

Pronóstico de la Demanda en Línea de Producto  
de una empresa del sector Refrigeración mediante  
la Metodología Universal de Pronóstico



Las empresas siempre buscan que la incertidumbre en sus procesos a futuro sea mínima, definir qué, cuánto, cómo, cuándo y para quién se debe producir para no generar desperdicios, sobreproducción y que esto no conlleve a sobrecostos, hacen parte de una buena planificación y control en ellas.

Pronosticar un evento futuro a partir de situaciones pasadas y presentes en las empresas, es la base para controlar las variables de los procesos en la búsqueda de obtener los resultados deseados, dando respuesta a los cinco ítems antes mencionados. Para cualquier organización evaluarse en función de acciones pasadas y presentes para planificar su futuro es parte de su buena gerencia en función de ser más competitivos y sobrevivir a las fluctuantes del mercado.

El pronóstico es desarrollado en una línea de producto de una empresa de Refrigeración, la cual no está realizando de manera adecuada el primer paso de la planeación de la producción, que es su pronóstico de la demanda, ya que el método que utilizan (promedio móvil simple a 3 periodos) no es acertado para pronosticar.



[www.ul.edu.co](http://www.ul.edu.co)  
Corporación Universitaria Latinoamericana  
Colombia, Barranquilla  
<http://libros.ul.edu.co/index.php/libros>



Pronóstico de la Demanda en Línea de Producto de una empresa del sector  
Refrigeración mediante la Metodología Universal de Pronóstico

## Pronóstico de la Demanda en Línea de Producto de una empresa del sector Refrigeración mediante la Metodología Universal de Pronóstico



Por Juan Carlos Herrera Vega,  
Rafael José Rodríguez Fernández,  
Sebastián Lanziano Ordoñez,  
Bruno de Jesus Rahmer,  
Hugo Hernández Palma



Pronóstico de la Demanda en Línea de Producto  
de una empresa del sector Refrigeración mediante  
la Metodología Universal de Pronóstico





***Pronóstico de la Demanda en Línea  
de Producto de una empresa del  
sector Refrigeración mediante la  
Metodología Universal de Pronóstico***



**Pronóstico de la Demanda en Línea de Producto de una empresa del sector Refrigeración mediante la Metodología Universal de Pronóstico**

*©Juan Carlos Herrera Vega, Rafael José Rodríguez Fernández, Sebastián Lanzziano Ordoñez, Bruno de Jesus Rahmer y Hugo Hernández Palma*

**Libro Resultado de Investigación**  
**ISBN 978-958-52861-3-9**

# *Pronóstico de la Demanda en Línea de Producto de una empresa del sector Refrigeración mediante la Metodología Universal de Pronóstico*

Autores:

*Juan Carlos Herrera Vega, Rafael José Rodríguez Fernández, Sebastián Lanziano Ordoñez y Bruno de Jesus Rahmer, Fundación Universitaria Tecnológico Comfenalco*

*Hugo Hernández Palma, Universidad del Atlántico*



Impreso por Corporación Universitaria Latinoamericana  
Colombia | Atlántico | Barranquilla

Pronóstico de la Demanda en Línea de Producto de una empresa del sector Refrigeración mediante la Metodología Universal de Pronóstico/ Barranquilla: Ediciones Corporación Universidad Latinoamericana, 2020.

116 p.; tablas; 17 X 24 cm  
ISBN 978-958-52861-3-9  
Incluye referencia bibliográfica

Pronóstico de la Demanda en Línea de Producto de una empresa del sector Refrigeración mediante la Metodología Universal de Pronóstico. I. Juan Carlos Herrera Vega, ii. Rafael José Rodríguez Fernández. iii. Sebastián Lanziano Ordoñez. iv. Bruno de Jesus Rahmer. v. Hugo Hernández Palma

658 G367 2020 Sistema de Clasificación Decimal Dewey 22ª. edición  
Corporación Universitaria Latinoamericana –Sistema de Bibliotecas

Impreso en Barranquilla, Colombia. Depósito legal según el Decreto 460 de 1995. El Fondo Editorial Ediciones Corporación Universidad Latinoamericana se adhiere a la filosofía del acceso abierto y permite libremente la consulta, descarga, reproducción o enlace para uso de sus contenidos, bajo una licencia Creative Commons Atribución 4.0 Internacional. <https://creativecommons.org/licenses/by/4.0/>

© Ediciones Corporación Universidad Latinoamericana  
Calle 58 55 -24a  
<http://libros.ul.edu.co/index.php/libros>  
[cinpro@ul.edu.co](mailto:cinpro@ul.edu.co)  
Barranquilla - Colombia

Producción Editorial  
Estrategias y calidad Editorial  
Calle 80B No. 41D-83  
[contacto@estrategiasycalidadeditorial.com](mailto:contacto@estrategiasycalidadeditorial.com)  
[www.estrategiasycalidadeditorial.com](http://www.estrategiasycalidadeditorial.com)

2020  
Barranquilla

Hecho en Colombia

# CONTENIDO

## CONTENIDO

|   |    |
|---|----|
| Resumen.....  | 9  |
| Abstract .....  | 10 |
| Introducción.....   | 11 |
| Objetivos De La Investigación .....                       | 12 |
| <i>Objetivo General</i> .....                             | 12 |
| <i>Objetivos Específicos</i> .....                        | 12 |
| Fundamentos Teóricos.....                                 | 13 |
| <i>Pronóstico De Demanda</i> .....                        | 13 |
| <i>Series Temporales</i> .....                            | 15 |
| <i>Metodología Universal De Pronósticos</i> .....         | 17 |
| <i>Análisis Previo</i> .....                              | 17 |
| <i>Síntesis</i> .....                                     | 18 |
| <i>Estructura Vertical – Nivel</i> .....                  | 18 |
| <i>Estructura horizontal – Ruido o aleatoriedad</i> ..... | 18 |
| <i>Estructura Tendencial</i> .....                        | 20 |
| <i>Estructura Estacional Y Cíclica</i> .....              | 20 |
| <i>Hipótesis</i> .....                                    | 21 |
| <i>Modelos Clásicos De Pronósticos</i> .....              | 22 |
| <i>Modelos De Ajuste Por Tendencia</i> .....              | 23 |
| <i>Modelos De Suavización</i> .....                       | 23 |
| <i>Modelos De Descomposición</i> .....                    | 25 |
| <i>Modelos Modernos A.R.I.M.A.</i> .....                  | 27 |
| <i>Recorte De La Serie De Datos</i> .....                 | 30 |

|  |    |
|--|----|
| <i>Determinar El Mejor Modelo</i> .....  | 30 |
| <i>Preparación De La Tabla De Comparaciones</i> .....                                | 30 |
| <i>Selección Del Mejor Modelo</i> .....  | 30 |
| <i>Cálculo De Los Pronósticos</i> .....  | 30 |
| <i>Pronóstico Mediante Redes Neuronales</i> .....                                    | 31 |
| <i>Generalidades Sobre Las Redes Neuronales</i> .....                                | 32 |
| <i>Contraste Entre La Neurona Biológica Y La Neurona Artificial</i> ..               | 32 |
| Antecedentes.....  | 34 |
| Descripción De La Problemática Caso De Estudio.....                                  | 37 |
| <i>Herramienta Para La Identificación Del Problema</i> .....                         | 37 |
| <i>Identificación Del Problema</i> .....   | 37 |
| <i>Análisis Del Problema</i> .....   | 41 |
| Resultados De La Investigación.....  | 42 |
| <i>Metodología Universal De Pronosticos En La Empresa</i> .....                      | 42 |
| <i>Síntesis</i> .....  | 42 |
| <i>Análisis Previo De La Serie De Tiempo</i> .....                                   | 43 |
| <i>Análisis De Estructura Vertical</i> .....   | 43 |
| <i>Análisis De Estructura Horizontal De Ruido O Aleatoriedad</i> ....                | 45 |
| <i>Análisis De Estructura Tendencial</i> .....                                       | 47 |
| <i>Análisis De Estructura Estacional Y/O Cíclica</i> .....                           | 48 |
| <i>Hipotesis Y Postulación De Modelos</i> .....                                      | 50 |
| <i>Pronósticos A Partir De Modelo De Regresión Lineal Y A.R.I.M.A.</i> ..            | 54 |
| <i>Metodología De Diseño E Implementación De Un Modelo De Redes Neuronales</i> ..... | 58 |
| Resultados.....  | 59 |
| <i>Caracterización De La Variable Respuesta</i> .....                                | 59 |
| <i>Creación De La Partición De Datos</i> .....                                       | 59 |
| <i>Definición De La Arquitectura Del Perceptrón Multicapa</i> ....                   | 60 |
| <i>Algoritmo De Aprendizaje</i> .....  | 61 |
| <i>Resultados</i> .....  | 63 |
| Conclusiones.....  | 65 |
| Referencias Bibliográficas.....  | 67 |



# **Pronóstico de la Demanda en Línea de Producto de una empresa del sector Refrigeración mediante la Metodología Universal de Pronóstico**

*Juan Carlos Herrera Vega*

*Rafael Rodríguez Fernández*

*Sebastián Lanzziano Ordoñez*

*Bruno de Jesus Rahmer*

*Fundación Universitaria Tecnológico Comfenalco*

*Hugo Hernández Palma*

*Universidad del Atlántico*

## **RESUMEN**

Las empresas siempre buscan que la incertidumbre en sus procesos a futuro sea mínima, definir qué, cuánto, cómo, cuándo y para quién se debe producir para no generar desperdicios, sobreproducción y que esto no conlleve a sobrecostos, hacen parte de una buena planificación y control en ellas.

Pronosticar un evento futuro a partir de situaciones pasadas y presentes en las empresas, es la base para controlar las variables de los procesos en la búsqueda de obtener los resultados deseados, dando respuesta a los cinco ítems antes mencionados. Para cualquier organización evaluarse en función de acciones pasadas y presentes para planificar su futuro es parte de su buena gerencia en función de ser más competitivos y sobrevivir a las fluctuantes del mercado. El pronóstico es desarrollado en una línea de producto de una empresa de Refrigeración, la cual no está realizando de manera adecuada el primer paso de la planeación de la producción, que es su pronóstico de la demanda, ya que el método que utilizan (promedio móvil simple a 3 periodos) no es acertado para pronosticar.

Para plantear una solución a esta problemática, se debe determinar el modelo de pronóstico de la demanda más apropiado para la empresa, planteándolo como una propuesta para reemplazar su método actual. Se emplea la metodología del modelo universal de pronósticos, empleando software como Microsoft Excel y Statgraphics Plus.

Finalmente, la realización de este trabajo impacta de manera positiva en la medida que se obtuvo un método de pronóstico de la demanda para los siguientes periodos(meses) mucho más acertados, lo que da como un siguiente resultado una planeación de la producción robusta, haciendo que la empresa se encuentre mejor preparada para afrontar la fluctuante demanda.

**PALABRAS CLAVES:** Pronóstico, Demanda, Metodología Universal de Pronóstico, Series Temporales, Modelos A.R.I.M.A.

## **ABSTRACT**

The Companies are always looking for that uncertainty in their processes in the future is minimal, define what, how much, how, when and for whom to produce in order to avoid waste, overproduction and this may lead to over costs, is part of good planning and control in them.

Predicting a future event from past and present situations in companies is the basis for controlling the variables of the processes in the search to obtain the desired results, responding to the five items mentioned above. For any organization to evaluate itself based on past and present actions to plan its future is part of its good management in terms of being more competitive and surviving fluctuating market. The forecast is developed in a product line of a Refrigeration company, which is not adequately performing the first step of the production planning, which is its forecast of the demand, since the method they use (moving average) simple to 3 periods) is not right to predict.

To propose a solution to this problem, the most appropriate demand forecast model for the company must be determined, presenting it as a proposal to replace its current method. The methodology of the universal forecasting model is used, using software such as Microsoft Excel and Statgraphics Plus.

Finally, the realization of this work has a positive impact on the extent to which a demand forecasting method was obtained for the following periods (months) that are much more accurate, which gives as a result the planning of the robust production,

making that the company is better prepared to face the fluctuating demand.

**KEYWORDS:** Forecast, Demand, Universal Forecasting Methodology, Temporary Series, A.R.I.M.A Models.

## INTRODUCCIÓN

En el mundo actual y global de las industrias, la competitividad y la capacidad de generar utilidades juega un papel muy importante en la sobrevivencia de una empresa, por lo que es necesario tener en cuenta todos los aspectos posibles que puedan hacer que mejore la rentabilidad y competitividad de estas, el principal aspecto a tener en cuenta debe ser el fluctuante mercado, ya que si una empresa quiere ser competitiva debe estar en capacidad de afrontarlo. Una excelente manera, es llevando a cabo una buena administración de la producción y control de esta con el fin de saber el que, cuanto, como y para quien producir, de esta manera se enfocan los recursos de tal forma que se pueda cumplir con los requerimientos de dicho fluctuante mercado.

Analizando en detalle los procesos relacionados con la planeación de la producción, se evidenció que la organización no posee un método apropiado para realizar el pronóstico de la demanda, si bien es cierto, utiliza el método de Promedio Móvil Simple con  $n=3$ , este es realmente sencillo y con poca confiabilidad, ya que se basa en una predicción que toma como referente los promedios y cuya debilidad manifiesta son los puntos aislados, por lo que la empresa no estaría realizando la planeación bajo criterios óptimos. Por otra parte, no hay una persona especializada para realizar estos pronósticos, lo que conlleva a una baja confiabilidad de los datos, puesto que los métodos, metodologías o modelos no son generados por expertos en el tema. La gestión de recolección de los datos que alimentan el método se retrasa e incluso se distorsionan estos mismos, haciendo que método sea aún menos eficaz. La empresa tampoco cuenta con un software licenciado y especializado para realizar la proyección de la demanda. En consecuencia, lo que se genera es una metodología de pronóstico sin exactitud o precisión de los resultados, lo cual puede ser delicado en términos financieros, considerando que con ellos se toman las decisiones dentro de la línea de producción de la empresa de Refrigeración, lo que hasta la fecha del estudio le había generado altos sobrecostos.

El objetivo del proyecto se enfocó en dar respuesta a cuanto producir, ya que muchas son las empresas que no saben cómo hacerlo y en la mayoría de los casos lo hacen de una manera inadecuada. El dar respuesta a esta pregunta involucra la aplicación de un método que utiliza hechos pasados para predecir el futuro, si bien se puede afirmar

que es imposible la formulación de un método que logre predecir al cien por ciento el futuro, también es posible afirmar que existen métodos que se acercan mucho a la realidad futura. Dependiendo el comportamiento del pasado y su correcta aplicación.

Se utilizó la Metodología Universal de Pronósticos desarrollada por el Ingeniero Mecánico Luis Mora, para analizar cuál de los modelos clásicos o modernos de pronósticos es el más acertado para la empresa, en términos de mayor precisión y menor error, que se traduzca en mayores ahorros económicos, con la finalidad de plantearlo como una propuesta a remplazar el método actual empleado por la empresa de refrigeración caso de estudio, y de esta forma poder cumplir con los requerimientos del mercado minimizando inventarios y costos asociados a órdenes de trabajo atrasadas. Aplicando la metodología universal de pronósticos a la serie de tiempo de ventas del producto se obtuvo que el mejor método para pronosticar con base a esta es el modelo (A) ARIMA (0, 1,1) x (1, 0,1)<sup>12</sup>. Se logró comparar contra los pronósticos base implementados en la empresa, encontrándose unos ahorros económicos estimados en \$60.004.720.

## **OBJETIVOS DE LA INVESTIGACIÓN**

### ***Objetivo General***

Analizar la demanda de producto estrella para el desarrollo de un modelo de pronóstico tomando como base la metodología del Modelo Universal de Pronósticos, en una empresa del sector metalmecánico en el departamento de Bolívar.

### ***Objetivos Específicos***

Desarrollar el análisis previo de la demanda, para la identificación del patrón o patrones de comportamiento de la línea de producto seleccionada en la empresa caso de estudio.

Postular modelos clásicos o modernos acorde a las características presentes en la demanda objeto de estudio.

Determinación del mejor modelo de pronóstico con base en el error de pronóstico y la bondad de ajuste presente.

## FUNDAMENTOS TEÓRICOS

### *Pronóstico De Demanda.*

Independiente del tamaño de las organizaciones uno de los retos de los Directivos y la alta gerencia en empresas manufactureras, es lograr minimizar el impacto de la variación de la demanda en la planeación organizacional. ¿Cuál será el crecimiento de nuestra empresa? ¿Cuál será el volumen de ventas el próximo año? ¿Será necesario comprar más máquinas o mudarse de edificio? Estas son algunos de los interrogantes que se plantean los ejecutivos de las empresas interesados en alcanzar un crecimiento de sus operaciones en forma ordenada y programada. En la proyección o predicción de las operaciones de una compañía, se utilizan técnicas de pronósticos tan diversas casi como empresas existen. Los hay basados en presentimientos intuitivos, en supuestos personales, hasta llegar a los que utilizan enfoques matemáticos y estadísticos.

Chapman (2006) consideró que “El punto de inicio de prácticamente todos los sistemas de planificación se da a partir de la demanda real o esperada de los clientes sin embargo en casi todos los casos el tiempo necesario para generar y entregar el producto o servicio excederá la expectativa del cliente o por el contrario se crean inventarios de productos terminados generando costos adicionales, si se quiere evitar que esto suceda, la producción tendrá que dar principio antes de que se conozca la demanda real del consumidor. Así, la producción deberá iniciar de la demanda esperada o, en otras palabras, de un pronóstico de demanda”<sup>1</sup>.

