó la función “*tsoutliers*” para detectar los meses en donde las ventas fueron atípicas por lo que el sistema propuso nuevas cantidades para realizar el análisis de series temporales para no afectar los pronósticos de ventas de enero a junio de 2021.

La siguiente tabla muestra las ventas atípicas de la serie temporal y la sugerencia de las ventas con las que se realizó el análisis para pronosticar de una forma más adecuada siguiendo los patrones de las ventas históricas de los demás meses.

Tabla 16.


Ventas históricas con sustitución de datos atípicos

Mes	Ventas atípicas	Ventas sugeridas
oct-18	820	875
mar-20	529	443
abr-20	105	477
may-20	165	602
jun-20	278	717
jul-20	225	638
nov-20	1146	899

Nota. Ventas atípicas de la serie temporal. Elaboración propia, realizado con Microsoft Excel y con R Studio 4.2.0.

Figura 20.

Diagrama de dispersión de las ventas históricas con sustitución de datos atípicos



Nota. Se grafican las ventas históricas con la sustitución de las ventas que sugirió R Studio para realizar el análisis de las series temporales. elaboración propia, realizado con Microsoft Excel 2022.

La serie temporal de las ventas históricas cumple con los siguientes supuestos estadísticos de los residuos: homocedasticidad de varianzas, normalidad de los datos e independencia, sin embargo, no cumple con el supuesto de estacionariedad por lo que se utiliza las funciones “*nsdiffs*” para diferenciar el componente estacional y “*ndiffs*” para diferenciar el componente regular o de tendencia, esto se realizó con el fin de transformar la serie temporal de ventas históricas en estacionaria.

Luego de realizar el diagnóstico general de la serie temporal, se observa que tiene componente de tendencia y de estacionalidad por tal motivo se evalúan los métodos de suavización exponencial triple o de *Holt-Winters* y ARIMA.

El alcance de esta investigación llega hasta la propuesta del modelo de pronóstico de la demanda del producto aromatizante para en presentación jarra, sin embargo, se puede continuar otra investigación para realizar análisis y comparación de costos de los modelos de pronósticos evaluados para elegir el modelo que genere más ganancia.

Adicionalmente la empresa puede tomar de referencia el análisis del diagnóstico y comprobación de supuestos estadísticos que se realizaron en la presente investigación, para replicarla en el análisis de los demás productos que distribuyen.

4.2. Análisis externo

En el artículo que trata sobre la aplicación de pronósticos en la toma de decisiones en las micro, pequeñas o medianas empresas, Pérez, *et al.*, (2018) realizaron comparaciones con los métodos de promedios móviles, suavización exponencial y regresión lineal, en los ejemplos de ventas históricas que

detallaron en el estudio, en el caso de la presente investigación se realizó comparación entre los métodos de suavización exponencial triple o de *Holt-Winters* con dos métodos de ARIMA.

En la tesis de Echegaray (2017) indica: “El proceso de identificación del tipo de modelo ARIMA más apropiado para una determinada serie de tiempo, tiene por finalidad estimar, el grado de diferenciación necesaria para producir estacionariedad y también, determinar el orden de los polinomios AR y MA” (p. 31). El autor explica detalladamente el proceso para analizar una serie temporal con la metodología de Box-Jenkins de los modelos ARIMA, desde el diagnóstico o análisis de la descomposición de la serie temporal, la identificación del tipo de modelo ARIMA, hasta la medición de error de pronóstico del modelo para elegir el modelo que se ajustaba mejor a los datos. En el presente estudio se realizó el mismo procedimiento cuando se evaluaron los modelos ARIMA y escogió el mejor modelo en el que tomó como referencia el modelo que generó menores cantidades tanto en los criterios de información *Akaike* y Bayesiano, como en las medidas de error de pronóstico como el de error porcentual medio.

