

**UNIVERSIDAD SAN FRANCISCO DE QUITO**

**Colegio de Ciencias e Ingeniería**

**Industria Petrolera: Modelamiento del pronóstico de la demanda y la  
planificación y proyección del consumo.**

**Nicolas Vela**

**Ingeniera Industrial**

Trabajo de fin de carrera presentado como requisito  
para la obtención del título de  
Ingeniera Industrial

Quito, 24 de abril de 2020

# **UNIVERSIDAD SAN FRANCISCO DE QUITO**

**Colegio de Ciencias e Ingeniería**

**Hoja de Calificación de Trabajo de Titulación**

**Industria Petrolera: Modelamiento del pronóstico de la demanda y la  
planificación y proyección del consumo.**

**Nicolas Vela**

**Ingeniera Industrial**

**Nombre del profesor/a, Título académico**

Maria Cristina Camacho Cordovez, MS.

Quito, 24 de abril de 2020

## **DERECHOS DE AUTOR**

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Nombres y Apellidos: Nicolas Andrés Vela Narvaez

Código: 00131166

Cedula de Identidad: 1720944741

Lugar y Fecha: Quito, 24 de abril de 2020

## **ACLARACIÓN PARA PUBLICACIÓN**

**Nota:** El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETheses>.

## **UNPUBLISHED DOCUMENT**

**Note:** The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETheses>.

## **AGRADECIMIENTOS**

Quisiera agradecer en especial a Maria Cristina Camacho Cordovez por los conocimientos compartidos durante el trayecto de mi proyecto y también por la confianza y apoyo incondicional otorgado durante este trabajo.

Asimismo, quisiera agradecer a mis padres, hermano y a mi familia que han sido mi guía durante mi carrera universitaria. En base a su apoyo incondicional he llegado a las últimas instancias de esta carrera.

De igual manera quisiera agradecer a todos mis profesores de la USFQ que me formaron en mi desarrollo académico y profesional.

## **RESUMEN**

El presente estudio se llevó a cabo en la industria de petróleos, con el objetivo de mejorar el sistema de planificación de demanda para una empresa de servicios petroleros. Actualmente la empresa se basa en el proceso de planificación de demanda con un pronóstico generado por el departamento de ventas, el cual normalmente no se alinea al consumo real. Es por eso que se optó por aplicar diferentes modelos matemáticos de pronósticos para determinar un modelo óptimo en relación al consumo real. Los resultados presentes muestran una clasificación de los modelos óptimos en base al consumo por categoría. Asimismo, dentro del estudio se identificó que los modelos óptimos con el menor índice de error son el método de suavizamiento exponencial tripe y promedios móviles. En base a estos modelos se generó pronósticos, los cuales se asimilan al consumo real disminuyendo el error en un 45%.

Palabras Claves: Pronósticos, Planificación Demanda, Series de Tiempo, Industria Petrolera

## **ABSTRACT**

This capstone project carried out in the oil industry, with the objective of improving the demand planning system for an oil services company. Currently the company is based on the demand planning process with a forecast generated by the sales department, which normally does not align with real consumption. The present study aimed to apply different mathematical forecasting models to determine an optimal model in relation to real consumption. The results show a classification of the optimal models based on consumption by category. The forecast error was able to reduce by 45%.