Además, Chapman (2006) manifiesta que el pronóstico no es realmente una predicción, sino una proyección estructurada del conocimiento pasado. Existen varios tipos de pronóstico, utilizados para distintos propósitos y sistemas. Algunos son modelos agregados de largo plazo que se emplean, precisamente, en la planificación de largo plazo, como la determinación de necesidades de capacidad general, el desarrollo de planes estratégicos, y la toma de decisiones estratégicas de compra de largo plazo. Otros son pronósticos de corto plazo para demanda de productos particulares, utilizados para la programación y el lanzamiento de la producción, antes de conocer las órdenes reales del cliente.<sup>2</sup>

Ha, C., Seok, H., & Ok, C. (2018) expresa que el criterio más importante para elegir un método de pronóstico es su precisión, es decir, qué tan fielmente predice el evento real. Un método de pronóstico con un pequeño error de pronóstico generalmente se

---

1 CHAPMAN, S. (2006). Planificación y control de la producción. México: Pearson Educación

2 Ibíd. Pág17.

acepta como bueno y el error de pronóstico se calcula en función de la diferencia de los valores pronosticados y los valores reales. La Desviación Absoluta Media (MAD), el Error Cuadrático Medio (MSE) y el Error Medio de Porcentaje Absoluto (MAPE) se utilizan como medidas típicas para determinar la precisión de los métodos de pronóstico.<sup>3</sup>

Nahmias (2007) considera que existen varias características de los pronósticos, las cuales se hace mención a continuación:<sup>4</sup>

- Normalmente están equivocados. Los pronósticos, una vez determinados, se consideran información conocida. Los requerimientos de recursos y los calendarios de producción pueden necesitar modificaciones si la demanda de pronóstico prueba ser inexacta. El sistema de planeación debe ser lo suficientemente sólido capaz de reaccionar ante errores de pronóstico no anticipados.
- Un buen pronóstico es más que un simple número. Dado que los pronósticos generalmente están equivocados, un buen pronóstico incluye cierta medida de error. Esto puede ser mediante un rango, o una medición de error como sería la variación de la distribución del error de pronóstico.
- Los pronósticos agregados son más exactos. De acuerdo a las estadísticas, la variación del promedio de una colección de variables aleatorias independientes distribuidas de manera idéntica es menor que la variación de cada una de las variables aleatorias; esto es, la variación de la muestra media es menor que la variación de la población. Este mismo fenómeno se presenta en los pronósticos. En una base porcentual, el error cometido en las ventas pronosticadas para una línea de productos generalmente es menor que el error cometido en el pronóstico de ventas para un producto individual.
- Entre más lejano sea el horizonte de pronóstico, menos exacta será la predicción. Es una característica totalmente intuitiva. Puede predecirse el valor que tendrá mañana el Dow Jones Industrial Average con mayor exactitud que el de del próximo año.
- Los pronósticos no deben usarse para excluir información conocida. En ocasiones, en los pronósticos puede haber información disponible concerniente a la demanda futura que no se mostró en la historia pasada de la serie. Por ejemplo, la compañía puede estar planeando una venta promocional especial para un producto en particular, por lo que la demanda probablemente será mayor que la normal. Esta información debe incluirse manualmente en el pronóstico.

3 HA, C., SEOK, H., & OK, C. (2 de Marzo de 2018). Evaluation of forecasting methods in aggregate production planning: Accumulative Absolute Forecast Error (CAFE). Seúl, República de Corea: ELSEVIER.

4 NAHMIA, S. (2007). Análisis de la producción y las operaciones. México D.F: 5 Ed. McGraw-Hill

### ***Series Temporales***

En Chapman (2006) los pronósticos de series de tiempo se encuentran entre los más utilizados por los paquetes de pronóstico vinculados con la proyección de demanda de productos. Todos ellos parten, básicamente, de un supuesto común: que la demanda pasada sigue cierto patrón, y que si este patrón puede ser analizado podrá utilizarse para desarrollar proyecciones para la demanda futura, suponiendo que el patrón continúa aproximadamente de la misma forma. Por último, esto implica el supuesto de que la única variable real independiente en el pronóstico de series de tiempo es, precisamente, el tiempo. Dado que se basan en información interna (ventas), en ocasiones se les denomina pronósticos intrínsecos.<sup>5</sup>

Esta metodología se basa en la utilización del modelo universal de pronósticos, con sus tres etapas del método científico: análisis previo, lanzamiento de hipótesis y verificación. Entre las metodologías que trabaja están: modelos clásicos y modelos estocásticos A.R.I.M.A.

Chase, (citado en Murraya, P. W., Agarda, B., & Baraja, M. A. 2018) manifiesta que los métodos de pronóstico de series de tiempo (incluyendo el promedio ingenuo, móvil, suavizado exponencial, descomposición y ARIMA) se basan en la premisa de que las ventas futuras limitarán el (los) patrón (s) de las ventas al por menor.<sup>6</sup>

Mora (2007) define una serie temporal, como un conjunto de datos obtenidos del análisis y de las observaciones de una variable discreta durante un lapso secuencial de tiempo, es importante recordar que existen datos no temporales, que son observaciones realizadas de una forma no hilada en el tiempo. En general se puede concretar que una serie temporal de datos es un conjunto de valores de una variable, asociados a otro grupo de instantes definidos de tiempo; lo que implica el estudio de dos variables, donde una de ellas es el tiempo y la otra representa el fenómeno que se desea pronosticar. Algunas de las áreas empresariales donde se practican con intensidad los pronósticos, son:<sup>7</sup>

- Previsión tecnológica, esta busca pronosticar cambios futuros en el sector en donde está ubicada la empresa y en aquellos entornos donde se consume los productos que se fabrican.

---

5 CHAPMAN, S. (2006). Planificación y control de la producción. México: Pearson Educación

6 MURRAYA, P. W., AGARDA, B., & BARAJA, M. A. (6 de Febrero de 2018). Forecast of individual customer's demand from a large and noisy dataset. Canada : ELSEVIER

7 MORA, A. G. (2007). Pronósticos de demanda e inventarios. Medellín: Editorial A M G.

- Previsión de ventas, esta se basa en las estimaciones sobre las posibles cuotas de mercado de la empresa en cada segmento; le permite a la organización planificar el resto de las actividades más importantes: producción, inversiones, gastos, contratación de personal, inventarios, demanda, materias primas, etc.
- Previsiones demográficas, tales como: tasas de natalidad, de nupcialidad, volúmenes de enfermedades, etc.; tienen interés para pronosticar las demandas de la sociedad en productos o servicios, ejemplo de esto son los cupos en las universidades.
- Previsión de recursos humanos, es una conjetura sobre las necesidades futuras de personal en las empresas en sus diferentes áreas.

Khorasani, Ehteshami, Ghadimi, & Salari, (2016) manifiestan que el modelado de series temporales o, en otras palabras, la descripción del comportamiento de una serie temporal en lenguaje matemático incluye tres pasos comunes: identificar el modelo experimental, estimando los parámetros del modelo (ajuste) y verificación del modelo. Para una identificación adecuada de un modelo experimental, se recomienda que estén disponibles al menos 50 observaciones de las series consideradas. Al analizar series de tiempo hidrológicas y ambientales con la aplicación de teorías estocásticas y estadísticas, se asume que todas las variables tienen una distribución normal. El primer paso en el modelado de una serie temporal es dibujarlo como un diagrama de series de tiempo que puede impulsar la identificación de tendencias, la no estacionalidad de la varianza, la estacionalidad (periodicidad) y otros tipos de irregularidades en los datos. La mayoría de los datos de series de tiempo no siguen una distribución normal, por lo tanto, antes de modelar o analizar procesos, necesitan normalizarse mediante funciones de transferencia. Como paso de pretratamiento, se dispone de una variedad de diferentes funciones de transferencia y pruebas estadísticas para preparar los datos antes de cualquier modelado que incluya la transformación de Box-Cox y la no estacionariedad en la media o la varianza. Estas pruebas se pueden categorizar en dos grupos principales: pruebas de independencia (por tiempo) y pruebas de distribución normal. Además, antes de cualquier proceso de modelado, las condiciones de las series de tiempo se prueban con respecto a la bondad de ajuste, los criterios de ajuste de pozos, el nivel de confiabilidad y los límites de los parámetros estadísticos.<sup>8</sup>

Prema & Uma Roa (2013) establecen que los principales tipos de modelos de series de tiempo incluyen modelos de series temporales paramétricas y no paramétricas. Los

---

8 KHORASANI, M., EHTESHAMI, M., GHADIMI, H., & SALARI, M. (11 de Junio de 2016). Simulation and analysis of temporal changes of groundwater depth using time series modeling. Iran: Springer International Publishing Switzerland.

enfoques paramétricos suponen que el proceso estocástico estacionario subyacente tiene una cierta estructura que se puede describir usando un pequeño número de parámetros.<sup>9</sup>

Severine Meunier, M., Cheikhrouhou, N., & Glardon, R. (2005) consideraron que aunque la aleatoriedad del patrón de series de tiempo no evalúa completa-mente la dificultad para establecer pronósticos matemáticos precisos, esta in-formación presenta la ventaja de la simplicidad e indica con una probabilidad razonable si se cumple la hipótesis para el uso de técnicas de extrapolación para la predicción.<sup>10</sup>

### ***Metodología Universal De Pronósticos.***

La metodología universal de pronósticos brinda una oportunidad de poder desarrollar un análisis estructurado, secuencial y lógico de las series de tiempo. El autor de esta metodología es el ingeniero en ciencias mecánicas Luis Alberto Mora Gutiérrez, que con sus estudios y amplia experiencia en pronósticos aplicados da a conocer esta herramienta tan importante para la planeación.

### ***Análisis Previo.***

El primer paso del método universal de acuerdo con Mora (2007) busca inicialmente realizar una observación y posterior análisis del comportamiento de los datos, de tal forma que se puedan detectar sus elementos característicos y asociarlos a los modelos más apropiados. En esta fase lo importante es determinar la estructura de la serie temporal.<sup>11</sup>

---

9 PREMA, V., & UMA RAO, K. (2013). Time series decomposition model for accurate wind speed forecast. Bangalore, India: Springer.

10 SEVERINE MEUNIER, M., CHEIKHROUHO, N., & GLARDON, R. (2005). Strategic Analysis of Products Related to the Integration of Human Judgement into Demand Forecasting. Ecublens, Switzerland: Springer

11 MORA, A. G. (2007). Pronósticos de demanda e inventarios. Medellín: Editorial A M G.

### **Síntesis.**

Mora (2007) considera que la síntesis es la parte donde se define o se plantea el tema a estudiar, se describen los antecedentes, en especial la metodología cualitativa por la cual se llega a determinar la importancia de realizar pronósticos en el fenómeno seleccionado y en especial se demuestra mediante la narración histórica de su contexto y del entorno en que se mueve. Esta síntesis histórica debe permitir al lector, poder conocer el entorno donde se desenvuelven los hechos que se pronostican y verificar que este tenga cierta estabilidad a lo largo de la historia.<sup>12</sup>

### **Estructura Vertical – Nivel.**

De acuerdo con Mora (2007) En este paso la estructura de nivel busca medir el comportamiento horizontal de la serie, entender su comportamiento a lo largo del tiempo. Se busca encontrar una serie sin cambios de nivel que invaliden la predicción futura. Gráficamente se pueden entender los cambios de nivel de la serie pero se debe complementar la información analíticamente, para ello se puede utilizar la relación de la media con la desviación estándar, se espera encontrar valores menores a 50% para series sin cambio de nivel.<sup>13</sup>

### **Estructura horizontal – Ruido o aleatoriedad.**

Para Makridakis (2009) el patrón o estructura horizontal se refiere a una serie neutra (que tiende a cero), que posee una desviación estándar pequeña y constante a lo largo de toda ella, donde a este fenómeno se le denomina estacionalidad. En estos casos se enuncia que la serie permanece estable dentro de cierto rango o desviación de valores; cuando esto ocurre en las series estacionarias en media, existe una probabilidad igual de que el siguiente valor este por encima como por debajo de la media (hay ausencia de ruido alrededor de la media). (Grafico 1).<sup>14</sup>

---

12 Ibid. Pág. 96.

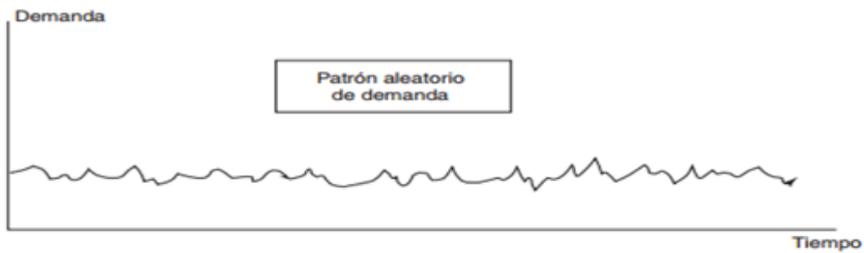
13 Ibid., Pág. 96

14 MAKRIDAKIS, S. y. (2009). Métodos de Pronósticos. México: Editorial Limusa.

El principio básico para determinar la existencia de ruido es mediante la suavización, buscando minimizar la desviación estándar (oscilaciones alternadas alrededor de una serie) de la serie mediante la supresión del componente de ruido para eliminar las incidencias aleatorias, que son las causantes de este ruido.

La serie con ruido presenta una distancia significativa entre los puntos de la serie original y los de la suavizada, lo que permite afirmar que los pronósticos que se calculan a partir de la historia de esta serie tienen influencia del ruido. Los componentes irregulares se revisan mediante Statgraphics en Irregular Component, que permite revisar la calidad de los datos de una serie. En el evento de que exista uno a más datos fuera de una desviación estándar normal, la gráfica es diferente, el método es básicamente de observación cualitativa.

Gráfico 1. Patrón aleatorio de la demanda.

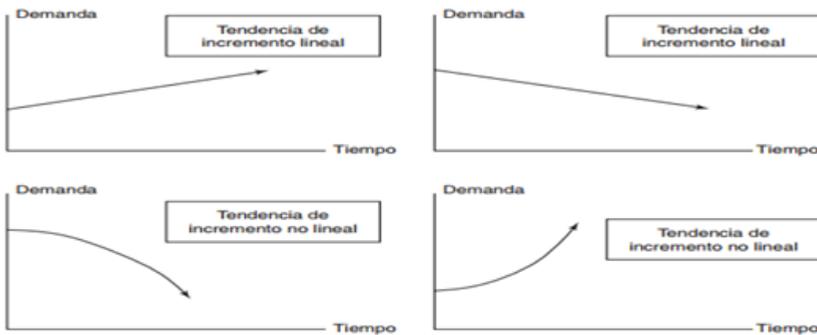


Fuente: planificación y control de la producción. Stephen N. Chapman, año 2006

### **Estructura Tendencial.**

Nahmias (2007) se refiere a la característica que presenta una serie de tiempo, a mostrar una tendencia de incremento línea o tendencia de incremento no lineal, evidenciable al analizar detalladamente los datos o representarlos gráficamente. (Gráfico 2).<sup>15</sup>

**Gráfico 2. Ejemplos de tendencias en la demanda**

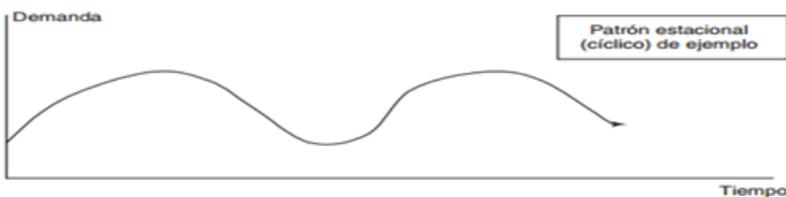


Fuente: planificación y control de la producción. Stephen N. Chapman, año 2006

### **Estructura Estacional Y Cíclica.**

Collier (2009) hizo mención de que los patrones estacionales se caracterizan por periodos repetibles de altas y bajas a lo largo de los periodos cortos, mientras que los patrones cíclicos son regulares en una serie de datos que suceden durante largos periodos. (Gráfico 3).<sup>16</sup>

**Gráfico 3. Patrón estacional (cíclico)**



Fuente: planificación y control de la producción. Stephen N. Chapman, año 2006

15 NAHMIA, S. (2007). Análisis de la producción y las operaciones. México D.F: 5 Ed. McGraw-Hill.

16 COLLIER, D. A. (2009). Administración de Operaciones. México D.F: 2 Ed. Cengage learning.

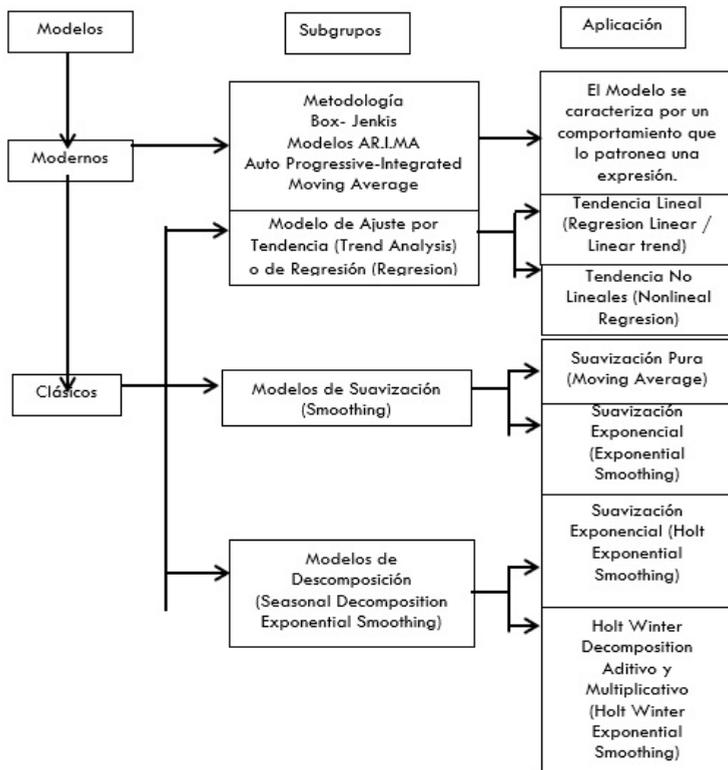
**Hipótesis.**

Se fundamenta principalmente en la determinación de el o los modelos que se ajustan de mejor forma a las características de la serie analizada en el paso uno. Se trata de conocer los comportamientos propios de cada uno de los modelos más utilizados tanto de clásicas como de modernos, con el fin de plantear hipótesis a partir las características de la serie de tiempo encontrada en el paso previo.