En la tesis que trata sobre pronósticos de ventas aplicados a fabricante de juntas y sellos para motor de una empresa automotriz, Frausto (2009) realizó un análisis de Pareto para realizar los pronósticos a las autopartes que más utiliza la empresa, luego realizó un diagnóstico general de los productos que tomó de referencia en el estudio de investigación, seguidamente evalúa los métodos cualitativos, promedio simple, descomposición de la serie temporal, suavización exponencial, ARIMA, regresión lineal y redes neuronales, finalizó con la comprobación de la precisión de los modelos para cada producto. Frausto (2009) afirma: “Las técnicas de pronósticos operan con los datos generados en el pasado, de este modo es de suma importancia la recolección de información efectiva y la reducción de la misma” (p. 58). En el caso de la presente

investigación, únicamente se evaluaron los métodos de suavización exponencial de *Holt-Winters* y ARIMA, debido a que el diagnóstico de la serie de datos de las ventas históricas del producto aromatizante para vehículos así lo requirió. De igual forma se realizó la comprobación de la precisión de los modelos para elegir el modelo que más se adaptará a los datos de la serie temporal.

CONCLUSIONES

1. El diagnóstico del comportamiento de la demanda en función del tiempo de las ventas históricas de enero de 2018 a diciembre de 2020 presenta una serie de tiempo que se ajusta a una distribución normal, es homocedástica en varianzas, no es estacionaria, la serie de residuos posee autocorrelación y contiene componente estacional y de tendencia.
2. Se evaluaron los métodos de pronósticos de suavizamiento exponencial triple o de *Holt-Winters* con los parámetros alfa de 0.6451, beta de 0.0001 y gamma de 0.0002, Auto-ARIMA (1,1,0),(0,1,0)[12] y ARIMA (0,0,0)(1,1,0)[12], según el comportamiento de la demanda de las ventas históricas del producto aromatizante para vehículos.
3. Los modelos específicos de pronósticos que generan el menor criterio de información y la menor medida de error son los de suavizamiento exponencial triple o de *Holt-Winters*, Auto-ARIMA (1,1,0),(0,1,0)[12] y ARIMA (0,0,0)(1,1,0)[12], los criterios de información que se evaluaron fueron los de *Akaike* (AIC), de *Akaike* corregido (AICc), bayesiano (BIC) y las medidas de error de pronósticos como el error porcentual absoluto medio (MAPE) y el error porcentual medio arcotangente (MAAPE).
4. Se propone que la empresa utilice el modelo Auto-ARIMA con transformación logarítmica de (1,1,0),(0,1,0)[12], para optimizar la planificación de demanda del producto aromatizante para vehículos, debido a que este modelo generó menores criterios de información como el de *Akaike* corregido de -41.33 y menores medidas de error de

pronóstico, como el error porcentual medio de 5.14 %, por lo que es el modelo que se ajustó mejor a los datos.

RECOMENDACIONES

1. Es necesario realizar diagnósticos de la demanda por lo menos cada trimestre para analizar la demanda en función del tiempo de las ventas históricas de tres años como mínimo, lo cual servirá para el análisis y evaluación de la serie temporal de las ventas.
2. Se deben evaluar los métodos de pronósticos que se adaptan mejor al comportamiento de la demanda, para generar el modelo que se ajuste mejor a los datos por lo menos cada trimestre.
3. Utilizar los criterios de información y medidas de error de pronósticos para comparar y seleccionar el mejor modelo de pronósticos para comprobar la precisión de este cada vez que se evalúen los métodos de pronósticos.
4. La empresa debe planificar la demanda de sus productos por lo menos cada trimestre, realizando análisis de series temporales para pronosticar adecuadamente los inventarios de sus productos, especialmente los que importan desde Europa y se hace necesario que la empresa replique este análisis de pronósticos de ventas en las demandas de otros productos similares que distribuyen.

REFERENCIAS

- Álvarez, M. y Durán, J. (2009). *Manual de la Micro, Pequeña y Mediana Empresa: Una contribución a la mejora de los sistemas de información y el desarrollo de las políticas públicas*. Naciones Unidas.
- Bazán Ramírez, W. (2020). Fundamentos para pronosticar una serie de tiempo estacionaria con información de su propio pasado. *Industrial Data*, 23(1), 207–228. Recuperado de <https://doi.org/10.15381/idata.v23i1.16504>.
- Casparri, M., García, V., y Masci, M. (abril, 2016). Introducción a los procesos estocásticos en la valuación de proyectos de inversión riesgosos. *Revista de Investigación en Modelos Matemáticos aplicados a la Gestión y la Economía*, 1(1), 155-168.
- Da Silva, R. (2018). *Cómo hacer pronósticos con la herramienta de previsión de Excel 2016*. Edición Kindle.
- Echegaray, V. (2017). *Pronóstico de demanda utilizando la metodología de Box-Jenkins* [Tesis de maestría, Universidad Nacional Jorge Basadre Grohmann]. Repositorio institucional.
- Frausto, J. (2009). *Pronósticos de ventas para la administración estratégica de los recursos en una empresa del sector automotriz*. [Tesis de maestría, Instituto Tecnológico y de Estudios Superiores de Monterrey, México]. Repositorio institucional.