**Key Words:** Forecast, Demand Planning, Time Series, Oil Industry

## Tabla De Contenido

<b>1. Introducción .....</b>	<b>11</b>
<b>2. Objetivos .....</b>	<b>13</b>
<b>2.1. Objetivo General .....</b>	<b>13</b>
<b>2.2. Objetivo Específicos .....</b>	<b>13</b>
<b>3. Revisión de Literatura .....</b>	<b>13</b>
<b>3.1. Pronósticos .....</b>	<b>13</b>
<b>3.2. Medida de Error .....</b>	<b>18</b>
<b>4. Metodología .....</b>	<b>20</b>
<b>4.1. Definición del Problema .....</b>	<b>21</b>
<b>4.2. Recolección de Data .....</b>	<b>21</b>
<b>4.3. Análisis de Data .....</b>	<b>21</b>
<b>4.4. Selección y Validación del Modelo .....</b>	<b>22</b>
<b>4.5. Implementación del Modelo de Pronósticos .....</b>	<b>23</b>
<b>4.6. Monitoreo del Sistema de Desempeño .....</b>	<b>23</b>
<b>5. Desarrollo .....</b>	<b>23</b>
<b>5.1. Análisis de Data .....</b>	<b>23</b>
<b>5.2. Selección y Validación del modelo .....</b>	<b>26</b>
<b>5.3. Resultados de la Selección y Validación del modelo .....</b>	<b>27</b>
<b>5.4. Implementación del Modelo de Pronósticos .....</b>	<b>29</b>
<b>6. Conclusiones .....</b>	<b>30</b>
<b>7. Referencias .....</b>	<b>32</b>
<b>8. Anexos .....</b>	<b>36</b>
<b>8.1. Anexo 1: .....</b>	<b>36</b>
<b>8.2. Anexo 2: .....</b>	<b>36</b>
<b>8.3. Anexo 3: .....</b>	<b>37</b>
<b>8.4. Anexo 4: .....</b>	<b>37</b>
<b>8.5. Anexo 5: .....</b>	<b>37</b>



## Índice De Tablas

<b>1. Tabla 1: Resumen de los modelos con mayor consumo según su clasificación.....</b>	<b>25</b>
<b>2. Tabla 2: Modelos Óptimos según sus Categorías.....</b>	<b>27</b>
<b>3. Tabla 3. Resumen de la Partición del Porcentaje de consumo de los modelos en base a su categoría.....</b>	<b>28</b>
<b>4. Tabla 4. Resumen de la Partición del Porcentaje de consumo del modelo D4.6 de bomba en base a los clientes.....</b>	<b>29</b>

## Índice De Figuras

<b>1. Imagen 1: Modelos con mayor consumo dependiendo su clasificación.....</b>	<b>22</b>
<b>2. Grafica 1: Análisis de Pareto de la Categorización Serie .....</b>	<b>24</b>
<b>3. Grafica 2: Análisis de Pareto de la Categorización Bomba.....</b>	<b>24</b>
<b>4. Grafica 3: Análisis de Pareto de la Categorización Motor.....</b>	<b>25</b>
<b>5. Grafica 4: Análisis de Pareto del Consumo de clientes.....</b>	<b>26</b>

## 1. Introducción

El gas y el petróleo son fuentes de energía que se remontan sobre millones de años atrás y, que además está previsto que sean nuestra principal fuente de energía durante los próximos años (Sandri, 2017). La Organización de Países Exportadores de Petróleo (OPEP) confirmó que el consumo de petróleo no disminuirá hasta el 2040 (Sandri, 2017). Según Viena, el consumo global de petróleo crecerá en el próximo año un 1.14%, hasta un consumo diario de 101,01 millones de barriles diarios, superando la barrera de los 100 millones de barriles (2019). Por su parte, el Ecuador tiene un consumo diario de 539,000 barriles por día (El Comercio). Asimismo, en el Ecuador existirá un incremento de producción de crudo con perspectivas en nuevos campos como el Ishipingo, Tambococha y Tiputini (ITT) que captan la atención de inversionistas internacionales hacia esta industria en el país (Lideres, 2014). Según Eduardo López, Presidente de la compañía de servicios petroleros Sertecpet el mercado de servicios y productores del sector mueven anualmente entre USD 1 000 millones y 2 000 millones (Lideres, 2014).