**Postulación De Los Modelos.**

La postulación de los modelos se basa en construir una hipótesis con relación a los modelos, y se cruza el análisis previo con las características de los modelos clásicos y/o modernos. (Figura 1

Figura 1. Modelos de Pronóstico



### **Modelos Clásicos De Pronósticos**

Las metodologías clásicas empleadas para el análisis de series temporales tienen su fundamento en la adopción del comportamiento pasado y actual de los datos, para predecir a partir de ellos el comportamiento futuro, con un margen de error dado.

#### **Modelos De Ajuste Por Tendencia.**

Para Mora (2007) este modelo lineal se ajusta a lo planteado en la ecuación 1:<sup>17</sup>

Ecuación 1: Ecuación de modelo de ajuste por tendencia lineal.

$$P = (a + b) * t$$

**P:** Pronóstico

**a:** es el intercepto de la serie temporal con el eje Y de los valores de la variable

**b:** la pendiente medida con la horizontal

**t:** es el instante del tiempo en que se desea valorar el pronóstico

Se pretende con este método que se puede realizar para un conjunto de datos, un ajuste con un modelo de regresión lineal con mínimos cuadrados a una línea recta, de tal forma que se pueda estimar los parámetros de la pendiente y el intercepto, que minimicen la participación del error aleatorio.

#### **Modelos De Suavización**

Nahmias (2007), define los modelos de suavización exponencial de la siguiente manera: “El pronóstico actual es el promedio ponderado del último pronóstico y el valor actual de demanda. Esto es,<sup>18</sup>

Nuevo pronóstico =  $\alpha$ (Observación actual de demanda) +  $(1 - \alpha)$ (Último pronóstico).

En símbolos,

$$F_t = \alpha D_{t-1} + (1 - \alpha) F_{t-1} \quad (1)$$

17 MORA, A. G. (2007). Pronósticos de demanda e inventarios. Medellín: Editorial A M G.

18 NAHMIA, S. (2007). Análisis de la producción y las operaciones. México D.F: 5 Ed. McGraw-Hill.

donde  $0 < \alpha \leq 1$  es la constante de suavizamiento, asociada a la ponderación relativa asignada al comportamiento actual de la demanda. Se debe entender  $(1 - \alpha)$  como el peso asignado a las observaciones pasadas. Replanteando la ecuación de una forma diferente, la ecuación de suavizamiento exponencial para  $F_t$  podría formularse como

$$F_t = F_{t-1} - \alpha(F_{t-1} - D_{t-1}) = F_{t-1} - \alpha e_{t-1} \quad (2)$$

Escrita de esta forma, vemos que el suavizamiento exponencial puede interpretarse de la siguiente manera: el pronóstico en cualquier periodo  $t$  es el pronóstico en el período  $t - 1$  más una cierta fracción de error de pronóstico observado en el período  $t - 1$ . Nótese que si pronosticamos alto en el período  $t - 1$ ,  $e_{t-1}$  es positivo y el ajuste consiste en disminuir el pronóstico. De forma similar, si pronosticamos bajo en el período  $t - 1$ , el error es negativo, y el ajuste es incrementar el pronóstico actual.

Prema, V., & Uma Rao, k. (2013), consideran que en los modelos de suavización, además, del suavizado exponencial único mencionado anteriormente, encontramos:<sup>19</sup>

Suavizado exponencial doble (DES) Este método se usa cuando los datos muestran una tendencia. El suavizado exponencial con una tendencia funciona de forma muy similar al simple alisamiento, excepto que se deben actualizar dos componentes en cada período y tendencia. El nivel es una estimación suavizada del valor de los datos al final de cada período. La tendencia es una estimación suavizada del crecimiento promedio al final de cada período. DES se puede modelar como se indica en las ecuaciones 3 y 4:

$$\text{Nivel: } S_{t+1} = \alpha X_{t+1} + (1 - \alpha)(S_{t+1} + b_{t-1}) \quad (3)$$

$$\text{Tendencia: } b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

Suavizado exponencial triple (TES) Este método se usa cuando los datos muestran tendencia y estacionalidad. Para manejar la estacionalidad, se agrega un tercer parámetro. Ahora, se introduce una tercera ecuación para cuidar la estacionalidad. El conjunto resultante de ecuaciones se llama el método "Holt-Winters" (HW) después de los nombres de los inventores. El modelo está dado por ecuaciones 5, 6 y 7:

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

19 PREMA, V., & UMA RAO, k. (2013). Time series decomposition model for accurate wind speed forecast. Bangalore, India: Springer

Nivel: (5)

Tendencia:  $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)(b_{t-1})$  (6)

Estacionalidad:  $S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$  (7)

$\alpha$  es la constante de suavizado de nivel (se encuentra entre 0 y 1).

$\beta$  es la constante de suavizado de tendencia (se encuentra entre 0 y 1).

$\gamma$  es la constante de suavizado estacional (se encuentra entre 0 y 1).

$L_t$  es la estimación del nivel de la serie en el tiempo  $t$ .

$Y_t$  es el valor real de la serie en el tiempo  $t$ .  $b_t$  es la estimación de la pendiente de la serie en el tiempo  $t$ .

$S_t$  es el componente estacional.

$s$  es la duración de la estacionalidad.

$m$  es el número de períodos por delante que se pronosticará.

$F_{t+m}$  es el pronóstico para  $m$  períodos por delante.

El pronóstico se obtiene del nivel, tendencia y componentes estacionales como en la ecuación. 8:

Pronóstico:  $F_{t+m} = L_t + b_{tm} + S_{t-s} + m$  (8)

### **Modelos De Descomposición.**

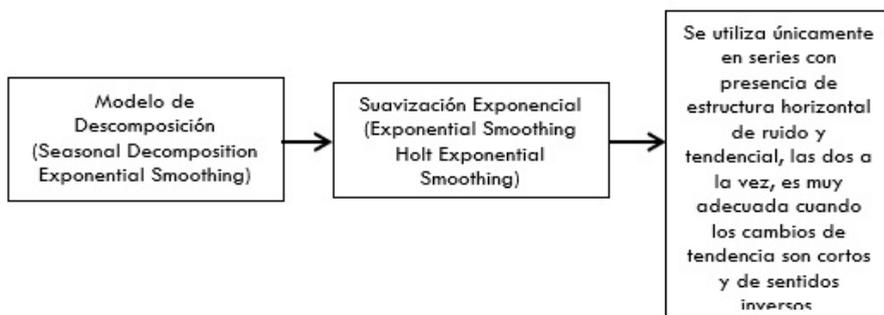
Tirkés, Güray, & Çelebi, (2017) han considerado que los métodos de descomposición se basan en un análisis de los componentes individuales de una serie de tiempo. En la descomposición, la fuerza de cada componente se estima por separado y luego sustituido en un modelo que explica el comportamiento de la serie de tiempo y es fácil entender. La descomposición de series temporales divide una serie de tiempo en cinco componentes: tendencia media, de largo alcance, estacionalidad, ciclo y aleatoriedad.<sup>20</sup>

Los modelos por descomposición según Mora (2007) se fundamentan en el propósito

20 TIRKES, G., GÜRAY, C., & ÇELEBI, N. (2017). Demand forecasting: a comparison between the holt-winters, trend analysis and decomposition models. Suppl.

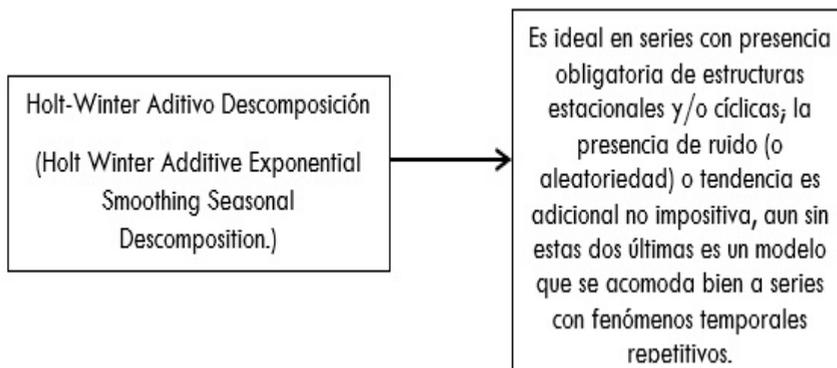
de descomponer completamente la estructura de la serie en subestructuras, considerándose para ello tres elementos: tendencia, ruido y fenómenos repetitivos temporales (Ciclicidad y Estacionalidad). (Figura 8 y 9).<sup>21</sup>

Figura 2. Modelos de suavización exponencial (Holt) y aplicación



Fuente: Pronostico de demanda e inventarios, Luis Alberto Mora, 2007

Figura 3. Modelo Holt-Winter y aplicación.



Fuente: Pronostico de demanda e inventarios, Luis Alberto Mora, 2007

21 MORA, A. G. (2007). Pronósticos de demanda e inventarios. Medellín: Editorial A M G.

### **Modelos Modernos A.r.i.m.a.**

De acuerdo con Mora, los modelos ARIMA, son más generales y teóricos que los de ajuste por tendencia, que los de suavización o que los de descomposición, son capaces de tratar cualquier patrón de datos y a la vez son aptos para establecer directamente un modelo estadístico de clase general que simule más adecuadamente la serie de datos temporales.<sup>22</sup>

Elamin & Fukushige, (2017) manifiestan que los modelos ARIMA (p, d, q) fueron desarrollados por Box y Jenkins (1970), y su enfoque para la identificación, estimación y diagnóstico se basa en el principio de parsimonia. Al identificar la especificación del modelo apropiado, se escudriñan las funciones de autocorrelación y autocorrelación parcial.<sup>23</sup>

De acuerdo con Gajowniczek & Zabkowski, (2017), los modelos ARIMA describen el modelo aproximado de secuencias de datos a lo largo del tiempo, asumiendo el término de retraso y el término de error aleatorio para explicar y predecir el resultado futuro con una cierta fórmula matemática. El análisis del promedio móvil integrado autorregresivo de Box-Jenkins (ARIMA) univariante se ha aplicado ampliamente a la predicción en muchos campos, incluidos problemas ambientales, médicos, comerciales y financieros, y de ingeniería.<sup>24</sup>

Petropoulos, Kourentzes, & Nikolopoulos, (2016) A pesar de la investigación significativa en la predicción de series de tiempo, el método ARIMA sigue siendo popular debido a su flexibilidad y buena precisión.<sup>25</sup>

Khashei & Hajirahimi, (2017) definen el modelo ARIMA como uno de los enfoques más utilizados para predecir el valor futuro de las series de tiempo extrayendo y modelando patrones lineales en los datos. Por lo tanto, el modelo clásico es adecuado para patrones lineales. En los modelos ARIMA, se asume que el valor futuro de una variable es una función lineal de los valores pasados y los términos de error.<sup>26</sup>

---

22 Ibid. Pág. 166

23 ELAMIN, N., & FUKUSHIGE, M. (3 de Agosto de 2017). Forecasting extreme seasonal tourism demand: the case of Rishiri Island in Japan. Japon: SPRINGER.

24 GAJOWNICZEK, K., & ZABKOWSKI, T. (8 de Octubre de 2017). Two-Stage Electricity Demand Modeling Using Machine Learning Algorithms. Polonia: ENERGIES.

25 PETROPOULOS, F., KOURENTZES, N., & NIKOLOPOULOS, K. (2016). Another look at estimators for intermittent demand. Reino Unido: ELSEVIER.

26 KHASHEI, M., & HAJIRAHIMI, Z. (2017). Performance evaluation of series and parallel strategies for financial time series forecasting. Isfahan, Ira: Springer.

$$y_t = u_t + \varphi_1 y_{t-1} + \dots + \varphi_p y_{t-p} - \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (9)$$

donde ( $y_t$ ) es el valor real en el tiempo  $t$  y  $\varepsilon_t$  es el ruido blanco, que se supone que se distribuye de forma independiente e idéntica con una media de cero y una varianza constante de  $\sigma^2$ .  $p$  y  $q$  son los números enteros de términos autorregresivos y promedio móvil en él. El modelo ARIMA y  $\varphi_i (i = 1, 2, \dots, p)$  y  $\theta_j (j = 1, 2, \dots, q)$  son los parámetros del modelo a ser estimados.

Khashei & Hajirahimi (2017) manifiestan que el procedimiento de modelado para los modelos ARIMA, que se basa en la metodología de Box-Jenkins, comprende tres pasos iterativos: identificación del modelo, estimación de parámetros y verificación de diagnóstico. En el paso de identificación, a menudo se requiere la transformación de datos para hacer estacionaria la serie temporal, que es una condición necesaria cuando se construye un modelo ARIMA para la predicción. Una serie temporal estacionaria se caracteriza por una constante media y una estructura de autocorrelación en el tiempo. Cuando las series temporales observadas presentan una tendencia y heterocedasticidad, la diferenciación y la transformación de potencia se aplican a los datos para eliminar la tendencia y estabilizar la varianza antes de que se pueda ajustar el modelo ARIMA. Una vez que se identifica un modelo tentativo, la estimación de los parámetros del modelo es directa. Los parámetros se estiman de modo que se minimice una medida general de errores, lo que se puede lograr utilizando un procedimiento de optimización no lineal. El paso final es la verificación de diagnóstico de la adecuación del modelo, que determina si se cumplen las suposiciones del modelo sobre errores en. Se pueden usar varias estadísticas de diagnóstico y diagramas residuales para examinar la bondad del ajuste de un modelo adoptado tentativamente a los datos históricos. Si el modelo se considera inadecuado, se identifica un nuevo modelo tentativo, que también está sujeto a la estimación de parámetros y la verificación del modelo. La información de diagnóstico puede ayudar a determinar modelo (s) alternativo (s). Este proceso de construcción de modelos de tres pasos generalmente se repite varias veces hasta que se identifica un modelo satisfactorio. El modelo final se usa para la predicción.<sup>27</sup>

Para Al-MUSAYLHA, M. S., Deo, R. C., ADAMOWSKIC, J. F., & LI, Y. (2017), el modelo ARIMA constituye un enfoque simplista pero popular aplicado para el pronóstico de series de tiempo. ARIMA fue popularizado por el trabajo de Box y Jenkins. Para desarrollar el

modelo ARIMA, se integran dos tipos de regresiones lineales: el autorregresivo (AR) y el pro

$$y_t = u_t + \varphi_1 y_{t-1} + \dots + \varphi_p y_{t-p} - \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

El modelo AR está escrito como:<sup>28</sup>

$$y_t = c + a_1 y_{t-1} + \dots + a_p y_{t-p} + u_t \quad (10)$$

donde  $a_1, \dots, a_p$  son los parámetros AR

$c$  es una constante

$p$  es el orden de AR,

$u_t$  es el ruido blanco.

Del mismo modo, el modelo MA puede escribirse

$$y_t = \mu + u_t + m_1 u_{t-1} + \dots + m_q u_{t-q} \quad (11)$$

donde  $m, \dots, m_q$  son los parámetros MA

$q$  es el orden de MA

$u_t, u_{t-1}, \dots, u_{t-q}$ , son los términos de ruido blanco (error), y  $\mu$  es la expectativa de  $y_t$ .

Cuando se integran estos modelos con los mismos datos de entrenamiento, el modelo ARIMA [ARIMA ( $p, q$ )] se convierte en:

$$y_t = c + a_1 y_{t-1} + \dots + a_p y_{t-p} + u_t + m_1 u_{t-1} + \dots + m_q u_{t-q} \quad (12)$$

donde  $p$  y  $q$  son los términos promedio autoregresivos y móviles, respectivamente.

La premisa básica de este modelo es que los datos de series temporales incorporan estacionariedad estadística, lo que implica que las propiedades estadísticas medidas, como la media, la varianza y la autocorrelación, permanecen constantes a lo largo del tiempo.

Para Mora (2007), la modelación bajo ARIMA, se basa en los siguientes pasos:<sup>29</sup>

28 Al-MUSAYLHA, M. S., Deo, R. C., ADAMOWSKIC, J. F., & LI, Y. (01 de Diciembre de 2017). Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia. Australia: ELSEVIER.