Gallegos, E. (2019). *Disminución de desabasto mediante un pronóstico de demanda y una política de inventarios*. [Tesis de maestría, Universidad Autónoma de Nuevo León, México]. Repositorio institucional.

Gujarati, D. y Porter, d. (2010). *Econometría*. McGraw-Hill.

Hanke, E. y Wichern, W. (2010). *Pronósticos en los negocios*. Prentice Hall.

Lind, D., Marchal, W. y Wathen, S. (2015). *Estadística aplicada a los negocios y la economía*. McGraw-Hill/Interamericana editores, S.A. de C.V.

Mero, J. (2018). Empresa, administración y proceso administrativo. *FIPCAEC*, 3(8), 84-102.

Molina Arias, M. (2017). ¿Qué significa realmente el valor de p? *Pediatría Atención Primaria*, 19(76), 377-381.

Monsalve, A. y Harmath, P. (2015). *Introducción al análisis de series de tiempo con aplicaciones a la econometría y finanzas*. Ediciones IVIC.

Montemayor, J. (2013). *Métodos de pronósticos para negocios*. Editorial Digital Tecnológico de Monterrey.

Nájera, J. (2020). *Pronósticos estratégicos de series de tiempo: Metodología práctica para economistas, administradores y científicos de datos*. Independently published.

Newbold, P., Carlson, W. y Thorne, B. (2008). *Estadística para Administración y Economía*. Pearson Educación.

- Ojeda, R. (2017). *Modelo de gestión para la planificación de las operaciones en las pymes del sector calzado y su impacto en el rendimiento de la inversión*. [Tesis de maestría, Universidad Técnica de Ambato, Ecuador]. Repositorio institucional.
- Pérez, A., Cruz, J., Villalobos, A. y Juárez, V. (2018). Importancia de los pronósticos en la toma de decisiones en las MIPYMES. *Revista GEON (Gestión, Organizaciones Y Negocios)*, 5(1), 97-114.
- Salazar, C. y Del Castillo, S. (2017). *Fundamentos básicos de estadística*. Sin editorial.
- Sánchez, A., (agosto, 2012) Aplicaciones prácticas de los métodos estadísticos para pronósticos en series de tiempo. *Revista Eafit*, 29(91), 81-95.
- Schroeder, G., Meyer, S. y Rungtusanatham, M. (2011). *Administración de operaciones: Conceptos y casos contemporáneos*. McGraw-Hill/Interamericana editores, S.A. de C.V.
- Walpole, E., Myers, H., Myers, L. y Ye K. (2012). *Probabilidad y estadística para ingeniería y ciencias*. Pearson Educación.

APÉNDICES

Apéndice 1.