Para poder producir el número de barriles que se elaboran a diario las petroleras y compañías de servicios siguen un proceso de producción y extracción de crudo, el cual comienza con la exploración de yacimientos (Repsol, 2019). El proceso de exploración es una técnica con diversas herramientas de alta tecnología, como el Sherlock que ayudan a determinar nuevos yacimientos de petróleo, y conocer sus cantidades y condiciones (Repsol,2019). Esta fase ofrece puntos claves para determinar y desarrollar planes de producción en función a las características del yacimiento (Repsol, 2019). Una vez localizado el yacimiento y comprobada su viabilidad, se procede con la segunda fase: la extracción o producción (Repsol, 2019). Para poder realizar la extracción del crudo dentro de los yacimientos se emplean técnicas de perforación siguiendo los más altos estándares (Repsol, 2019). Los componentes de perforación que se utilizan para llevar a cabo este proceso son los sistemas de potencia, transmisión de energía, izaje, rotación, perforación, circulación de lodo y prevención de surgencias (Hernán, 2019). El presente estudio se enfoca en el sistema de perforación, el cual tiene como componente principal la sarta de perforación. La sarta de perforación es una herramienta que ayuda a transmitir fuerza de empuje y rotación para que la barrena gire al fondo del pozo (SLB Oilfield Glossary).

El abastecimiento de los equipos es un punto clave y estratégico para que los recursos de las empresas se vuelvan óptimos, creando una cadena de valor que genere ganancias y un flujo de dinero óptimo (Rodríguez, 2005). La cadena de demanda en la industria de servicios petroleros incluye todas las actividades relacionadas con el flujo de equipos, bienes, activos y productos, desde la etapa de la materia prima hasta la etapa de su consumo (Ríos, 2006). Por ende, toda detención de flujo es una pérdida; si se detiene el flujo de equipos existe un incremento de inventario generando pérdidas por capital inmovilizado o pérdida de ventas (Ríos, 2006). La administración eficiente y efectiva del flujo de equipos y capital es el punto clave para el éxito de la cadena de demanda (Ríos, 2006).

La empresa donde se está realizando el estudio se encuentra en la rama de servicios petroleros dedicada a realizar proyectos de provisión de servicios en las diferentes fases de la industria, siendo su enfoque el servicio de extracción, y perforación de petróleo y/o gas (EKOS, 2019). La empresa está entre las empresas más grandes de servicios en la industria petrolera a nivel mundial (SPE, 2019), la cual genera una ganancia superior a los 20 billones en los últimos cinco años (Jiménez, 2015) y tiene un segmento del mercado del 12.74% (CSI Market, 2020). Dicha empresa consta con un departamento de planificación de demanda, operaciones y recursos. La planificación se realiza en base al número de sartas de perforación proyectadas por el departamento de ventas. Una sarta de perforación es la combinación de la columna de perforación, el arreglo de fondo de pozo y cualquier otra herramienta utilizada para que la barrena gire en el fondo del pozo (SLB Oilfield Glossary). Asimismo, existen varios pasos a seguir en la planeación de demandas y proyección de inventarios en base a los pronósticos estimados por ventas. El incumplimiento de la demanda proyectada en relación al consumo es uno de los problemas que surge durante estos pasos. Por lo tanto, el presente estudio, abarca un análisis de diferentes pronósticos de sartas.

## 2. Objetivos

### 2.1. Objetivo General

Crear un sistema de planificación de la demanda a través de la aplicación de modelos de pronósticos con el fin de reducir costos de importación de suministros.

### 2.2. Objetivo Específicos

- Aplicar modelos de pronósticos para la identificación y proyección del consumo de sartas.
- Clasificar e identificar los equipos de bombas, motores, series y sartas en base al consumo.
- Crear un sistema amigable funcional para la actualización de modelos de pronósticos

## 3. Revisión de Literatura

A continuación, se especificará la revisión literaria que abarca marcos teóricos e investigaciones relacionadas a los campos de pronósticos y sus proyecciones.

### 3.1. Pronósticos

Se vio la necesidad de implementar pronósticos en base al consumo, considerando que el departamento de ventas no se maneja de la misma forma en relación al consumo, sino dependiendo de cuantos clientes tienen previsto durante el año y sus niveles de producción. Según Nahmias (2009) existen aproximadamente 70 diferentes métodos para realizar pronósticos, los cuales se clasifican en relación al tiempo; los pronósticos pueden tener una clasificación de corto, mediano o largo plazo (Nahmias, 2009). Adicionalmente, esta clasificación de métodos de pronósticos está dividida en métodos subjetivos y objetivos. Los métodos de pronósticos subjetivos o también conocidos como cualitativos normalmente se basan en el juicio humano (Arunraj, & Ahrens, 2016). Por el contrario, los métodos objetivos o también conocidos como cuantitativos, son métodos que normalmente se basan en sistemas matemáticos y estadísticos que involucran el modelamiento de datos sobre la demanda histórica y su deducción hacia el futuro (Arunraj, & Ahrens, 2016).