29 MORA, A. G. (2007). Pronósticos de demanda e inventarios. Medellín: Editorial A M G.

### ***Recorte De La Serie De Datos.***

La serie recorta máxima en el diez por ciento (10%) de sus datos siempre y cuando no pase de doce meses (o cuatro años, o doce semanas, o sesenta días, etc. (Dependiendo de la unidad de tiempo en el que se tengan los datos).

### ***Determinar El Mejor Modelo.***

El mejor modelo, es la fase de desarrollo y se realiza mediante la utilización de herramientas de tipo computacional, es decir software para realizar los pronósticos con cada uno de los modelos clásicos y los modernos.

### ***Preparación De La Tabla De Comparaciones.***

La tabla de comparaciones se elabora en una hoja de Excel y consiste en una tabla de cálculos donde se descargan los n pronósticos recortados en el paso anterior con el fin de comparar los resultados, y poder establecer un mecanismo de error cuadrático o similar con valor absoluto, que permite seleccionar los modelos que más se acerquen a los n datos reales recortados, con el fin de tomar los más opcionados y con estos realizar la prueba final de comparación con los dos últimos reales con los cuales se selecciona el mejor y con la serie completa se realiza el pronóstico final.

### ***Selección Del Mejor Modelo.***

La selección del mejor modelo se realiza para satisfacer la hipótesis, el recorte y en general el método, por lo cual se adopta como modelo, para realizar las previsiones requeridas para el corto plazo.

### ***Cálculo De Los Pronósticos.***

El cálculo de los pronósticos se realiza después de escoger el mejor modelo, y donde se deben tener presente los parámetros con los cuales fueron calculados.

HAN, y otros, 2013 consideran que el modelo ARIMA tiene varias ventajas sobre otros enfoques, como la media móvil, el suavizamiento exponencial, la red neuronal y, en particular, su capacidad de previsión y su información más rica sobre los cambios relacionados con el tiempo.<sup>30</sup>

### ***Pronóstico Mediante Redes Neuronales***

Los métodos anteriormente trazados se enmarcan en metodologías de pronóstico tradicionales ampliamente desarrolladas en la literatura especializada tales como aquellos basados en juicios de expertos que trasladan información de carácter cualitativo en estimaciones de carácter cuantitativo u otros que se subsumen de metodologías esencialmente cuantitativas, cobijando a los métodos de pronósticos causales, que asumen la existencia de relaciones de causalidad entre variables y los pronósticos en series temporales, que parten de la premisa de que la demanda puede ser explicada por el comportamiento de los valores retardados de la variable dependiente. Para la elaboración de algún modelo proyectivo convencional se asume el cumplimiento estricto de otras hipótesis, que, en caso de no cumplirse, ocasionan un detrimento en la estimación paramétrica y, por tanto, en la capacidad predictiva del modelo en cuestión.

En el contexto de la minería de datos y la inteligencia artificial, el modelo de redes neuronales es utilizado ordinariamente a razón de las múltiples ventajas que posee en contraposición a los métodos de suavizamiento y regresión que precisan del cumplimiento de ciertas hipótesis como: ausencia de multicolinealidad, no dependencia de perturbaciones aleatorias, estabilidad de la varianza del error de la variable respuesta, relación de linealidad entre variables, entre otros.

Una red neuronal es un sistema que permite establecer relaciones lineales y no lineales entre las salidas y las entradas. Se anotan como ventajas las siguientes: habilidad para aprender mediante la proporción de datos a la red como entrada, indicándole cuál es la salida (respuesta) esperada. Por otro lado, una Red Neuronal es capaz de crear su propia representación de la información sin necesidad de la intervención de un agente. Debido a que una Red Neuronal almacena la información de forma redundante, ésta responde apropiadamente aun si ocurren fallos, también es capaz de manejar cambios irrelevantes en la información de entrada, como señales con ruido u otros que podrían afectar el comportamiento de la variable a explicar. Dado que su estructura es paralela, permite obtener respuestas en tiempo real.

---

30 HAN, P., WANG, P., TIAN, M., ZHANG, S., LIU, J., & ZHU, D. (2013). Application of the ARIMA Models in Drought Forecasting Using the Standardized Precipitation Index. China: IFIP International Federation for Information Processing.

El funcionamiento de una red neuronal artificial está inspirado en el sistema nervioso del ser humano y le confiere características notables tales como capacidad de aprendizaje adaptativo, auto-organización, entre otras. Desde la óptica de la resolución de problemas, este tipo de modelo procesa la información en paralelo y a través de un proceso de aprendizaje es capaz de generalizar la información no disponible en el proceso de aprendizaje. La cantidad de entradas depende intrínsecamente de la calidad y cantidad de la información disponible para ser categorizada, a la vez que la cantidad de neuronas de salida equivale a las clases segregadas. Las unidades de una capa se conectan unidireccionalmente con las de la siguiente capa, sometiendo a sus salidas a la multiplicación por una ponderación particular para cada una de las conexiones (Villada, Muñoz, & García, 2012).<sup>31</sup>

### **Generalidades Sobre Las Redes Neuronales**

#### **Contraste Entre La Neurona Biológica Y La Neurona Artificial**

Las neuronas, a diferencia de las demás células poseen una amplia capacidad de comunicación. Las dendritas y el cuerpo celular receptan señales de entrada, y éste último se encarga de combinar e integrar para la emisión posterior de señales de salida. El axón por su parte se encarga de transmitir las a sus terminales, los cuales se encargan de distribuir la información a un subconjunto nuevo de neuronas. La sinapsis, que se define como la conexión entre dos neuronas es direccional y la información fluye hacia un sentido único. Las señales generadas a través de la neurona y que es transportada a lo largo del axón es de naturaleza eléctrica, mientras que la señal que se transmite entre los terminales del axón de una neurona y las dendritas de las neuronas posteriores es de tipo químico. Caicedo & López (2009)<sup>32</sup> establecen las siguientes similitudes directas entre la actividad de una neurona biológica y una artificial a nivel funcional (Sánchez Anzola, 2015)<sup>33</sup>.

Las neuronas reciben señales de entrada. Las neuronas están altamente conectadas con otras neuronas a partir de las cuales receptan un estímulo de cualquier evento que ocurre o de señales eléctricas con la información aprendida. Este proceso implica capacidad de procesamiento de información y realización de tareas de alta complejidad. Las señales pueden ser afectadas por las ponderaciones sinápticas por lo que

31 Villada, F.; Muñoz, N.; & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios de Valores. *Información Tecnológica*, 23(4), 11-20.

32 Caicedo, E.; & López, J. (2009). *Una Aproximación práctica a las Redes Neuronales Artificiales*. Cali: Universidad del Valle.

33 Sánchez Anzola, N. (2005). Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario. *ODEON* (9), 113-172.

la comunicación entre neuronas ocurre mediante sinapsis en el que los neurotransmisores, bloquean o dan vía libre a las señales que provienen de las otras neuronas. Las neuronas que envían la información son presinápticas y las neuronas que reciben la señal post-sináptica. Los elementos de proceso suman las entradas afectadas por las sinapsis. Las neuronas reciben señales eléctricas de otras neuronas con las que establecen contacto y estas señales actúan de modo acumulativo. En la neurona se transmite una señal de salida: si el total de la señal eléctrica que recibe una neurona es suficiente, se puede vencer el potencial de acción permitiendo que la neurona se active o que permanezca inactiva. La salida puede ir a múltiples neuronas: cuando se activa una neurona, esta se encuentra en capacidad de transmitir un impulso eléctrico a las otras neuronas con las cuales tiene contacto. El nuevo impulso actúa como entrada para otras neuronas o como estímulo en algún músculo.

Ya identificadas las características fundamentales de las neuronas biológicas es procedente describir algunas propiedades distintivas de las redes neuronales artificiales. Una red de este último tipo comprende una serie de modelos matemáticos y computacionales que se aproximan al funcionamiento de una red neuronal biológica y su campo de aplicación se hace extensivo en múltiples dominios de estudio. Las RNA pueden entenderse como un modelo artificial y simplificado del cerebro de los animales, sistema novedoso para procesamiento de la información y cuya unidad básica se fundamenta en la unidad del sistema nervioso, la neurona.

Entre los modelos neuronales más célebres se encuentran los perceptrones. Consisten en un conjunto de elementos computacionales simples unidos por arcos que llevan asociada una ponderación numérica que indica la significación de la información entrante a este arco. El MLP se reconoce por sus mejores resultados comparativo a otros modelos, optimizando la solución del problema de clasificación y de regresión, tomando como punto de partida múltiples casos disponibles.

Como extensión de estos modelos fundamentales se encuentra el Perceptron Multicapa, una red neuronal formada por múltiples capas y son capaces de sortear las limitaciones naturales del Perceptron simple. Por esto se incorpora a la topología de esta red una nueva capa denominada oculta, cuantas veces sea necesario (Coello Blanco, Casas, Pérez González, & Caballero Mota, 2015)<sup>34</sup>

---

34 Coello Blanco, L.; Casas, L.; Pérez González, O.; & Caballero Mora, Y. (2015). Redes neuronales artificiales en la producción de tecnología educativa para la enseñanza de la diagonalización. *Revista Academia y virtualidad*, 8(1), 12-20.

## ANTECEDENTES

1. JIMENEZ, Daniela Loreto. Análisis y pronósticos de demanda para telefonía móvil. Tesis de Magister en gestión de operaciones. Santiago: Universidad de Chile. Facultad de ciencias físicas y matemáticas departamento de ingeniería industrial, 2011. 159 p.

En el presente proyecto, sus autores describieron cómo mejorar los pronósticos de demanda y caracterizar la toma de decisiones de los clientes en base a según qué características toman sus decisiones de compra. Para ello, se realizó un estudio de demandas, en base a los datos aportados, cuyos resultados fueron estudiados mediante series de tiempo, análisis estadísticos y por medio de un modelo Log lineal. Se testearon así diversas hipótesis sobre el comportamiento de los consumidores ante distintas variables: influencia del precio y del producto ofertado y como estas influyen en la compra de equipos de telefonía móvil. Se detectó que es posible tomar acciones correctivas para pronósticos con un porcentaje importante de error, los cuales serán efectivos si se toman a corto plazo. Para diseñar el estudio, se sugirió determinar primero los distintos grupos de aparatos, los cuales fueron agregados a partir de características similares que se a distintos tipos de clientes.

2. ROSAS, José Andrés y CORTES, Emery Leandro. Propuesta de una metodología de planeación de la demanda y de los inventarios de medicamentos y dispositivos médicos de uso en pacientes hospitalizados en una Ips de cuarto nivel. Tesis de Magister en ingeniería industrial. Cali: Universidad ICESI. Facultad de Ingeniería, 2013. 98 p.

En el desarrollo de este trabajo los autores evidencian que a través de las referencias que realizan entre las diferentes instituciones prestadoras de salud de la región del Valle del Cauca que no se ha profundizado en el desarrollo de herramientas que les permitan a los planeadores o compradores mejorar el nivel de compras de medicamentos y dispositivos médicos versus la demanda de pacientes atendidos por el sin número de condiciones clínicas de los pacientes, esto ha llevado a que cada institución de salud desarrollo mecanismos y estrategias propias para garantizar las existencias de estos productos llevando en muchas ocasiones a la no prestación adecuada de servicio o en su defecto a pérdidas considerables de dinero por productos vencidos o que han quedado obsoletos. Se concluye que para obtener un adecuado esquema de planeación de la demanda de medicamentos y dispositivos médicos se debe tener en cuenta factores internos y factores externos

3. MACIAS, Gilberto German. "Metodología para calcular el pronóstico de la demanda y una medición de su precisión, en una empresa de autopartes: caso de estudio". Tesis de Maestría en ciencias con especialidad en administración. México D.F: Unidad profesional interdisciplinaria de investigación y ciencias sociales y administrativas, 2007. 131 p.

Macias, nos muestra en esta su tesis una metodología general para el cálculo del pronóstico de la demanda en las empresas del ramo de autopartes, para atacar la falta de consistencia en la manera de realizar el cálculo del pronóstico de la demanda y al mismo tiempo, otorgar al nivel directivo una solución mediante la búsqueda y prueba de nuevas técnicas, despertando la inquietud de utilizar algunas otras técnicas para anticipar su demanda. El trabajo lo abocó en una metodología basada en la técnica estadística Box-Jenkins de series de tiempo que ayude a los directivos de las empresas a conocer la demanda de autopartes de su organización que pudiera presentarse en el futuro, utilizando una herramienta más confiable que disminuya el error al momento de calcular el pronóstico y mejore su eficiencia, para que resulten mejores tomas de decisiones a la hora de realizar pedidos y de esta forma, se optimicen recursos al disminuir gastos de inventarios innecesarios y las posibles pérdidas de oportunidad de la empresa. En la investigación se enfocó exclusivamente a estudiar el tipo de demanda que se presenta en el mercado de repuesto, ya que debido a la diversidad en los tipos de organizaciones con las que se trabaja en el mercado de refacciones automotrices, es difícil sistematizar las solicitudes de los pedidos y por ende la determinación del tipo de demanda que presenta cada organización se vuelve más complicada. Por lo cual, la metodología que se propuso abarca todos aquellos artículos clasificados como A, dentro de una clasificación ABC, logrando con esto evaluar sólo aquellos productos de mayor peso en la organización, que contribuyan de manera importante a mejorar la precisión en el cálculo de su pronóstico de forma global e individual.

4. BERMÚDEZ ESCOBAR, Andrea & LONDOÑO OLARTE, Sebastián. Metodología para optimizar inventarios de producto terminado en una empresa, basado en estimación de demanda y minimización de costos. Trabajo de grado para optar al título de Ingeniero Industrial. Universidad Pontificia Bolivariana, Escuela de Ingeniería, Facultad de Ingeniería Industrial. Medellín, 2013. 101 P.

Bermúdez Escobar, evidencia en este trabajo de grado en una empresa de lácteos, los pasos para estimar la demanda de los productos, buscando proponer un esquema de inventario a un mejor costo. Parte de estimar modelos de pronóstico de demanda para tres productos elaborados, comparando entre algunos métodos clásicos y redes neuronales, con el fin de encontrar el método más eficiente y acertado para efectuar predicciones de ventas. Éstas son entradas para proponer un modelo de optimi-

zación de inventarios, que permita determinar una política adecuada para su manejo. Se describen y se utilizan los modelos de pronóstico: Suavización exponencial simple, Suavización exponencial Holt, modelos dinámicos y de Box-Jenkins, por medio de los programas estadísticos Statgraphics y R. Seguido a esto, se formula un modelo de red neuronal artificial (RNAs), para cada una de las series, usando el software MATLAB y se compara con el modelo clásico elegido. Se detalla el proceso de estimación de las RNA y se selecciona el modelo de pronóstico final. Por último, se realiza el modelo de optimización de inventarios, en el software LINGO, usando los pronósticos obtenidos de los modelos de RNAs, que resultaron los más eficientes. Para cumplir con el objetivo de proponer un esquema de pedidos y almacenamiento de inventarios a costo óptimo.

5. FRAUSTO ENRÍQUEZ, Jorge Humberto. Pronósticos de ventas para la administración estratégica de los recursos en una empresa del sector automotriz. Tesis que para optar el grado de maestro en Ciencias con especialidad en Ingeniería Industrial. Instituto Tecnológico y de estudios superiores de Monterrey campus estado de México. Atizapán de Zaragoza, México, Noviembre 2009. 100 p.

El autor Frausto, a partir de sus estudio y realización de esta investigación pretende generar un método que cumpla con las necesidades de la empresa y con las condiciones de demanda específicas del mercado que atiende, para generar los pronósticos de venta detallados para cada producto, tanto para el análisis de estrategias y políticas de inventarios, como para el estudio de capacidades y presupuestos de inversión. El objetivo particular es evaluar varios métodos de generación de pronósticos (entre ellos ARIMA) para la demanda en estudio, comparando sus resultados individuales y evaluando su costo de desarrollo contra el valor agregado que dan a los pronósticos. Igualmente se identificarán las limitantes en el uso de pronósticos y entendimiento sobre el utilizar una técnica de pronósticos inadecuada, para los procesos establecidos. Estos pronósticos generados, serán utilizados para el desarrollo de la estructura de toma de decisiones que incluyen puntos relativos al aprovisionamiento como son el cuándo y cuánto comprar, inclusive cuando y cuanto producir, además, puntos relativos a las inversiones y capacidades para determinar la capacidad necesaria tanto en instalaciones, maquinaria y mano de obra.

## **DESCRIPCIÓN DE LA PROBLEMÁTICA CASO DE ESTUDIO**

Es un trabajo visto desde el tipo de investigación proyectiva, para el cual se abordó a utilizar herramientas cualitativas y cuantitativas en la definición del planteamiento del problema y un análisis para solución de este. Primeramente, se procede a identificar el problema a partir de una Check List, para evaluar los porcentajes de cumplimiento en cuanto a algunas características de la planeación y control de la producción.

Se procede a realizar un Diagrama de Pareto en el área de Planeación de la empresa para evaluar las posibles variables que están afectando el buen desarrollo de esta y trabajar sobre ello para dar las mejoras. Identificada la variable problema, se realizó un Diagrama Causa-Efecto, para que de manera gráfica se relacionaran los aspectos que inciden en esta.