Matriz de coherencia

Elementos	Problema estadístico	Objetivos	Metodología	Resultados	Conclusiones	Recomendaciones
General	Se desconoce el modelo de pronósticos para optimizar la planificación de demanda en una empresa comercializadora de aromatizantes para vehículos en la Ciudad de Guatemala.	Proponer un modelo de pronósticos para optimizar la planificación de demanda en una empresa comercializadora de aromatizantes para vehículos en Guatemala.	El enfoque es de tipo cuantitativo, debido a que se analizó el comportamiento de la demanda del producto aromatizante para vehículos.	Según el análisis exploratorio que se realizó en general a la serie de datos de ventas históricas, con la comprobación de los supuestos estadísticos y con la verificación de la precisión de los criterios de información y las medidas de error de pronósticos de los modelos evaluados, se propone utilizar el modelo Auto-ARIMA, que utiliza transformación logarítmica (1,1,0)(0,1,0)[12] debido a que es el modelo que se ajusta mejor a los datos y es el que genera las menores cantidades de los criterios de información Akaike corregido (AICc) de -41.3358 y Bayesiano (BIC) de -39.6648, así como también, un error porcentual medio arcotangente (MAAPE) de 5.1373 generando un 5.1555% de error porcentual medio en el modelo.	Se propone que la empresa utilice el modelo Auto-ARIMA con transformación logarítmica de (1,1,0),(0,1,0)[12], para optimizar la planificación de demanda del producto aromatizante para vehículos, debido a que este modelo generó menores criterios de información como el de Akaike corregido de -41.33 y menores medidas de error de pronóstico, como el error porcentual medio de 5.14%, por lo que es el modelo que se ajustó mejor a los datos.	La empresa debe planificar la demanda de sus productos por lo menos cada trimestre, realizando análisis de series temporales para pronosticar adecuadamente los inventarios de sus productos, especialmente los que importan desde Europa y se hace necesario que la empresa replique este análisis de pronósticos de ventas en las demandas de otros productos similares que distribuyen.
			El diseño es no experimental, debido a que se trabajó con base de datos de las ventas históricas de los años 2018, 2019 y 2020.			

Continuación del apéndice 1.

Elementos	Problema estadístico	Objetivos	Metodología	Resultados	Conclusiones	Recomendaciones
Específicos	No se conoce el comportamiento de la demanda en función del tiempo de las ventas de los años 2018, 2019 y 2020.	Realizar un diagnóstico del comportamiento de la demanda en función del tiempo de las ventas históricas de los años 2018, 2019 y 2020.	El alcance es descriptivo correlacional; descriptivo porque se estudiaron las causas, características y propiedades de la variable dependiente (ventas) y correlacional porque se analizó la relación que tiene la variable dependiente (ventas) con la variable independiente (tiempo) con el fin de poder pronosticar las ventas futuras.	El promedio de ventas mensuales es de 681 unidades con desviación estándar de 282 unidades, al realizar la gráfica de dispersión de datos, se observó que existe un aumento en las ventas del año 2019 en comparación del año 2018, sin embargo en el 2020 hay una baja o decaída en las ventas por tema de Pandemia Covid-19, por lo que se convierten los datos en serie temporal con sustitución de datos atípicos, en donde cumple los supuestos de normalidad, homogeneidad de varianzas e independencia de los datos, el único supuesto que no cumple es el de estacionariedad, por lo que se realizó una diferenciación tanto en el componente estacional como el de tendencia.	El diagnóstico del comportamiento de la demanda en función del tiempo de las ventas históricas de enero de 2018 a diciembre de 2020 presenta una serie de tiempo que se ajusta a una distribución normal, es homocedástica en varianzas, no es estacionaria, la serie de residuos posee autocorrelación y contiene componente estacional y de tendencia.	Es necesario realizar diagnósticos de la demanda por lo menos cada trimestre para analizar la demanda en función del tiempo de las ventas históricas de tres años como mínimo, lo cual servirá para el análisis y evaluación de la serie temporal de las ventas.
	No se conocen los métodos de pronósticos que se evaluarán en la serie de datos histórica de ventas.	Evaluar la serie temporal de las ventas históricas, utilizando los métodos de pronósticos específicos según los patrones de la demanda.	La investigación es de tipo descriptivo correlacional, debido a que se estudió la relación que tienen las variables de estudio.	Dado el análisis exploratorio de los datos, se procedió a evaluar la serie temporal de ventas históricas con los métodos de suavización exponencial triple o de Holt-Winters con constantes Alfa de 0.6451, Beta de 0.0001 y Gamma de 0.0002, modelo Auto-ARIMA con transformación logarítmica (1,1,0),(0,1,0)[12] y un modelo ARIMA (0,0,0)(1,1,0)[12].	Se evaluaron los métodos de pronósticos de suavizamiento exponencial triple o de Holt-Winters con los parámetros alfa de 0.6451, beta de 0.0001 y gamma de 0.0002, Auto-ARIMA (1,1,0),(0,1,0)[12] y ARIMA (0,0,0)(1,1,0)[12], según el comportamiento de la demanda de las ventas históricas del producto aromatizante para vehículos.	Se debe evaluar los métodos de pronósticos que se adaptan mejor al comportamiento de la demanda, para generar el modelo que se ajuste mejor a los datos por lo menos cada trimestre.