Según Nahmias (2009), los métodos cuantitativos están divididos en series de tiempos, métodos causales y modelos híbridos. El método serie de tiempo se define como el conjunto de observaciones y medidas en puntos o periodos sucesivos de tiempo sobre una variable específica (Chopra, & Meindl,

2013). Dentro de los modelos existentes, existen tendencias o patrones diferentes, donde según Namhías (2009) los patrones de series de tiempo se les clasifican por tipos de métodos que son: modelos para series estacionarias, con tendencia y estacionalidad. Una serie estacionaria se da cuando el patrón tiende a oscilar alrededor de una media constante (Villavicencio, 2019). Tendencia es cuando los datos muestran un tipo de orientación, y estacionalidad son fluctuaciones periódicas o un patrón que se repite en intervalos fijos (Reyes Aguilar, 2007). Según Nahmias (2009) los modelos que se realizan para series de tiempo estacionarias son promedios móviles, y suavizamiento exponencial simple. Mientras que para tendencia el modelo es suavizamiento exponencial doble o Holt, y para la estacionalidad es la descomposición de promedios móviles y suavizamiento exponencial triple o Winters (Nahmias, 2009). Es importante recalcar que los métodos mencionados de series de tiempo, como promedio móvil y suavizamiento exponencial son métodos de pronóstico de un paso adelante (Da Veiga, et al, 2010). Dicho de otra manera, se supone que los pronósticos de cualquier periodo serán los mismos debido a que es una serie estacionaria. Mientras que los métodos de Holt y Winters son de varios pasos adelante, es decir que sus pronósticos varían según el período que se pronostique, debido a que no se considera serie estacionaria ya que sus observaciones fluctúan a través del tiempo (Da Veiga, et al, 2010).

Un estudio realizado por el Instituto Colombiano de Estudios Superiores de Incolda (ICESI), sobre el análisis de series de tiempo en los pronósticos de la demanda en un almacenamiento de productos perecederos, fomenta el uso de técnicas de pronósticos de series de tiempo para su análisis de eventos futuros (Juárez, & Flores, 2016). El estudio resalta la importancia del análisis de datos de series de tiempo para la toma de decisiones en el almacenamiento de productos perecederos (Juárez, & Flores, 2016). Dicho estudio optó por utilizar promedio móvil simple, promedio móvil ponderado, suavizamiento exponencial, y suavizamiento exponencial ajustado, debido a que estos modelos tienen una exactitud y precisión a corto plazo (Juárez, C. y Flores, J. 2016). Según el estudio realizado por Juárez y Flores (2016) la técnica que resultó con menor error y una mejor señal de rastreo fue la técnica de promedios móviles en relación a los otros métodos de series de tiempo. Por otro lado, otro estudio aplicado en una

empresa de productos de aseo realizó la planeación y control de la producción evaluando la demanda en relación a los métodos series de tiempo (Cortes, Bonilla, & Espitia, 2019). Tras haber analizado la demanda obtenida mediante sus datos históricos observaron que la data histórica contenía un patrón de estacionalidad y tendencia (Cortes, Bonilla, & Espitia, 2019). Según la data histórica y los patrones se utilizó el método de suavizamiento exponencial triple o método de Winters (Cortes, Bonilla, & Espitia, 2019). Asimismo, Cortes et. al, reiteran que se debe usar datos históricos para poder identificar la estacionalidad y tendencia de la data (2019). Según Cortes et. al, esto permite determinar los métodos de pronósticos más adecuados, de modo que se pueda aplicar y evaluar mediante indicadores de error y señal de seguimiento (2019).