### ***Herramienta Para La Identificación Del Problema.***

Al entrar en una organización a analizar qué problemas encontrar, se debe tratar en lo más posible de ir depurando la información partiendo de lo general hasta llegar a lo particular para lo cual es necesario la utilización de herramientas como entrevistas, Check List, diagrama de barras, diagramas de Pareto y diagrama de causa-efecto entre otras herramientas ya sean cualitativas como cuantitativas para identificar la raíz de un problema.

### ***Identificación Del Problema.***

Se hicieron preguntas basadas en cómo se lleva a cabo el proceso de planeación, programación y control de la producción en la empresa con el fin de tener una vista preliminar del problema. Luego, se aplicó complementariamente un check List cuantitativo, siendo ésta la principal herramienta para la identificación del problema, en la cual se analizó el porcentaje de cumplimiento de las características detalladas y en qué rango del criterio de evaluación se encuentran (Tabla 1) y cuánto es su porcentaje de incumplimiento.

Tabla 1. Check List aplicada al proceso.

| MODULO       | N° | CARACTERÍSTICA   | SI | NO | N/A | EVALUACIÓN |    |    |   | PUNTAJE | % CUMPLIMIENTO |
|--------------|----|--|----|----|-----|------------|----|----|---|---------|----------------|
|              |    |  |    |    |     | E          | B  | R  | M |         |                |
| Planeación   | 1  | ¿cuentan con un método de proyección de la demanda?                                | x  |    |     | 0          | 0  | 0  | 0 | 0       | 0%             |
|              | 2  | ¿tienen algún método de planeación agregada?                                       | x  |    |     | 0          | 0  | 50 | 0 | 50      | 50%            |
|              | 3  | ¿realizan el plan de requerimiento de material "MRP"?                              | x  |    |     | 0          | 80 | 0  | 0 | 80      | 80%            |
|              | 4  | ¿realizan el plan maestro de producción "MPS"?                                     | x  |    |     | 0          | 0  | 50 | 0 | 50      | 50%            |
| Programación | 5  | ¿programan la producción?  | x  |    |     | 0          | 80 | 0  | 0 | 80      | 80%            |
|              | 6  | ¿cumple la empresa con las fechas de entregas pactadas?                            | x  |    |     | 0          | 80 | 0  | 0 | 80      | 80%            |
|              | 7  | ¿poseen un criterio bajo el cual producir?   | x  |    |     | 0          | 80 | 0  | 0 | 80      | 80%            |
| Control      | 8  | ¿Existen métodos de trabajo documentados?  | x  |    |     | 100        | 0  | 0  | 0 | 100     | 100%           |
|              | 9  | ¿Existen índices de seguimiento y medición para los procesos dentro de la empresa? | x  |    |     | 0          | 80 | 0  | 0 | 80      | 80%            |
|              | 10 | ¿tiene un buen comportamiento su capacidad frente a la demanda?                    | x  |    |     | 0          | 80 | 0  | 0 | 80      | 80%            |

Los criterios de puntuación están delimitados de acuerdo al rigor con que se cumple cada característica, es decir, si una característica se cumple, se analiza si esta es: Excelente, se asigna una puntuación de (100), si es bueno (80), regular (50) y malo (0). (Tabla 2).

**Tabla 2. Criterios de puntuación.**

| Criterios De Puntuación |         |
|-------------------------|---------|
| Calificación            |         |
| Nivel                   | Puntaje |
| Excelente ( E )         | 100     |
| Bueno ( B )             | 80      |
| Regular ( R )           | 50      |
| Malo ( M )              | 0       |

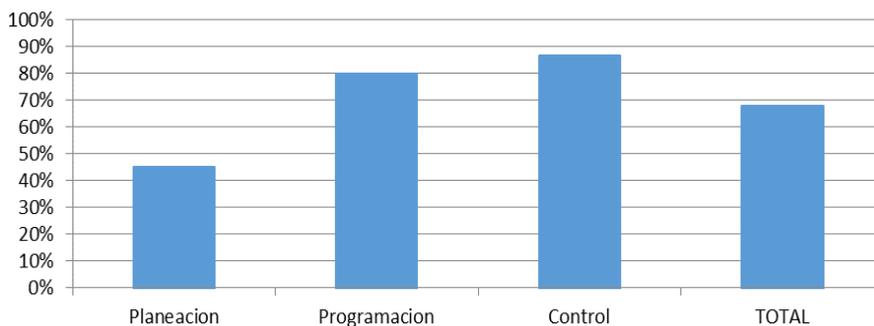
En la tabla 3 se muestra la totalidad de puntos (PT) y los puntos obtenidos por la empresa (PO) además de porcentaje de cumplimiento que tiene la empresa para cada módulo, siendo el de planeación el que menos presenta cumplimiento con un 45%. (Tabla 3).

**Tabla 3. Resumen evaluación empresa.**

| Modulo       | Pt   | Po  | %   |
|--------------|------|-----|-----|
| Planeación   | 400  | 180 | 45% |
| Programación | 300  | 240 | 80% |
| Control      | 300  | 260 | 87% |
| TOTAL        | 1000 | 680 | 68% |

La información detallada en la tabla 3. (Resumen evaluación empresa), se presenta de manera visual en el gráfico 4.

**Gráfico 4. Gráfico de barra de la situación actual de la empresa.**



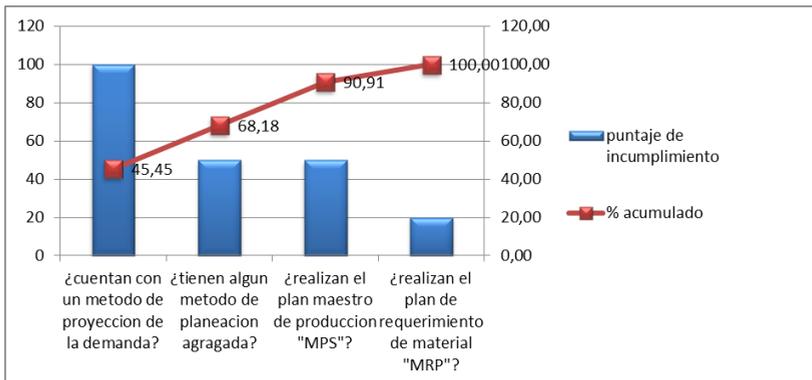
Se realizó un diagrama de Pareto para el módulo que presentó el menor porcentaje de cumplimiento, con el fin de priorizar entre las características que lo componen. Para efectos de llevar a cabo el diagrama de Pareto se invirtieron los datos de puntaje de cumplimiento de la check list, es decir, si el puntaje de cumplimiento es 80% se toma como dato su complementario que es el puntaje de incumplimiento, en este caso el 20%. (Tabla 4).

Tabla 4. Tabla de datos para diagrama de Pareto.

| Características                                       | Puntaje de incumplimiento | %     | % acumulado |
|---|---------------------------|-------|-------------|
| ¿Cuentan con un método de proyección de la demanda?   | 100                       | 45,45 | 45,45       |
| ¿Tienen algún método de planeación agregada?          | 50                        | 22,73 | 68,18       |
| ¿Realizan el plan maestro de producción "MPS"?        | 50                        | 22,73 | 90,91       |
| ¿Realizan el plan de requerimiento de material "MRP"? | 20                        | 9,09  | 100,00      |
| Totales   | 220                       | 100   |             |

En el siguiente gráfico se puede observar que la característica con más incumplimiento es la que está directamente enfocada al método de proyección de la demanda y es la que genera el 45,45% del incumplimiento.

Gráfico 5. Diagrama de Pareto para el módulo de planeación



### Análisis Del Problema.

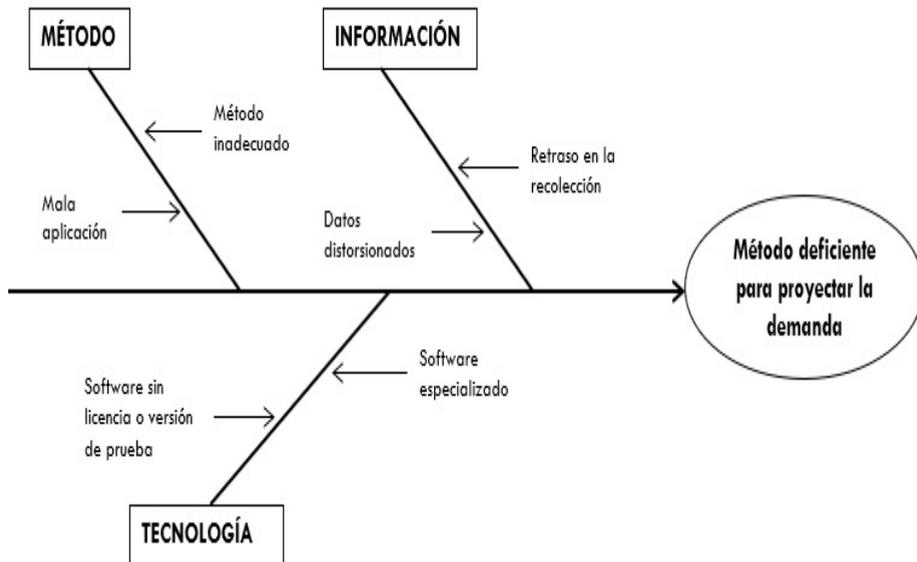
Para efectos de analizar el problema se llevó a cabo un diagrama de causa-efecto o diagrama de espinas (Figura 4), donde se muestran las causas de que el método de pronóstico sea deficiente en la empresa. En cuanto al método, materia prima (información) y maquinaria (tecnología).

La empresa no posee un método adecuado para realizar el pronóstico de la demanda, además no hay una persona especializada para realizar estos pronósticos.

La gestión de recolección de los datos que alimentan el método se retrasa e incluso se distorsionan estos mismos, haciendo que le método sea aún menos eficaz

La empresa no tiene software licenciados y especializados para realizar la proyección de la demanda.

Figura 4. Diagrama de Causa-Efecto



## RESULTADOS DE LA INVESTIGACIÓN

### Metodología Universal De Pronósticos En La Empresa

A continuación, se aplicará la metodología universal de pronósticos a la empresa con el fin de saber el método de pronóstico adecuado para su serie de tiempo.

#### Síntesis.

La empresa necesita un método de pronóstico de la demanda que se adecue a su serie de tiempo en la línea del producto, por lo que el método a utilizar es la metodología universal de pronósticos. Actualmente casi todas las compañías utilizan métodos de pronósticos con diferentes fines, pero el más común se da en la demanda, ya que es el primer paso para llevar a cabo la planeación de la producción.

Tabla 5. Datos: ventas del año 2010 hasta el 2017 del producto

| Relación de ventas año 2010 vs 2011 |      |     |     |     |     |     |     |     |     |     |     |     |       |
|-------------------------------------|------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-------|
| AÑO                                 | ENE  | FEB | MAR | ABR | MAY | JUN | JUL | AGO | SEP | OCT | NOV | DIC | TOTAL |
| 2010                                | 260  | 189 | 289 | 322 | 355 | 298 | 281 | 307 | 345 | 286 | 287 | 365 | 3584  |
| 2011                                | 288  | 294 | 312 | 391 | 382 | 371 | 315 | 322 | 400 | 408 | 385 | 361 | 4229  |
| Diferencia                          | 28   | 105 | 23  | 69  | 27  | 73  | 34  | 15  | 55  | 122 | 98  | -4  | 645   |
| Variación                           | 11%  | 56% | 8%  | 21% | 8%  | 24% | 12% | 5%  | 16% | 43% | 34% | -1% | 18%   |
| Relación de ventas año 2011 vs 2012 |      |     |     |     |     |     |     |     |     |     |     |     |       |
| AÑO                                 | ENE  | FEB | MAR | ABR | MAY | JUN | JUL | AGO | SEP | OCT | NOV | DIC | TOTAL |
| 2010                                | 288  | 294 | 312 | 391 | 382 | 371 | 315 | 322 | 400 | 408 | 385 | 361 | 4229  |
| 2011                                | 377  | 316 | 411 | 431 | 397 | 403 | 381 | 345 | 367 | 382 | 401 | 388 | 4599  |
| Diferencia                          | 89   | 22  | 99  | 40  | 15  | 32  | 66  | 23  | -33 | -26 | 16  | 27  | 370   |
| Variación                           | 31%  | 7%  | 32% | 10% | 4%  | 9%  | 21% | 7%  | -8% | -6% | 4%  | 7%  | 9%    |
| Relación de ventas año 2012 vs 2013 |      |     |     |     |     |     |     |     |     |     |     |     |       |
| AÑO                                 | ENE  | FEB | MAR | ABR | MAY | JUN | JUL | AGO | SEP | OCT | NOV | DIC | TOTAL |
| 2010                                | 377  | 316 | 411 | 431 | 397 | 403 | 381 | 345 | 367 | 382 | 401 | 388 | 4599  |
| 2011                                | 299  | 333 | 391 | 414 | 428 | 406 | 439 | 478 | 435 | 502 | 421 | 398 | 4944  |
| Dif                                 | -78  | 17  | -20 | -17 | 31  | 3   | 58  | 133 | 68  | 120 | 20  | 10  | 345   |
| Variación                           | -21% | 5%  | -5% | -4% | 8%  | 1%  | 15% | 39% | 19% | 31% | 5%  | 3%  | 8%    |
| Relación de ventas año 2013 vs 2014 |      |     |     |     |     |     |     |     |     |     |     |     |       |
| AÑO                                 | ENE  | FEB | MAR | ABR | MAY | JUN | JUL | AGO | SEP | OCT | NOV | DIC | TOTAL |

| 2010                                | 299 | 333 | 391 | 414  | 428 | 406 | 439 | 478 | 435 | 502 | 421 | 398 | 4944  |
|-------------------------------------|-----|-----|-----|------|-----|-----|-----|-----|-----|-----|-----|-----|-------|
| 2011                                | 513 | 485 | 468 | 399  | 402 | 521 | 478 | 551 | 586 | 611 | 555 | 606 | 6175  |
| Dif                                 | 214 | 152 | 77  | -15  | -26 | 115 | 39  | 73  | 151 | 109 | 134 | 208 | 1231  |
| Variación                           | 72% | 48% | 20% | -4%  | -6% | 28% | 9%  | 15% | 35% | 22% | 32% | 52% | 25%   |
| Relación de ventas año 2014 vs 2015 |     |     |     |      |     |     |     |     |     |     |     |     |       |
| AÑO                                 | ENE | FEB | MAR | ABR  | MAY | JUN | JUL | AGO | SEP | OCT | NOV | DIC | TOTAL |
| 2010                                | 513 | 485 | 468 | 399  | 402 | 521 | 478 | 551 | 586 | 611 | 555 | 606 | 6175  |
| 2011                                | 644 | 482 | 709 | 688  | 615 | 584 | 473 | 717 | 600 | 715 | 574 | 751 | 7552  |
| Dif                                 | 131 | -3  | 241 | 289  | 213 | 63  | -5  | 166 | 14  | 104 | 19  | 145 | 1377  |
| Variación                           | 26% | -1% | 51% | 72%  | 53% | 12% | -1% | 30% | 2%  | 17% | 3%  | 24% | 22%   |
| Relación de ventas año 2015 vs 2016 |     |     |     |      |     |     |     |     |     |     |     |     |       |
| AÑO                                 | ENE | FEB | MAR | ABR  | MAY | JUN | JUL | AGO | SEP | OCT | NOV | DIC | TOTAL |
| 2010                                | 644 | 482 | 709 | 688  | 615 | 584 | 473 | 717 | 600 | 715 | 574 | 751 | 7552  |
| 2011                                | 634 | 586 | 735 | 615  | 593 | 605 | 645 | 661 | 633 | 692 | 602 | 790 | 7791  |
| Dif                                 | -10 | 104 | 26  | -73  | -22 | 21  | 172 | -56 | 33  | -23 | 28  | 39  | 239   |
| Variación                           | -2% | 22% | 4%  | -11% | -4% | 4%  | 36% | -8% | 6%  | -3% | 5%  | 5%  | 3%    |
| Relación de ventas año 2016 vs 2017 |     |     |     |      |     |     |     |     |     |     |     |     |       |
| AÑO                                 | ENE | FEB | MAR | ABR  | MAY | JUN | JUL | AGO | SEP | OCT | NOV | DIC | TOTAL |
| 2010                                | 634 | 586 | 735 | 615  | 593 | 605 | 645 | 661 | 633 | 692 | 602 | 790 | 7791  |
| 2011                                | 675 | 761 | 788 | 783  | 758 |     |     |     |     |     |     |     |       |
| Dif                                 | 41  | 175 | 53  | 168  | 165 |     |     |     |     |     |     |     |       |
| Variación                           | 6%  | 30% | 7%  | 27%  | 28% |     |     |     |     |     |     |     |       |

Fuente: Tomado de la Empresa

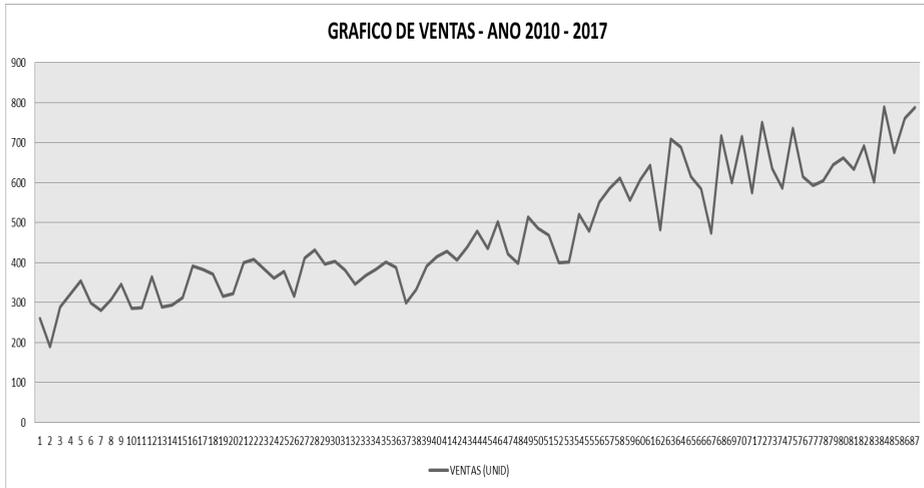
### **Analisis Previo De La Serie De Tiempo**

En este numeral se analiza en detalle que tipo(s) de estructura posee la serie de tiempo

### **Análisis De Estructura Vertical.**

El análisis de estructura vertical permite dejar en evidencia si existen cambios de nivel en la serie y de ser así, es necesario decidir en qué punto se debe recortar con la finalidad de evitar distorsión o un alto error de pronóstico. (Grafico 6).