Continuación del apéndice 1.

Elementos	Problema estadístico	Objetivos	Metodología	Resultados	Conclusiones	Recomendaciones
Específicos	Se desconoce el modelo de pronósticos que genera el menor error.	Comprobar la precisión de los modelos específicos que se evaluarán, utilizando los criterios de información y las medidas de error de pronósticos.	Las variables que se analizaron en la investigación fueron las ventas en unidades en presentación Jarra, como variable dependiente y el tiempo en meses como variable independiente. Son variables de tipo cuantitativo, escala de razón.	Se evaluó la precisión de cada modelo dando como resultado los siguientes AICc: 49.4157, -41.3358, 297.0168. BIC: 472.3355, -39.6648, 298.8015. MAPE: 6.5302, 5.1555, 6.3802. MAAPE: 6.5067, 5.1373, 6.3406 para los modelos Holt-Winters, Auto-ARIMA (1,1,0),(0,1,0)[12] y ARIMA (0,0,0)(1,1,0)[12] respectivamente.	Los modelos específicos de pronósticos que generan el menor criterio de información y la menor medida de error son los de suavizamiento exponencial triple o de Holt-Winters, Auto-ARIMA (1,1,0),(0,1,0)[12] y ARIMA (0,0,0)(1,1,0)[12], los criterios de información que se evaluaron fueron los de Akaike (AIC), de Akaike corregido (AICc), bayesiano (BIC) y las medidas de error de pronósticos como el error porcentual absoluto medio (MAPE) y el error porcentual medio arcotangente (MAAPE).	Utilizar los criterios de información y medidas de error de pronósticos para comparar y seleccionar el mejor modelo de pronósticos para comprobar la precisión de este cada vez que se evalúen los métodos de pronósticos.

Nota. Se presenta la matriz de coherencia. Elaboración propia, realizado con Microsoft Excel.

Apéndice 2.

Código en R Studio 4.2.0

```
rm(list = ls())
graphics.off()
if(!require(readxl)){install.packages("readxl")}#Leer archivos Excel
if(!require(zoo)){install.packages("zoo")}#Mutate, rollmean
if(!require(tsutils)){install.packages("tsutils")}#decomp, mseastest, seasplot
if(!require(ggplot2)){install.packages("ggplot2")}#graficos junto con ggfortify
if(!require(nortsTest)){install.packages("nortsTest")}#check_residuals
if(!require(plotly)){install.packages("plotly")}#plot_ly
if(!require(autoplotly)){install.packages("autoplotly")}#autoplotly y ggfortify
if(!require(TSrepr)){install.packages("TSrepr")}#maape
if(!require(trend)){install.packages("trend")}#funcion cs.test
if(!require(seastests)){install.packages("seastests")}#funcion wo, de
#estacionalidad, isSeasonal
if(!require(forecast)){install.packages("forecast")}#nsdiffs, auto.arima,
#seasadj
if(!require(Metrics)){install.packages("Metrics")}#mape,mae,mse,rmse
if(!require(tsoutliers)){install.packages("tsoutliers")}#tso atipicos
if(!require(changepoint)){install.packages("changepoint")}#cpt.meanvar
if(!require(funtimes)){install.packages("funtimes")}#notrend_test
if(!require(TSA)){install.packages("TSA")}#funcion McLeod.Li.test
#(heterocedasticidad condicionada)
if(!require(trend)){install.packages("trend")}#funcion snh.test
if(!require(snht)){install.packages("snht")}#funcion snht
if(!require(TTR)){install.packages("TTR")}#funcion SMA
if(!require(quantmod)){install.packages("quantmod")}#funcion chartSeries
if(!require(tsoutliers)){install.packages("tsoutliers")}#funcion tso

#VENTAS HISTÓRICAS DEL PRODUCTO AROMATIZANTE PARA VEHÍCULOS LITTLE BOTTLE
#EXPRESADO EN JARRAS DE 42 UNIDADES DE FRAGANCIAS SURTIDAS DE ENERO DE 2018 A
#DICIEMBRE DE 2020.

##### 1.Importacion de datos desde excel #####

ventas_aromatizantes <- read_excel("base_de_datos.xlsx", sheet="ventas")
ventas_aromatizantes

##### 2. Objeto temporal tipo ts #####

ventas_aromatizantes$mes <- as.Date(ventas_aromatizantes$mes)
ventas_aromatizantes.ts <- ts(ventas_aromatizantes$ventas,start=c(2018,1),
                             frequency=12)

ventas_aromatizantes.ts
autoplotly(ventas_aromatizantes.ts,shareX="Tiempo", colour="blue")+
  ggplot2::ggtitle("Ventas históricas-Aromatizantes para vehículos") +
  ggplot2::labs(y="Ventas", x="Tiempo")
boxplot(ventas_aromatizantes.ts ~ cycle(ventas_aromatizantes.ts),
        col = rainbow(12))
cycle(ventas_aromatizantes.ts)

##### 3. Detección de valores atípicos #####

tsoutliers(ventas_aromatizantes.ts)
```