Adicionalmente existen otros modelos de series de tiempos como el de Croston y Box-Jenkins. El método de Croston es en base a una demanda intermitente (Santa Cruz, & Correa, 2017). En otros términos, es una demanda donde ciertos periodos no poseen ningún tipo de demanda (Santa Cruz, & Correa, 2017). El modelo de Croston se divide en dos partes: los valores positivos de la demanda (tamaño de la demanda), y los tiempos entre demandas consecutivas no nulas (tiempo de observaciones), de esta forma se logra pronosticar utilizando suavizamiento exponencial (Santa Cruz, & Correa, 2017). Este método es recomendado para productos con ventas ocasionales (Burgaentzle, 2016). Asimismo, el método Box-Jenkins no cumple con observaciones sucesivas independientes si no se utiliza las dependencias entre valores de serie. Hay tres aplicaciones que se utilizan para realizar el modelo de Box-Jenkins que son ARMA, ARIMA, SARIMA (Adhikari & Agrawal, 2013). Se utiliza la técnica ARMA cuando existen series de tiempo estacionarias, mientras que ARIMA se utiliza cuando las series de tiempo son no estacionarias y finalmente SARIMA se utiliza cuando las series de tiempo no estacionarias con estacionalidad (Adhikari & Agrawal, 2013). Asimismo, Zhang afirma que los modelos ARMA y ARIMA son los métodos lineales más comunes, pero su capacidad de pronósticos está limitada debido al supuesto de comportamiento lineal, por lo tanto, no siempre satisfactorio (2003). Según Makridakis, S. & Hibon.M, concuerdan que el método Box- Jenkins no es el más preciso para pronosticar series de tiempo

en casos de aplicaciones reales y empresariales ya que existe un nivel alto de aleatoriedad donde los patrones no son consistentes (1997). Adicionalmente, ya que los pronósticos se requieren de forma periódica o diaria no es práctico utilizar modelos complejos donde se necesita un amplio análisis matemático (Chen & Ou, 2011).

En un estudio realizado para determinar la demanda de una empresa en el sector turístico, se determinó que la demanda era estacional, por ende, se utilizaron los métodos de Box Jenkins y Winters para pronosticar (Jiménez, Abad, & Fernández, 2006). En el método de Box-Jenkins se utilizó la técnica de ARIMA para determinar proyecciones a corto plazo debido a que los resultados a largo plazo generan una imprecisión en los resultados (Jiménez, Abad, & Fernández, 2006). Asimismo, debido a que los datos históricos tienen una tendencia con estacionalidad se utilizó el método de Winters (Jiménez, J., Abad, J., y Fernández, R. (2006). Se llevó a cabo una comparación de capacidad predictiva de los métodos de predicción ampliamente utilizados (Jiménez, Abad, & Fernández, 2006). Los resultados obtenidos de dicho estudio de datos fueron similares entre métodos en la medida de error (Jiménez, Abad, & Fernández, 2006). Dado que las tres medidas estadísticas de error fueron similares, se optó por el error más insignificante, donde demuestran que ARIMA tiene un error más insignificante en relación a Winters (Jiménez, Abad, & Fernández, 2006).

Un estudio realizado por Pérez, Mosquera, & Bravo, evaluó el comportamiento de la demanda para evitar excesiva cantidad de productos con falta de rotación (2012). Evaluaron el comportamiento de datos históricos de la demanda de los productos mediante diferentes metodologías de pronóstico como promedio móvil, suavizamiento exponencial simple, método de Croston y método de Winters (Pérez, Mosquera, & Bravo, 2012). La elección del mejor método está adecuada por pequeñas diferencias entre las evaluaciones de errores, donde se sugiere utilizar promedios móviles (Pérez, Mosquera, & Bravo, 2012). El estudio recalca que el método de Croston no fue la mejor opción debido a que se debe utilizar cuando existe una demanda errática o irregularidad en la demanda (Pérez, Mosquera, & Bravo, 2012)