**Gráfico 6. Ventas del año 2010 hasta el 2017**



**Fuente: autores**

Al analizar la gráfica 6, no se observa un cambio marcado de nivel en la serie, por lo que a simple vista se puede decir que la serie esta apta para pronosticar, pero antes es necesario hacer un análisis cuantitativo más a fondo como lo es el de media y desviación estándar. En esta serie se logra apreciar un comportamiento con tendencia ascendente, que deberá ser evaluado. (Tabla 6).

**Tabla 6. Análisis de media y desviación estándar**

|                     |            |
|---------------------|------------|
| Media               | 472,390805 |
| Desviación Estándar | 147,460232 |
| Desv. Est./media    | 31,22%     |

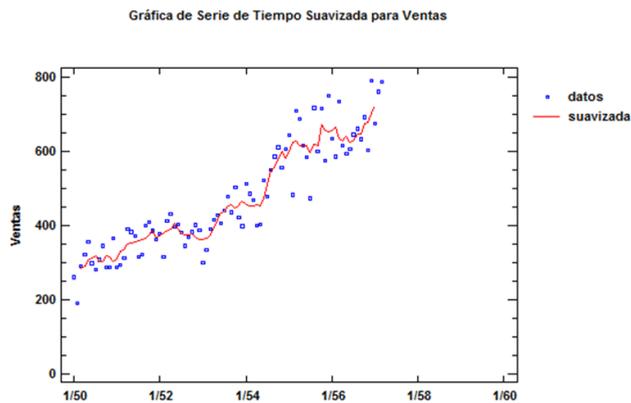
**Fuente: autores.**

En el análisis de media y desviación estándar de la serie, se observa que la relación entre estas mismas es mucho menor al 50%. Acorde con Luis Mora, su experiencia le permite inferir que series de tiempo con unos valores inferiores a 50% en el coeficiente de variación no generan cambios de nivel que afecten el pronóstico, por una alta variabilidad.

### **Análisis De Estructura Horizontal De Ruido O Aleatoriedad.**

El criterio para determinar la existencia de ruido o aleatoriedad es través de la suavización de la serie temporal, método con el cual se puede minimizar la desviación estándar, para evidenciar comportamientos en la serie de tiempo (Gráfico 7).

**Gráfico 7. Serie de ventas suavizadas**



**Fuente: autores**

En las siguientes gráficas se nota de forma muy clara que los puntos originales están distantes de la línea de suavización, con lo cual se puede afirmar, sin ninguna duda que la serie original presenta niveles de ruido o aleatoriedad.

Ya que el método anterior es netamente visual, se debe confirmar si existe ruido o aleatoriedad, realizando la verificación de ruido por pruebas estadísticas de rachas.

Prueba de Aleatoriedad de Ventas

(1) Corridas arriba o debajo de la mediana

Mediana= 421,0

Número de corrida arriba o abajo de la mediana = 10

Número esperado de corridas = 44,0

Estadístico z para muestras grandes = 7,26767

Valor – P = 3, 68483E-13

(2) Corridas arriba y abajo

Número de corrida arriba y abajo = 50

Número esperado de corridas = 57,6667

Estadístico z para muestras grandes = 1,84158

Valor – P = 0,0655363

(3) Prueba Box-Pierce

Prueba basada en las primeras 24 autocorrelaciones

Estadístico de prueba para muestras grandes = 612,01

Valor – P = 0,0

Se ha realizado tres pruebas para determinar si la serie de tiempo ventas es una secuencia aleatoria de números, o no. Una serie de tiempo de número aleatorio a menudo es llamada ruido blanco ya que contiene una contribución igual a varias frecuencias. La primera prueba cuenta el número de veces que la secuencia estuvo arriba o debajo de la mediana. El número de tales corridas es igual a 10, comparado con un valor esperado de 44,0 si la secuencia fuera aleatoria. Puesto que el valor-P para esta prueba es menor a 0,05, se puede rechazar la hipótesis de que la serie es aleatoria, con un nivel de confianza del 95,0%. La segunda prueba cuenta el número de veces que la secuencia ascendió o descendió. El número de tales corridas es igual a 50, comparado con un valor esperado de 57,6667 si la secuencia fuera aleatoria. Puesto que el valor-P para esta prueba es mayor o igual que 0,05, no se puede rechazar la hipótesis de que la serie es aleatoria, con un nivel de confianza del 95,0% o mayor. La tercera prueba está basada en la suma de cuadrados de los primeros 24 coeficientes de autocorrelación. Puesto que el valor-P para esta prueba es menor que 0,05, se puede rechazar la hipótesis de que la serie es aleatoria, con un nivel de confianza del 95,0%. Puesto que las tres pruebas son sensibles a diferentes tipos de desviaciones de un comportamiento de un comportamiento aleatorio, el no pasar cualquiera sugiere que la serie de tiempo pudiera no ser completamente aleatoria.

Puesto que en la primera prueba el valor-p es menor a 0,05, se puede rechazar la hipótesis de que la serie sea aleatoria con un nivel de confianza del 95%.

Para la segunda prueba el valor-p es mayor que 0,05, no se puede rechazar la hipótesis de que la serie es aleatoria con un nivel de confianza del 95%.

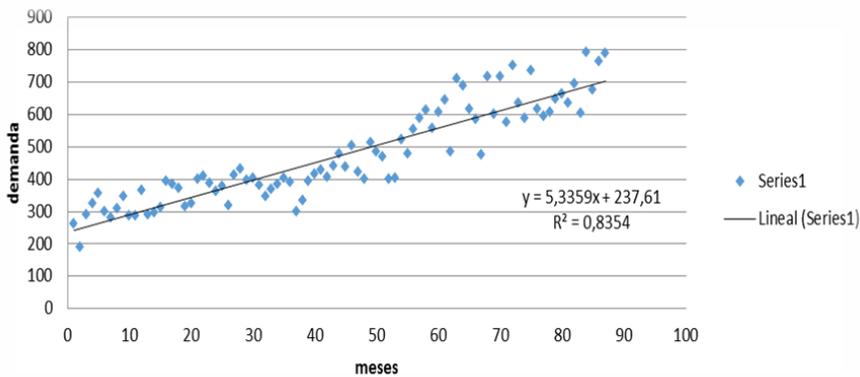
En la tercera prueba el valor-p es menor a 0,05, se puede rechazar la hipótesis de que la serie sea aleatoria con un nivel de confianza del 95%.

Las tres pruebas son sensibles a diferentes tipos de desviación de un componente aleatorio, el no pasar cualquiera de estas sugiere que la serie pudiera no ser completamente aleatoria.

### **Análisis De Estructura Tendencial.**

Este tipo de series presentan un incremento o disminución en su pendiente a través del tiempo, se puede detectar visualmente y por la aplicación de un ajuste por tendencia lineal. (Gráfico 8).

**Gráfico 8. Análisis de estructura tendencial. (Diagrama de dispersión)**

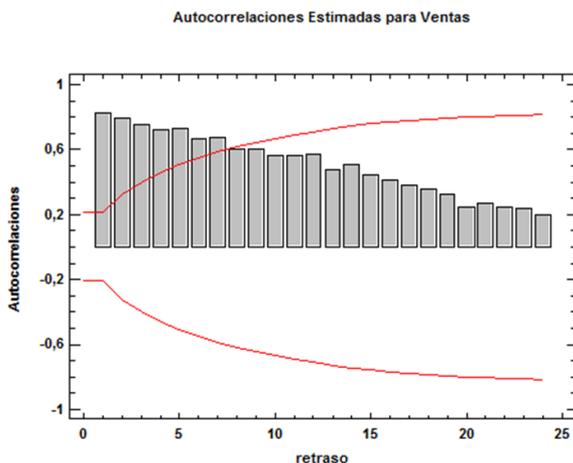


**Fuente: autores**

La serie posee tendencia ya que tiene valor de la pendiente (5,33) y el coeficiente  $r^2$  es 0,83 (83,54%) relativamente cercano al 85%, implicando que el modelo lineal es adecuado para representar la serie de datos.

Con fines de realizar un análisis mucho más completo y apoyar los resultados del gráfico 8, se realiza el análisis por coeficientes de autocorrelación. (Gráfico 9).

Gráfico 9. Análisis por coeficientes de autocorrelación



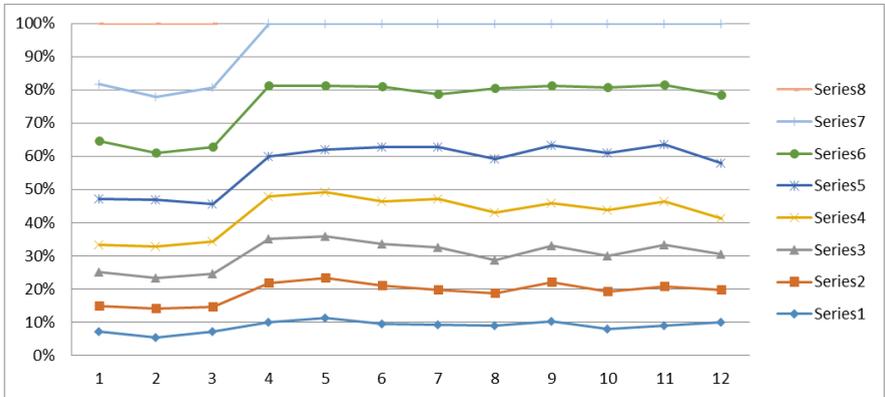
Fuente: autores

Los datos están por fuera de los límites, quiere decir que hay autocorrelación entre los datos. Lo que confirma la presencia de tendencia ya que se verifica la no independencia mutua de los datos, que se encuentran correlacionados y sus coeficientes son significativamente diferentes de cero.

### **Análisis De Estructura Estacional Y/O Cíclica.**

Son series que poseen estructuras que se repiten a través del tiempo y que son influenciadas por factores estacionales o cíclicos. Las series con comportamiento estacional presentan una repetición iterativa inferior a doce meses, mientras que las cíclicas una superior a un año, ejemplos típicos de series con comportamiento estacional son los fenómenos climáticos, como el verano o el invierno, la demanda de objetos para navidad, la utilización de servicios de playa o descanso en periodos de vacaciones, en general son fenómenos que se repiten en el lapso de un tiempo de un año. Cuando los eventos que se manifiestan como valores repetitivos en frecuencias superiores a un año, se asigna a este comportamiento una estructura cíclica. (Gráfico 10).

**Gráfico 10. Estructura estacional**

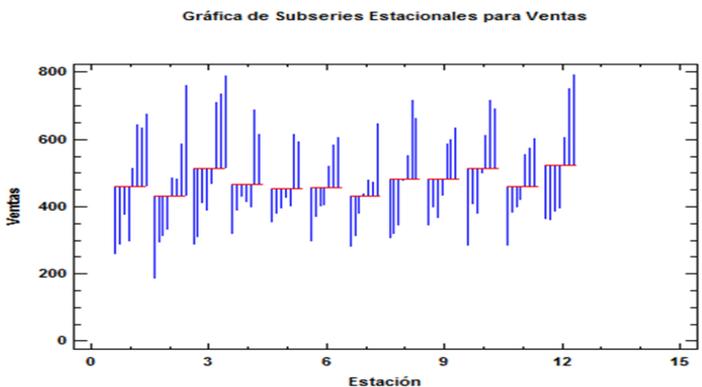


Fuente: autores

La serie objeto de estudio posee estacionalidad, se puede observar en el anterior gráfico debido a que en ninguno de los puntos se interceptan las líneas, pero también es evidente que las líneas no son completamente paralelas por lo cual la serie no es completamente estacional.

Se deben evaluar pictóricamente cada uno de los íconos y la distribución de cada uno de ellos, a través de un pictograma de subseries estacionales. En ella se puede evidencia que no hay una similitud en ellas que permite inferir estacionalidad de manera concluyente (Gráfico 11).

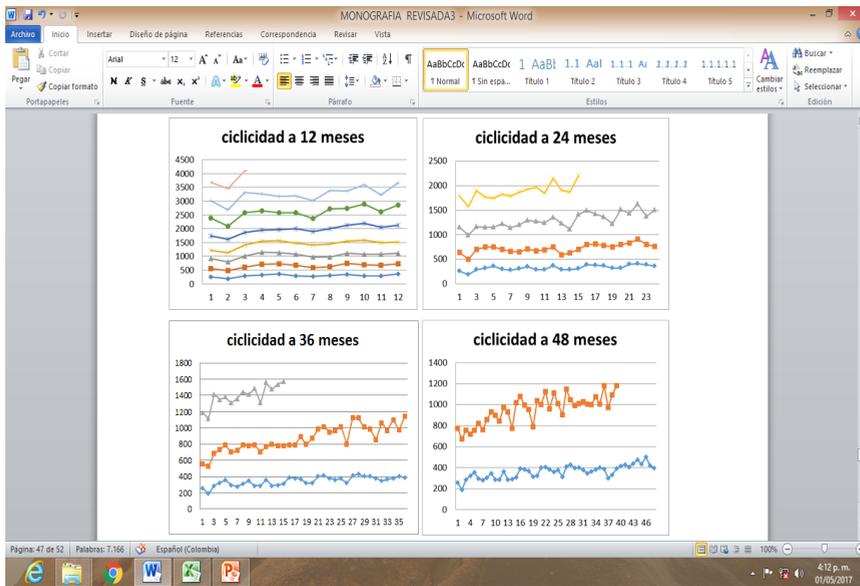
**Gráfico 11. Pictograma de subseries estacionales**



Fuente: autores

Posteriormente se realiza el análisis de estructura cíclica a 24,36 y 48 meses, donde los comportamientos esperados deben ser paralelismo y no cruce de líneas graficadas. (Gráfico 12).

Gráfico 12. Estructura Cíclica



Fuente: autores

La serie tiene Ciclicidad intermedia, ya que no se intercepta en ninguna de las gráficas con diferentes temporalidades, pero al igual no son completamente paralelas. La más cercana es una ciclicidad a 24 meses., que muestra un comportamiento más acorde a este patrón esperado. El análisis a 36 meses hay puntos en los cuales se pierde el paralelismo del patrón evaluado, así como en 48 meses, por lo cual se descartan como estructuras válidas.

### **Hipotesis Y Postulación De Modelos.**

Se resumen las características y estructuras de la serie encontradas en la serie de tiempo de la empresa objeto de estudio en la línea del producto seleccionada. La cual tiene como objeto brindar el consolidado de la información procesada, para facilitar la identificación del modelo de pronóstico apropiado. (Tabla 7).

**Tabla 7. Síntesis de análisis previo**

| Síntesis De Analisis Previo   | Alto | Medio | Bajo | Muy Leve | Inexistente |
|-------------------------------|------|-------|------|----------|-------------|
| Estructura De Nivel           |      |       |      |          | X           |
| Estructura Horizontal (Ruido) |      |       |      | X        |             |
| Estructura Tendencial         | X    |       |      |          |             |
| Estructura Estacional         |      |       |      | X        |             |
| Estructura Cíclica            |      |       |      | X        |             |
| Irregularidad                 |      |       |      |          | X           |
| Fenómenos Exógenos            |      |       |      |          | X           |
| Existencia De Patrón Adecuado |      | X     |      |          |             |

**Fuente: autores**

Según la síntesis de análisis previo, el mejor modelo clásico de pronósticos que se le puede aplicar a la serie es el de tendencia lineal, debido a que la estructura más marcada en la serie es la tendencia y la presencia de ruido es muy leve casi que inexistente al igual que la estacionalidad y ciclicidad, pero para efectos de un análisis más profundo se realiza la comparación de todos los modelos mediante el software Statgraphics, con los siguientes modelos propuestos, con su respectiva ecuación que lo modela:

#### Modelos

- (A) Tendencia línea =  $5,60637 + 0,0114562t$
- (B) Tendencia cuadrática =  $5,62347 + 0,0103037t + 0,000013096 t^2$
- (X) Tendencia exponencial =  $\exp(1,72617 + 0,00187637t)$
- (Δ) tendencia curtva-S =  $\exp(1,82073 + -0,206765 t)$
- (E) Promedio móvil simple de 2 términos
- (Φ) Suavización exponencial simple con alfa = 0,401

Estos seis modelos se sintetizan en la Tabla 8, donde se comparan: RMSE: Root Mean Squared Error (Raíz del Cuadrado Medio del Error), RUNS: Prueba corridas excesivas arriba y abajo, RUNM: Prueba corridas excesivas arriba y debajo de la mediana, AUTO: Prueba de Box-Pierce para autocorrelación excesiva, MEDIA: Prueba para diferencia en medias entre la 1ª mitad y la 2ª mitad y VAR: Prueba para diferencia en varianza entre la 1ª mitad y la 2ª mitad.