Continuación del apéndice 2.

```
##### 3.1. Objeto temporal tipo ts sustitución valores atípicos #####

ventas <- read_excel("base_de_datos.xlsx", sheet="ventas")
ventas.ts <- ts(ventas$ventas_outl,start=c(2018,1), frequency=12)
ventas.ts
autoplotly(ventas.ts,sharex="Tiempo", colour="blue")+
  ggplot2::ggtitle("Ventas históricas-Aromatizantes para vehículos") +
  ggplot2::labs(y="Ventas", x="Tiempo")
boxplot(ventas.ts ~ cycle(ventas.ts), col = rainbow(12))
cycle(ventas.ts)

##### 4. Análisis exploratorio #####

#Estacionariedad:
#Ho:La serie temporal no es estacionaria
#Ha:La serie temporal es estacionaria

#Homocedasticidad:
#Ho:La serie temporal es homocedástica
#Ha:La serie temporal es heterocedástica

#Distribucion Normal:
#Ho:La serie temporal se ajusta a una distribución normal
#Ha:La serie temporal no se ajusta a una distribución normal

nortsTest::check_residuals(ventas.ts,unit_root ="adf",normality="epps",
                           arch="Lm", seasonal="ocsb", plot=TRUE)
```

Continuación del apéndice 2.

```
##### 4.1. Análisis de homocedasticidad #####

#Homocedasticidad:
#Ho:La serie temporal es homocedástica
#Ha:La serie temporal es heterocedástica

snh.test(ventas.ts)

##### 4.2. Análisis de independencia #####

#Independencia:
#Ho:La serie de residuos no exhibe autocorrelación
#Ha:La serie de residuos recibe autocorrelación

Box.test(ventas.ts)
Box.test(ventas.ts, type="Ljung-Box")

##### 4.2.1. Gráficos función de autocorrelación #####

ggAcf(ventas.ts)
ggPacf(ventas.ts)
ggAcf(ventas.ts,plot=FALSE)
stats::acf(ventas.ts)
stats::pacf(ventas.ts)

##### 5. Descomposición de la serie #####

descomposicion_ventas <- decompose(ventas.ts, type="additive")
descomposicion_ventas
plot(descomposicion_ventas)
```