Por otra parte, los métodos causales son aquellos que se basan en la suposición de la variable que se pronostica y contiene una relación causa y efecto con las demás variables (Burgaentzle, 2016). Dentro de estos métodos causales se encuentra el análisis de regresión que forma parte de modelo de tendencias (Nahmias, 2009) Asimismo, existen otros métodos que son regresión múltiple y red neural artificial (Adhikari & Agrawal, 2013). De igual manera el método de red neural artificial trata de reconocer regularidades y patrones en los datos para aprender de ellos y luego pronosticar en base a su conocimiento previo (Adhikari & Agrawal, 2013). Finalmente, los modelos híbridos son una combinación entre métodos de series de tiempos y métodos causales (Arunraj, & Ahrens, 2005). Aburto y Weber plantearon un ejemplo de un método híbrido donde combinan los modelos de promedio móviles integrado con redes neuronales (ARIMA) con el fin de mejorar el modelo (2007). Asimismo, existen muchos autores que concuerdan que no hay modelos exactos o únicos que puede ser usados en todas las situaciones, lo cual hace elegir un modelo de pronósticos una tarea difícil (Arunraj & Ahrens, 2015).

En un estudio realizado en la Universidad Tecnológica de Pereira sobre pronósticos y ventas usando redes neuronales, demuestra la comparación entre técnicas clásicas de pronóstico y redes neuronales (Toro, Mejía, & Salazar, 2004). En dicho estudio se compara los métodos series de tiempo, promedio móviles y dobles promedios móviles con las redes neuronales (Toro, Mejía, & Salazar, 2004). Toro, Mejía y Salazar, nos comenta que las redes neuronales son útiles cuando el comportamiento es variable y el patrón del comportamiento es similar a lo largo del tiempo (2004). El método de series de tiempo no comparte la misma tendencia en comparación a las redes neuronales debido a que solo usan datos de periodos anteriores y pronostica sin tener en cuenta la época del año (Toro, Mejía, & Salazar, 2004). Por otro lado, otro estudio realizado por la Universidad de Carabobo compara la predicción de redes neuronales con diferentes métodos de series de tiempo (Rúales, & Laguna, 2014). Una vez definido los métodos Holt, Winters, ARIMA, y Redes Neuronales, se evaluó el comportamiento de cada método considerando el error cuadrático medio (Rúales, & Laguna, 2014). El resultado final del estudio demuestra que Redes Neuronales tiene el menor error en comparación al resto de métodos de series de

tiempo (Rúales, & Laguna, 2014). Asimismo, los errores de series de tiempo son muy similares entre ellos (Rúales, & Laguna, 2014).

Por otro lado, un estudio realizado en la universidad nacional de nordeste analiza el modelo de Redes Neuronales, Perceptrón Multicapa y Base Radial para la predicción del rendimiento académico de alumnos universitarios (Longoni, M., et al, 2010). El modelo de Perceptrón Multicapa está formado por una capa de entrada, un numero de capas ocultas y una capa de salida (Longoni, M., et al, 2010). En la capa oculta existen neuronas que reciben información por parte de las neuronas de la capa de entrada, para así generar un algoritmo de feedfowarding y entrenar sus neuronas (Longoni, M., et al, 2010). Por otro lado, la capa de entrada recibe datos históricos de información previa y los traspasa a la capa oculta, donde luego son traspasados a la capa de salida como respuesta del pronóstico (Longoni, M., et al, 2010). El estudio realizado por Longoni, M., et al, realizaron una división de la base de datos para así tener información de entrenamiento y de prueba en el estudio (2010). En la parte del entrenamiento se emplea el algoritmo en función a un aprendizaje supervisado de retro propagación y gradiente descendiente (Longoni, M., et al, 2010). En dicho estudio se pudo apreciar que el modelo Perceptrón Multicapa predice adecuadamente, teniendo un porcentaje de precisión del 78.2%, por lo tanto, tiene un rendimiento bueno al predecir (Longoni, M., et al, 2010). Se concluye en el estudio que las técnicas de Redes Neuronales Artificiales son una buena herramienta para predecir pronósticos y optar por un modelo adecuado de predicción (Longoni, M., et al, 2010). Asimismo, el ajuste y precisión que el modelo de Perceptrón Multicapa tiene en relación al modelo de Base Radial es superior al llevar a cabo su pronóstico (Longoni, M., et al, 2010).