**Tabla 8. Comparación de modelos clásicos.**

| Modelo | Rmse    | Mae     | Mape    | Me      | Mpe       | Aic     | Hqc     | Sbic    |
|--------|---------|---------|---------|---------|-----------|---------|---------|---------|
| (A)    | 55,7676 | 41,3188 | 8,93594 | 2,79997 | -0,595847 | 8,34124 | 8,48961 | 8,70971 |
| (B)    | 56,2402 | 41,475  | 8,94471 | 2,66894 | -0,592502 | 8,3811  | 8,54089 | 8,77791 |
| (C)    | 55,8562 | 41,4416 | 8,9377  | 3,14341 | -0,494823 | 8,34441 | 8,49278 | 8,71288 |
| (D)    | 139,645 | 109,476 | 23,271  | 20,3817 | -2,83711  | 10,1771 | 10,3254 | 10,5455 |
| (E)    | 60,7187 | 44,1172 | 9,47166 | 10,8142 | 1,48015   | 8,48836 | 8,62532 | 8,82849 |
| (F)    | 58,642  | 42,9439 | 9,17779 | 15,7924 | 2,36583   | 8,41876 | 8,55572 | 8,75889 |

**Periodo de estimación**

| Modelo | Rmse    | Runs | Runm | Auto | Media | Var |
|--------|---------|------|------|------|-------|-----|
| (A)    | 55,7676 | OK   | OK   | ***  | OK    | OK  |
| (B)    | 56,2402 | OK   | OK   | ***  | OK    | OK  |
| (C)    | 55,8562 | OK   | OK   | ***  | OK    | OK  |
| (D)    | 139,645 | OK   | ***  | ***  | ***   | OK  |
| (E)    | 60,7187 | OK   | OK   | **   | OK    | OK  |
| (F)    | 58,642  | OK   | OK   | *    | OK    | OK  |

**Fuente: autores**

RMSE: Root Mean Squared Error (Raíz del Cuadrado Medio del Error)

RUNS: Prueba corridas excesivas arriba y abajo

RUNM: Prueba corridas excesivas arriba y debajo de la mediana

AUTO: Prueba de Box-Pierce para autocorrelación excesiva

MEDIA: Prueba para diferencia en medias entre la 1ª mitad y la 2ª mitad

VAR: Prueba para diferencia en varianza entre la 1ª mitad y la 2ª mitad

OK: no significativo ( $p \geq 0,05$ )



| Modelo | Rmse    | Runs | Runm | Auto | Media | Var |
|--------|---------|------|------|------|-------|-----|
| (A)    | 52,7845 | OK   | OK   | OK   | OK    | **  |
| (B)    | 52,6001 | OK   | OK   | OK   | OK    | **  |
| (C)    | 53,1714 | OK   | OK   | OK   | OK    | **  |
| (D)    | 53,2259 | OK   | OK   | OK   | OK    | **  |
| (E)    | 52,6994 | OK   | OK   | OK   | OK    | **  |

Fuente: autores

Todos los modelos logran pasar 4 de las 5 pruebas y tienen un mismo nivel significativo en la de VAR, sin embargo, el modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup> tiene menor error en las pruebas AIC, HGC y SBIC, por lo que se toma como el modelo que más se ajusta a la serie.

### **Pronósticos A Partir De Modelo De Regresión Lineal Y A.R.I.M.A**

A continuación se calculan los pronósticos con los modelos que más se ajustan a la serie, en este caso (tendencia lineal =  $5,60637 + 0,0114562 t$ ). (Tabla 10) y modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup>. (Tabla 10). Para efectos de análisis los pronósticos se realizaron con datos históricos de 6 años y 3 meses, dejando dos meses de datos históricos para comparar estos datos reales con sus respectivos pronósticos, en los periodos 4 y 5.

Se observa en la tabla 11, el pronóstico (778 redondeado de 777,579) para el periodo 4 (abril) del año 2017, Hay que tener en cuenta que lo más recomendable es solo tomar el primer pronóstico planteado. Es decir, siempre pronosticar a partir de este.

Tabla 10. Pronostico con Tendencia lineal =  $5, 60637 + 0, 0114562 t$  (Abril de 2017).

| Periodo | Pronóstico | Límite en 95,0% |          |
|---------|------------|-----------------|----------|
|         |            | Inferior        | Superior |
| 4/57    | 777,579    | 620,932         | 973,743  |
| 5/57    | 748,076    | 598,283         | 935,374  |
| 6/57    | 769,683    | 615,101         | 963,114  |
| 7/57    | 720,026    | 576,83          | 898,77   |
| 8/57    | 794,541    | 634,545         | 994,878  |
| 9/57    | 812,335    | 648,401         | 1017,72  |
| 10/57   | 855,04     | 681,446         | 1072,86  |
| 11/57   | 784,933    | 627,492         | 981,876  |

Fuente: autores

En la tabla 11 se observa el pronóstico de 749 redondeado a partir de 748,64 para el periodo 5(mayo) del año 2017, calculado a partir del periodo 4.

**Tabla 11. Pronostico con Tendencia lineal = 5, 60637 + 0, 0114562t (A partir de mayo de 2017).**

| Periodo | Pronóstico | Límite en 95,0% |          |
|---------|------------|-----------------|----------|
|         |            | Inferior        | Superior |
| 5/57    | 748,64     | 599,657         | 934,639  |
| 6/57    | 770,269    | 616,526         | 962,352  |
| 7/57    | 720,573    | 578,16          | 898,065  |
| 8/57    | 795,156    | 636,036         | 994,085  |
| 9/57    | 812,97     | 649,937         | 1016,9   |
| 10/57   | 850,751    | 679,248         | 1065,56  |
| 11/57   | 785,551    | 628,985         | 981,089  |
| 12/57   | 852,823    | 681,113         | 1067,82  |

**Fuente: autores**

De igual forma se sintetiza el pronóstico planteado con modelos autorregresivos, a partir del modelo ARIMA (0, 1, 1) x (1, 0, 1)<sub>12</sub>, identificado como el más apropiado para el pronóstico. Se observa el pronóstico para el mes de abril de 2017 en la tabla 12, con 786 unidades aproximadas a partir de 785,293 unidades. A partir de este pronóstico se realiza el correspondiente al mes de mayo de 2017, como se detalla en la tabla 13.

**Tabla12. Pronóstico con modelo (A) ARIMA (0,1,1) x (1,0,1)<sub>12</sub> (abril de 2017)**

| Periodo | Pronóstico | Límite en 95,0% |          |
|---------|------------|-----------------|----------|
|         |            | Inferior        | Superior |
| 4/57    | 785,293    | 679,451         | 891,135  |
| 5/57    | 765,978    | 656,553         | 875,403  |
| 6/57    | 769,687    | 656,793         | 882,581  |
| 7/57    | 738,906    | 622,646         | 855,166  |
| 8/57    | 814,29     | 694,76          | 933,821  |
| 9/57    | 803,921    | 681,207         | 926,636  |
| 10/57   | 852,234    | 726,417         | 978,052  |
| 11/57   | 775,326    | 646,48          | 904,173  |

**Fuente: autores**

**Tabla 13. Pronostico con modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup> (mayo de 2017).**

| Periodo | Pronóstico | Límite en 95,0% |          |
|---------|------------|-----------------|----------|
|         |            | Inferior        | Superior |
| 5/57    | 761,127    | 656,047         | 866,208  |
| 6/57    | 764,711    | 655,102         | 874,319  |
| 7/57    | 733,684    | 620,554         | 846,814  |
| 8/57    | 809,495    | 692,95          | 926,039  |
| 9/57    | 799,166    | 679,304         | 919,028  |
| 10/57   | 884,043    | 760,952         | 1007,13  |
| 11/57   | 755,014    | 628,778         | 881,25   |
| 12/57   | 922,414    | 793,109         | 1051,72  |

**Fuente: autores**

Tomando como base el pronóstico para el periodo 4 (abril) del año 2017, es posible afirmar que el modelo más acertado para la serie de tiempo de ventas en la empresa en objeto de estudio es el modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup>, presentado por el software Statgraphics, ya que éste comparado con el modelo de tendencia lineal está por encima en las 5 pruebas clave, y tiene menores errores, además comparando los pronósticos de los meses de abril y mayo de 2017 con los datos reales de esos mismos periodos para saber cuál es el desfase de cada modelo se puede analizar, que el modelo de Tendencia lineal = 5, 60637 + 0, 0114562 t para el mes de abril obtuvo 778 ventas pronosticadas y el dato real fue 783 ventas resultando un desfase de 5 unidades, mientras que el modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup> obtuvo 786 ventas pronosticadas y el dato real fue 783 ventas resultando un desfase de 3 unidades, así mismo el modelo de Tendencia lineal = 5, 60637 + 0, 0114562 t para el mes de mayo obtuvo 749 ventas pronosticadas y el dato real fue 758 ventas resultando un desfase de 9 unidades, mientras que el modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup> obtuvo 762 ventas pronosticadas y el dato real fue 758 ventas resultando un desfase de 4 unidades. Al analizar estas unidades desfasadas se reafirma que el modelo más acertado es el modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup>.

Con el claro objetivo de resaltar el beneficio que de la empresa al aplicar el método propuesto como el más acertado modelo ((A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup>), se realizó un análisis de costos (Tabla 13) basados en los mismos suministrados por la empresa (Anexo C).

**Tabla 13. Análisis de costos**

| ANÁLISIS DE COSTOS  |         |            |           |           | Costo de ordenes atrasada | Costo de almacenamiento | TOTAL        |
|---|---------|------------|-----------|-----------|---------------------------|-------------------------|--------------|
|   | Mes/Año | Pronóstico | Dato real | Desfasado | \$1.042.000               | \$889.320               |              |
| Método usado por la empresa   | abr-17  | 742        | 783       | -41       | \$42.722.000              |                         | \$63.562.000 |
|   | may-17  | 778        | 758       | 20        |                           | \$20.840.000            |              |
| Modelo A.R.I.M.A. propuesto   | abr-17  | 786        | 783       | 3         |                           | \$2.667.960             | \$6.225.240  |
|   | may-17  | 762        | 758       | 4         |                           | \$3.557.280             |              |
| Diferencia entre el costo total del método utilizado por la empresa y el método propuesto |         |            |           |           |                           |                         | \$57.336.760 |

**Fuente: autores**

En el análisis de costos se evidencia claramente que el método utilizado por la empresa pronostica para los meses de abril y mayo, respectivamente 742 y 778, el dato real para estos meses son 783 y 758, obteniendo un desfase de -41 incurriendo en un costo de orden atrasada de \$42.722.000; y 20 incurre en un costo de almacenamiento de \$20.840.000, resultando un costo total de \$63.562.000, mientras que el método propuesto pronostica para los meses de abril y mayo, respectivamente 786 y 762, el dato real para estos meses son 783 y 758, obteniendo un desfase de 3 incurriendo en un costo de almacenamiento de \$2.667.960; y 4 incurre en un costo de almacenamiento de \$3.557.280, reflejando un costo total de \$6.225.240, la diferencia entre el costo total del método utilizado por la empresa y el método propuesto es de \$57.336.760 lo que indica la ganancia que la empresa tendría si hubiera aplicado el método propuesto para esos meses, se puede afirmar que aplicando el método propuesto para los siguientes meses, la empresa tendría más ganancias al disminuir sus costos.

### ***Metodología De Diseño E Implementación De Un Modelo De Redes Neuronales***

La construcción de un perceptrón multicapa implica la ejecución de una secuencia de pasos cronológica y lógicamente ordenados: Caracterización de la variable respuesta, definición de la arquitectura y topología del perceptrón, la segmentación de los conjuntos de entrenamiento y testeo, selección del algoritmo de aprendizaje, evaluación del modelo y estimación de las proyecciones en el corto plazo.

En la fase de caracterización de la variable respuesta se identifica el patrón de la demanda y su naturaleza. Posteriormente se define de la arquitectura del perceptrón, esto es, el modo de comunicación inter-neuronal de una capa a otra. La definición de la topología se efectúa de forma iterativa, es decir, que el número de capas ocultas y el número de neuronas por capa a ejecutar del proceso de aprendizaje se realiza reiteradas veces. En cada configuración tentativa se modifica el número de nodos y capas intermedias. Se establecieron iguales funciones de activación en todos los modelos propuestos: lineal en la capa de entrada y sigmooidal en capas oculta y de salida.

Los datos se disponen tal y como se capturan, de modo que la muestra total se divide en cuatro segmentos para entrenamiento y los registros remanentes se destinan para validación del modelo.

El entrenamiento de los modelos se realiza estableciendo un número máximo de épocas y un límite de convergencia basado en la disminución de error cuadrado medio después de una cantidad determinada de tiempo. La regla o algoritmo de aprendizaje puede definirse como el mecanismo mediante el cual se modifican los parámetros de la red. En el caso del perceptrón multicapa se trata de un algoritmo de aprendizaje supervisado; es decir, la modificación de los parámetros se realiza para que la salida de la red sea lo más próxima posible a la salida proporcionada por agente externo o salida deseada. Por tanto, el proceso de aprendizaje de la red es equivalente a encontrar un mínimo de la función error que previamente se ha definido. Generalmente este es un procedimiento de prueba y error, es decir, partiendo de una arquitectura de red que se ha entrenado, se efectúan modificaciones en el número de neuronas ocultas y el número de capas hasta conseguir una arquitectura de red que proporcione proyecciones con un margen de error reducido.

Finalmente se ejecuta la evaluación del rendimiento de las redes neuronales evaluando el comportamiento de la función de costo global que ha sido introducido.

En el apartado posterior se reportan los resultados derivados de la metodología propuesta.

## RESULTADOS

### Caracterización De La Variable Respuesta

Antes de definir la arquitectura del perceptrón multicapa es imperativo caracterizar apropiadamente la conducta histórica de la variable respuesta, en este caso, la demanda mensual. Así, en la Tabla 15 se calcula la demanda media para cada mes del periodo referencial seleccionado para el análisis, computándose además la desviación estándar y el coeficiente de variación de Pearson, da cuenta sobre la relación existente entre la desviación típica y la media aritmética en un valor porcentual. Nótese que dado que el coeficiente de variación para los meses por encima de los de veinte punto porcentuales y permanece relativamente estable con algunos cambios abruptos en los demás periodos, puede aseverarse que patrón de demanda es probabilístico y dinámico.

Tabla 14. Caracterización del Patrón de Demanda

| Periodo    | Demanda Media | Desviación Estándar | Coficiente De Variación |
|------------|---------------|---------------------|-------------------------|
| Enero      | 490,000       | 167,958             | 34,3%                   |
| Febrero    | 465,286       | 169,219             | 36,4%                   |
| Marzo      | 543,429       | 193,889             | 35,7%                   |
| Abril      | 531,571       | 161,204             | 30,3%                   |
| Mayo       | 511,429       | 145,945             | 28,5%                   |
| Junio      | 481,667       | 101,382             | 21,0%                   |
| Julio      | 455,167       | 111,611             | 24,5%                   |
| Agosto     | 514,000       | 162,326             | 31,6%                   |
| Septiembre | 504,333       | 116,826             | 23,2%                   |
| Octubre    | 550,000       | 140,757             | 25,6%                   |
| Noviembre  | 489,667       | 97,500              | 19,9%                   |
| Diciembre  | 549,000       | 192,977             | 35,2%                   |

### Creación De La Partición De Datos

El conjunto de datos de partición se ha realizado del siguiente modo: el 70% de la totalidad de datos se ha destinado para la muestra de entrenamiento, el 20% de los registros siguientes son asignados a la muestra de prueba. Para verificar el comportamiento de los errores en las épocas. El porcentaje restante se dispone para pertenecer a la muestra de reserva, que es constituida para evaluar el desempeño del modelo final incluyendo los registros fuera del proceso de entrenamiento.

### Definición De La Arquitectura Del Perceptrón Multicapa

Las conexiones del Perceptron multicapa siempre están direccionadas hacia adelante, o en otros términos redes feedforward. Las relaciones entre inputs y outputs.

Considerérese una perceptrón multicapa con  $C$  capas y  $n_c$  neuronas en cada capa. Sea también la activación de una neurona  $i$  de la capa  $C$  rotulada por  $a_i^c$  y  $w_{ji}^{c-1}$  es la matriz de ponderaciones dada por:

$$W = w_{ji}^{c-1} = \begin{pmatrix} w_{11}^c & w_{12}^c & \dots & w_{1n_c+1}^c \\ w_{21}^c & w_{22}^c & \dots & w_{2n_c+1}^c \\ \vdots & \vdots & \dots & \vdots \\ w_{n_c1}^c & w_{n_c2}^c & \dots & w_{n_cn_c+1}^c \end{pmatrix} \quad (13)$$

Y  $u_i^c$  el vector de umbrales de cada capa dada por la siguiente expresión:

$$U = u_i^c = \begin{pmatrix} u_1^c \\ u_2^c \\ \vdots \\ u_N^c \end{pmatrix} \quad (14)$$

La topología de un perceptrón multicapa queda establecida por:

Una capa de entrada, recepta señales exteriores y las transmite hacia la red.