Continuación del apéndice 2.

```
##### 5.1. Análisis de estacionalidad y tendencia #####

#Estacionalidad:
#Ho:La serie de tiempo no es estacional
#Ha:La serie de tiempo es estacional

#Tendencia:
#Ho: La serie de tiempo no tiene tendencia
#Ha: La serie de tiempo tiene tendencia

tsutils::seasplot(ventas.ts,outplot=3)#Grafico de estacionalidad, pruebas de
#tendencia y estacionalidad

#Estacionalidad multiplicativa:
#Ho:La serie de tiempo no tiene estacionalidad multiplicativa
#Ha:La serie de tiempo tiene estacionalidad multiplicativa

mseastest(ventas.ts, outplot=2)#1,2#Si la estacionalidad es multiplicativa

##### 6. Diferenciación de la serie temporal #####

#valor de la diferenciación estacional

nsdiffs(ventas.ts,test="seas")#"seas","ch","hegy","ocsb"

#valor de la diferenciación de tendencia

ndiffs(ventas.ts,test="adf")#"adf","pp","kpss"

difventas.ts <- diff(ventas.ts)
difventas.ts
autoplot(difventas.ts)

##### 7. Suavización o Alisado Exponencial #####

##### 7.1. Alisado exponencial triple de Holt-winters #####

Hw.ventas <- hw(ventas.ts, h=6, seasonal="additive")
Hw.ventas$model
Hw.ventas #Pronostico
summary(Hw.ventas)
Hw.ventas$fitted
autoplotly(Hw.ventas,sharex="Tiempo", colpur="blue")+
  ggplot2::ggtitle("Pronóstico de Ventas-Alisado exponencial de Holt-winters")+
  ggplot2::labs(y="Ventas", x="Tiempo", type="l")
checkresiduals(Hw.ventas$model)
nortsTest::check_residuals(Hw.ventas$model,unit_root ="adf",normality="epps",
                           arch="Lm", seasonal="ocsb", plot=TRUE)
```

Continuación del apéndice 2.

```
##### 8. Modelos ARIMA #####

##### 8.1. Modelo 1 AUTO-ARIMA #####

#Funcion AUTO-ARIMA con transformacion logaritmica

Mod1.AR <- auto.arima(ventas.ts, lambda = "0")
Mod1.AR
summary(Mod1.AR)
ProMod1.AR <- forecast(Mod1.AR, h=6)
ProMod1.AR #pronostico
autoplotly(ProMod1.AR,sharex="Tiempo", colour="blue")+
  ggplot2::ggtitle("Pronóstico de Ventas-Auto ARIMA (1,1,0)(0,1,0)[12]") +
  ggplot2::labs(y="Ventas", x="Tiempo")
autoplot(ProMod1.AR)
nortsTest::check_residuals(Mod1.AR,unit_root = "adf",normality="epps",
                             arch="box", seasonal="ocsb", plot=TRUE)

##### 8.2. MODELO 2 ARIMA (0,0,0),(1,1,0)12 #####

Mod2.AR <- forecast::Arima(ventas.ts, order=c(0,0,0),seasonal=c(1,1,0))
summary(Mod2.AR)
ProMod2.AR <- forecast::forecast(Mod2.AR, h=6)
ProMod2.AR#ver pronostico
autoplotly(ProMod2.AR,sharex="Tiempo", colour="blue")+
  ggplot2::ggtitle("Pronóstico de Ventas-ARIMA0 (0,0,0),(1,1,0)[12]") +
  ggplot2::labs(y="Ventas", x="Tiempo")
nortsTest::check_residuals(Mod2.AR$residuals,unit_root = "adf",normality="epps",
                             arch="box", seasonal="ocsb", plot=TRUE)

##### 9. Comparación de modelos #####

aicc <- data.frame(Hw.ventas=Hw.ventas$model$aicc,
                   Mod1.AR=Mod1.AR$aicc,
                   Mod2.AR=Mod2.AR$aicc)

bic <- data.frame(Hw.ventas=Hw.ventas$model$bic,
                  Mod1.AR=Mod1.AR$bic,
                  Mod2.AR=Mod2.AR$bic)

mape <- data.frame(Hw.ventas=mape(Hw.ventas$x,Hw.ventas$fitted)*100,
                   Mod1.AR=mape(Mod1.AR$x,Mod1.AR$fitted)*100,
                   Mod2.AR=mape(Mod2.AR$x,Mod2.AR$fitted)*100)

maape <- data.frame(Hw.ventas=maape(Hw.ventas$x,Hw.ventas$fitted),
                    Mod1.AR=maape(Mod1.AR$x,Mod1.AR$fitted),
                    Mod2.AR=maape(Mod2.AR$x,Mod2.AR$fitted))

matriz <- rbind(AICC=aicc, BIC=bic, MAPE=mape, MAAPE=maape)
matriz
```

Nota. Se presenta el código en R Studio 4.2.0 elaboración propia, realizado con R Studio 4.2.0.