### **3.2. Medida de Error**

La precisión es el determinante que decide el mejor método de uso de pronósticos (Sahu, & Kumar, 2013). Asimismo, la inexactitud de pronósticos genera riesgos en la cadena de suministros generando tres posibles situaciones. Las siguientes situaciones son: carencias de productos, trabajo atrasado, y excedentes de inventario, por ende, la precisión de los pronósticos mejora el rendimiento de

los pronósticos (Da Veiga, 2005). Debemos recalcar que los pronósticos siempre van a tener una medida de error (Burgaentzle, 2016). Según Nahmias (2009) el error es la diferencia entre el pronóstico y el periodo de la demanda real para el mismo periodo. Por lo tanto, una variación en la demanda genera dos tipos de errores, el positivo y el negativo. El error positivo representa un exceso de inventario, mientras que el error negativo representa lo contrario la falta de inventario (Arunraj & Ahrens, 2015).

Para poder realizar las medidas de error de pronósticos en el sector empresarial Hyndman, & Koehler, nos comentan que se debe utilizar medidas de error dependientes y en base a métodos porcentuales (2005). Las medias dependientes de escala son error cuadrático medio (MSE), raíz de error cuadrático medio (RMSE), y error medio absoluto (MAE) (Hyndman, & Koehler, 2005). Armstrong, nos comentan que el RMSE es preferido al MSE ya que está en la misma escala de los datos, y no es sensible en comparación al MAP (2001). Asimismo, el MSE es recomendado usar cuando se utiliza suavizamiento exponencial ya que evalúa la dispersión entre periodos (Amstrong,2001). Asimismo, otros autores como Chan, Kingsman & Wong (1999) reafirman que el RMSE es mejor indicador que el MAE, debió a que RMSE asignan más ponderación a los errores grandes, haciendo que esto sea un mejor criterio. Además, el RMSE genera una ponderación a los errores grandes donde es el mejor criterio al considerar que pronóstico es adecuado (Bereson, Levine & Krehbiel. 2001).

Según varios estudios la manera de poder definir y medir el método a utilizar o implementar es en base al error (Sahu & Kumar, 2013). En un estudio realizado en la universidad de Almería se definió la capacidad predictiva en los métodos Box- Jenkins y Holt, donde se utilizaron las medidas de error como Error medio absoluto (MAE) y Error porcentual medio absoluto (MAPE) (Jiménez, Abad, & Fernández, 2006). Asimismo, se consideró ambos métodos de errores y se midió que método tiene el menor error para determinar que método es óptimo (Jiménez, Abad, & Fernández, 2006). El Error porcentual medio absoluto (MAPE) es la herramienta más popular en la industria para calificar el porcentaje de aceptación del modelo pronosticado (Jiménez, Abad, & Fernández, 2006). Una de las ventajas que ofrece el Error porcentual medio absoluto (MAPE) es que proporciona la media del error en porcentaje, lo cual es fácil

de entender (Jiménez, Abad, & Fernández, 2006). Asimismo, Hyndman, & Koehler, (2005) mencionan que si el error del pronóstico se encuentra menor a 10% la calidad del pronóstico es buena, si esta entre 10 a 20% la calidad del pronóstico es moderada y finalmente si es mayor al 30% la calidad del modelo es pobre. Otro estudio realizado en la Universidad Popular Autónoma del Estado de Puebla por Arturo Contreras (2004), utiliza dos métodos de error para determinar el modelo óptimo en base a los resultados del error (Jiménez, Abad, & Fernández, 2006). Los dos métodos usados en dicho estudio son desviación media absoluta (MAD) y la señal de rastreo (TS) (Jiménez, Abad, & Fernández, 2006). En dicho estudio se analizó los métodos de series de tiempo en base al error para determinar el modelo de pronósticos, observando el modelo con el menor error se determinó que método es el óptimo (Jiménez, Abad, & Fernández, 2006).