Las capas ocultas, constituidas por nodos de red no perceptibles directamente activan neuronas cuando se aplica la función de transferencia sobre la sumatoria de los productos de las activaciones recibidas por pesos específicos. Esto puede expresarse como:

$$a_i^c = f\left(\sum_{j=1}^{n_c} w_{ji}^{c-1} a_j^{c-1} + u_i^c\right) \text{ para } i = 1, 2, \dots, n_c \text{ y } c = 2, 3, \dots, C - 1 \quad (15)$$

La activación de neuronas en capa de salida, es una aplicada a una función de activación sobre la sumatoria de los productos recibidos por los pesos respectivas. Esto puede expresarse como:

$$a_i^c = f\left(\sum_{j=1}^{n_c} w_{ji}^{c-1} a_j^{c-1} + u_i^c\right) \text{ para } i = 1, 2, \dots, n_c \text{ y } c = 2, 3, \dots, C - 1 \quad (16)$$

Para todas las capas ocultas se ha utilizado la función tangente hiperbólica que comprime el espectro de valores en un intervalo  $[-1,1]$  y viene expresada como:

$$\gamma(c) = \text{Tanh}(c) = \frac{(e^c + e^{-c})}{(e^c - e^{-c})} \quad (17)$$

La función de activación de la capa de salida es la función identidad como  $\gamma(c) = c$ , de manera que la salida de la unidad es equivalente al nivel de activación.

Los pesos nuevos serán  $w_{ji}^{c-1}(n) = w_{ji}^{c-1}(n-1) + \alpha \delta_i^c(n) \alpha \delta_i^{c-1}(n)$  y los umbrales de la capa posterior  $u_i^c(n) = u_i^c(n-1) + \alpha \delta_i^c(n)$ .

### **Algoritmo De Aprendizaje.**

Durante el entrenamiento se actualizan las ponderaciones sinápticas después del caso disponible destinado para el proceso de aprendizaje hasta el alcance del criterio de convergencia. Ha de anotarse que el entrenamiento requiere un importante esfuerzo computacional que es proporcional al resultado de multiplicar a la cantidad de ponderaciones el número de épocas de entrenamiento y por los registros dispuestos para el aprendizaje en cada época.

Previo a la ejecución del proceso de entrenamiento de la red se definen las condiciones iniciales, esto es, unas ponderaciones aleatorias asignadas a las conexiones neuronales que se hallan dentro de un intervalo de valores. El criterio de parada es la disminución del cálculo del error cuadrático medio para cada caso disponible para el entrenamiento debajo de un umbral establecido.

El algoritmo de retropropagación (adaptación bi-etápica) utilizado en el caso presente consiste en propagar el error de modo inverso al funcionamiento de la red, esto es, de la capa de salida hacia la capa de entrada, sin dejar por fuera las capas ocultas intermedias, de modo que las ponderaciones son modificadas progresivamente hasta reducir la función de costo global. Las neuronas localizadas en las capas ocultas solo captan una porción pequeña de la señal total del error, dependiendo de la contribución marginal aportada por cada neurona a la salida. Este proceso se aplica en reiteradas ocasiones en cada capa, hasta que la totalidad de las neuronas reciben una señal de error que alerta la participación relativa sobre el error total.

De un modo formal el algoritmo de retropropagación puede resumirse así:

Sea la entrada total o neta de una neurona oculta  $J$  estará dado por:

$$net_j^p = \sum_{i=1}^N w_{ij} x_i^p + \theta_j \quad (18)$$

Siendo  $\theta_j$  el umbral de la neurona

Al aplicar la función de activación a la entrada neta de la neurona oculta, se obtiene el valor de la salida

$$y_j^p = f(net_j^p) \quad (19)$$

Y la entrada neta que recibe una neurona de salida denotada por  $k$  viene dado por

$$net_k^p = \sum_{j=1}^N v_{kj} y_j^p + \theta_k \quad (20)$$

El valor de la neurona de salida es:

$$y_k^p = f(net_k^p) \quad (21)$$

Y la función de error para cada patrón de entrenamiento que da cuenta sobre la distancia existente entre la salida deseada y la real se expresa como:

$$\frac{1}{2} \sum_{k=1}^m (d_k - y_k^p)^2 \quad (22)$$

La técnica del gradiente descendente es utilizada por el algoritmo de retro propagación cuya capacidad para organizar el conocimiento disponible de la capa intermedia a fin de obtener cualquier correspondencia entre las capas.

Pártase del supuesto que se encuentra en la iteración  $k$  en la cual se introduce un patrón cuya salida de unidad  $i$  es  $y_i^p$  y la salida deseada es  $d_k$ , la regla de variación de las ponderaciones sinápticas vendrá dada por

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k) \quad (23)$$

Siendo 
$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (24)$$

El término delta obedecerá a esta expresión funcional:

$$\delta_k^2 = g'(h_k) [(d_k - y_k^p)] \quad (25)$$

Dado que esta cantidad se propaga en dirección inversa al funcionamiento de la red se deduce que:

$$\Delta w_{ij}(k) = \eta \delta_k^2(k) s_j(k) \quad (26)$$

Mientras que la modificación de las ponderaciones en la capa anterior se expresa tal y como sigue, utilizando la regla de la cadena.

$$\Delta t_{jr} - \eta \frac{\partial E}{\partial t_{jr}} = \eta \eta \frac{\partial E}{\partial s_j(k)} \frac{\partial s_j(k)}{\partial t_{jr}(k)} \quad (27)$$

La variación de la ponderación  $\Delta t_{jr}$  será:

$$\Delta w_{ij}(k) = \eta \delta_i^1(k) x_r(k) \quad (28)$$

## Resultados

En la Tabla 15 se presenta un resumen del modelo construido que recopila la información que fue explicitada en apartados antecedentes y algunos otros resultados relevantes. Se ha determinado que sólo existirá una neurona por capa, un criterio de convergencia basado en la reducción del error cuadrático medio luego de un intervalo de tiempo y la selección de las funciones de activación para cada capa.

**Tabla 15.** Resumen del modelo

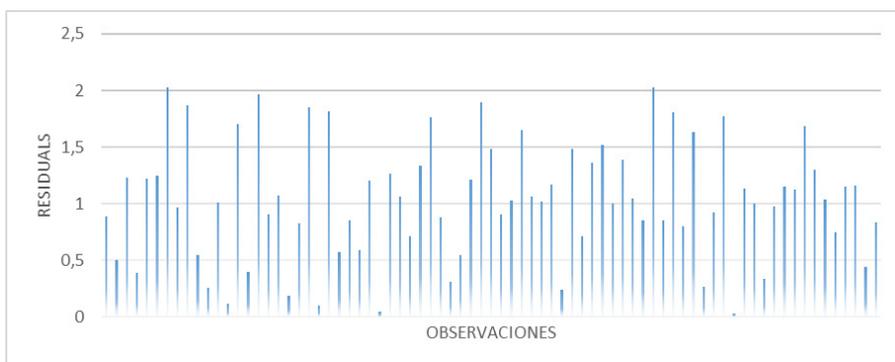
|   |
|---|
| Cantidad Máxima de Pasos: 100000                                  |
| Neuronas por capa: 1  |
| Algoritmo de Aprendizaje: Retropropagación                        |
| Funciones de Activación: Tangente Hiperbólica – Función Identidad |
| Semilla Aleatoria: 4489004  |
| Error Cuadrático Medio: 69,4                                      |
| Criterio de Parada: No reducción del error luego de 10 minutos    |

1

Se percibe, por ejemplo, que el error cuadrático medio es relativamente bajo, por consiguiente, existe una alta similitud entre las ventas proyectadas y las ventas reales.

La idoneidad del modelo es refrendada igualmente al analizar el gráfico 13 de residuales pues no se detectan comportamientos anómalos ni tendencias acentuadas entre los mismos. Nótese que el espectro de valores de los residuales es reducido y que, por consiguiente, no existen discrepancias significativas entre las proyecciones y los valores reales.

**Gráfico 13.** Residuales del modelo de Redes Neuronales



La tabla 16 conjunta las proyecciones generadas a partir del modelo de Redes Neuronales artificiales para los subsiguientes seis periodos.

**Tabla 16. Predicciones generadas por la Red Neuronal Artificial**

| Período | Ventas  |
|---------|---------|
| 1       | 602,621 |
| 2       | 790,750 |
| 3       | 675,786 |
| 4       | 761,976 |
| 5       | 789,329 |
| 6       | 783,956 |
| 7       | 757,986 |

En definitiva, se ratifica que la capacidad predictiva de la Red Neuronal Artificial es evidentemente superior a las otras técnicas proyectivas consideradas, tanto para reproducir con amplia exactitud el comportamiento de la variable respuesta y generar pronósticos en el corto y mediano plazo.

## CONCLUSIONES

En el presente trabajo se demostró que la empresa tiene un método deficiente de proyección de la demanda, haciendo que la empresa tenga sobre costos por almacenamiento o deje de ganar por costo de oportunidad.

Se analizó la demanda histórica de 6 años y 3 meses de la empresa en su línea de producto, obteniendo así, que el método más acertado a esta serie de tiempo para realizar un pronóstico de demanda es el modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup>. Presentado por el software Statgraphics; cuando se hace referencia a el más acertado no significa que necesariamente el pronóstico va a ser igual al siguiente periodo, pero si va a ser una cifra muy cercana a la real, lo anterior queda demostrado ya que si observamos en la (tabla 6) existen datos históricos de 6 años y 5 meses, lo que indica se dejaron dos meses por fuera del análisis, esto con el fin de comparar entre el pronóstico utilizado actualmente por la empresa (Anexo B) y el método obtenido como el más acertado (modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup>). Para esos dos últimos meses (abril y mayo de 2017) se observa que el método utilizado por la empresa (Anexo B) tiene mayor número de desfase y por ende de costos de ordenes atrasadas y costos de almacenamiento, lo que lleva al resultado de que el método propuesto (modelo (A) ARIMA (0,1,1) x (1,0,1)<sup>12</sup>) sea mucho mejor, con una diferencia de costos de \$60.004.720 (Tabla 13).

El análisis demostró una disminución significativa de error en el método propuesto como el más acertado con respecto al pronóstico del método actual, lo que al ponerlo en práctica disminuirá considerablemente el costo de inventario y costo de ordenes atrasadas, además la planeación de la empresa va a verse muy beneficiada, haciendo que esta se encuentre mejor preparada para afrontar la fluctuante demanda.

Si bien los pronósticos de demanda son una herramienta fundamental para la planeación de una empresa, y en condiciones normales se acercan mucho a la realidad hay que tener muy en cuenta que también pueden desfasarse un poco debido a los fenómenos exógenos.

El modelo de Redes Neuronales arroja un mejor desempeño a partir de un menor error cuadrático medio de 69,4 ; que los pronósticos de series de tiempo tradicionales y que modelos como lo es ARIMA, estos últimos en mención totalmente econométricos que ajustan en un grado factible los datos para pronosticar las ventas en este caso; pero que, a comparación con la Red Neuronal, esta última tiene mayor confiabilidad en los resultados arrojados, teniendo en cuenta que los pronósticos de ventas son un insumo fundamental en el proceso de planeación, casi que para todos los procesos organizacionales.

Las diferencias permiten un espacio de ventajas de una técnica a otra, para el caso de las redes neuronales, estas no requieren ninguna suposición sobre las distribuciones de probabilidad de los datos, solo los aprenden, tienen la facultad de operar con datos incompletos y analizar datos con alta o nula correlación. Una característica importante en las redes neuronales artificiales empleadas en los pronósticos, es que los datos no deben de ser analizados para probar el supuesto de tendencia o estacionalidad en la serie de tiempo previo a la realización del pronóstico.

En la red neuronal artificial no es requerido especificar supuestos, como sí lo son empleados en los modelos convencionales, pues el método involucra el aprendizaje de las relaciones. Así, este modelo de pronóstico de venta se valida con esta investigación como el más conveniente para ser utilizado por la empresa para su línea de producto, dando respuesta a un control y programación de la producción, evitando sobre costos y gastos relacionados con Ventas.

## REFERENCIAS BIBLIOGRÁFICAS

- AL-MUSAYLHA, M. S., Deo, R. C., ADAMOWSKIC, J. F., & LI, Y. (01 de Diciembre de 2017). Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia. Australia: ELSEVIER.
- BERMUDEZ ESCOBAR, A., & LONDONO OLARTE, S. (2013). Metodología para optimizar inventarios de producto terminado en una empresa, basado en estimación de demanda y minimización de costos. Medellin, Colombia: Universidad Pontificia Bolivariana, Escuela de Ingeniería.
- CAICEDO, E., & López, J. (2009). Una aproximación práctica a las Redes Neuronales Artificiales. Cali: Universidad del Valle.
- CHAPMAN, S. (2006). Planificación y control de la producción. México: Pearson Educación.
- COELLO BLANCO, L., Casas, L., Pérez González, O., & Caballero Mota, Y. (2015). Redes neuronales artificiales en la producción de tecnología educativa para la enseñanza de la diagonalización. Revista Academia y Virtualidad, 8(1), 12-20.
- COLLIER, D. A. (2009). Administración de Operaciones. México D.F: 2 Ed. Cengage learning.
- ELAMIN, N., & FUKUSHIGE, M. (3 de Agosto de 2017). Forecasting extreme seasonal tourism demand: the case of Rishiri Island in Japan. Japon: SPRINGER.
- FRAUSTO ENRIQUEZ, J. H. (2009). Pronósticos de ventas para la administración estratégica de los recursos en una empresa del sector automotriz. Atizapán de Zaragoza, México: Instituto Tecnológico y de estudios superiores de Monterrey.
- GAJOWNICZEK, K., & ZABKOWSKI, T. (8 de Octubre de 2017). Two-Stage Electricity Demand Modeling Using Machine Learning Algorithms. Polonia: ENERGIES.
- HA, C., SEOK, H., & OK, C. (2 de Marzo de 2018). Evaluation of forecasting methods in aggregate production planning: A Cumulative Absolute Forecast Error (CAFE). Seúl, República de Corea: ELSEVIER.
- HAN, P., WANG, P., TIAN, M., ZHANG, S., LIU, J., & ZHU, D. (2013). Application of the ARIMA Models in Drought Forecasting Using the Standardized Precipitation Index . China: IFIP International Federation for Information Processing .
- JIMENEZ, D. L. (2011). Análisis y pronósticos de demanda para la telefonía móvil. Santiago de Chile, Chile.
- KHASHEI, M., & Hajirahimi, Z. (2017). Performance evaluation of series and parallel strategies for financial time series forecasting. Isfahan, Ira: Springer.

- KHORASANI, M., EHTESHAMI, M., GHADIMI, H., & SALARI, M. (11 de Junio de 2016). Simulation and analysis of temporal changes of groundwater depth using time series modeling. Iran: Springer International Publishing Switzerland.
- LIANG, Y., & LIU, S. (2013). The Classic Swine Fever Morbidity Forecasting Research Based on Combined Model . China: IFIP International Federation for Information Processin.
- MACIAS, G. G. (2007). Metodología para calcular el pronóstico de la demanda y una medición de su precisión, en una empresa de autopartes: caso de estudio. México D.F.
- MAKRIDAKIS, S. y. (2009). Métodos de Pronósticos. México: Editorial Limusa.
- MORA, A. G. (2007). Pronósticos de demanda e inventarios. Medellín: Editorial A M G.
- MURRAYA, P. W., AGARDA, B., & BARAJA, M. A. (6 de Febrero de 2018). Forecast of individual customer's demand from a large and noisy dataset. Canada : ELSEVIER.
- NAHMIAS, S. (2007). Análisis de la producción y las operaciones. México D.F: 5 Ed. McGraw-Hill.
- PÉREZ GOSENDE, P. A. (s.f.). Metodologías para la resolución de problemas de distribución en planta. Cuba: Universidad Matarca; Departamento Ingeniería Industrial.
- PETROPOULOS, F., KOURENTZES, N., & NIKOLOPOULOS, K. (2016). Another look at estimators for intermittent demand. Reino Unido: ELSEVIER.
- PREMA, V., & Uma Rao, k. (2013). Time series decomposition model for accurate wind speed forecast. Bangalore, India: Springer.
- ROSAS, J. A., & CORTES, E. L. (2013). Propuesta de una metodología de planeación de la demanda y de los inventarios de medicamentos y dispositivos médicos de uso en pacientes hospitalizados en una Ips de cuarto nivel. Cali, Colombia.
- SÁNCHEZ ANZOLA, N. (2015). Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario. ODEON(9), 113-172.
- SEVERINE MEUNIER, M., Cheikhrouhou, N., & Glardon, R. (2005). Strategic Analysis of Products Related to the Integration of Human Judgement into Demand Forecasting. Ecublens, Switzerland: Springer.
- TIRKES, G., GÜRAY, C., & ÇELEBI, N. (2017). DEMAND FORECASTING: A COMPARISON BETWEEN THE HOLT-WINTERS, TREND ANALYSIS AND DECOMPOSITION MODELS . Suppl.
- VILLADA, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. Información Tecnológica, 23(4), 11-20.