#### **4. Metodología**

El presente estudio usa la metodología “Forecasting Process” que establece los pasos que se deben llevar a cabo para poder realizar un estudio de pronósticos de tiempos (Montgomery, Jennings & Kulahci, 2008). Estos pasos son la base de un proceso establecido en el libro de “Introduction to Time Series Analysis and Forecasting” que son los siguientes:

1. Definición del Problema
2. Recolección de Data
3. Análisis de Data
4. Selección y Validación del Modelo
5. Implementación del modelo
6. Monitoreo del modelo

Adicionalmente se utilizará una metodología conocida como “Focused Forecast” en el paso de selección y ajuste de modelo para poder determinar el modelo óptimo a utilizar. Los siguientes pasos de la metodología que se llevar a cabo son los siguientes:

#### **4.1. Definición del Problema**

La planificación de la empresa está en base al número de sartas de perforación proyectadas por el departamento de ventas. El departamento de ventas envía un pronóstico anual y mensual al departamento de planificación donde representa la estimación de la demanda que se consumirá al mes y al año. Asimismo, si existe alguna modificación del pronóstico el departamento de ventas se encarga de enviar dicha actualización. Se pudo identificar que existe problema debido a que los pronósticos no se alineaban con la realidad del consumo; haciendo que exista un incumplimiento de la demanda proyectada en relación al consumo verdadero. Al tener un pronóstico mayor al consumo se genera una alta cantidad de inventario. La relación del consumo con el pronóstico proyectado genera un error mayor al 50% de todas las sartas durante el 2019. Adicionalmente, la planificación de pronósticos se debe llevar a cabo en el departamento de planificación para así tener un control adecuado del pronóstico en relación al consumo.

#### **4.2. Recolección de Data**

La data utilizada en el estudio será proporcionada por la empresa. Se utilizará datos históricos del consumo y movimientos hechos de cada Sarta. Cada consumo realizado tiene número de unidades entregadas, modelos, y cliente de los cuales se consumieron. Asimismo, toda esta información nace de un documento generado y entregado al departamento de planificación, donde la data histórica fue generada a partir del 2016.


#### **4.3. Análisis de Data**

Durante este paso se debe llevar a cabo la limpieza y estructuración de los datos para verificar que los datos obtenidos sean precisos al ser evaluados en los pronósticos (Vejar, R. 2017). La data histórica que se maneja es a partir del 2016 y es obtenida mediante los pedidos de campo que se realizan al departamento de planificación. Se realizó un proceso manual para pasar todas las órdenes de campo desde el 2016 en adelante a un Excel para así tener una base de datos cuantitativa.

La data historia de una Sarta puede ser catalogada y clasificada por consumo total, consumo de serie, consumo de bomba y consumo de motor. Dentro de cada clasificación se encuentran modelos que

pertenecen a cada clasificación, donde se llevó a cabo un análisis de Pareto para determinar el mayor consumo de los modelos de series, bombas y motores. Los modelos con mayor consumo de cada clasificación se pueden observar en la Imagen 1. Cabe recalcar por temas de confidencialidad los modelos son acrónimos de los modelos reales de la empresa.

**Imagen 1:** Modelos con mayor consumo dependiendo su clasificación



Al determinar que modelos tienen un mayor consumo debido a su clasificación, se llevó a cabo un análisis del comportamiento de su data histórica para poder identificar si dicho modelo tiene algún tipo de tendencia, o estacionalidad. En base a los patrones de la data histórica se procedió a escoger el modelo apropiado en función a su consumo histórico.

#### 4.4. Selección y Validación del Modelo

Focused forecast nos ayudará a determinar qué modelo es apropiado para realizar pronósticos futuros. Para poder determinar qué modelo es óptimo para cada pronóstico se seleccionó modelos de series temporales y de series neuronales donde se verificó el Error porcentual medio absoluto (MAPE) para determinar si el modelo es apropiado. En función al Error porcentual medio absoluto (MAPE) se

determinó qué modelos encajan mejor a los patrones existentes de la data histórica de cada sarta. Los modelos de pronósticos que se seleccionaron para llevar a cabo los diferentes análisis son:

1. Redes Neuronales Perceptrón Multicapa
2. Promedios Móviles
3. Suavizamiento Exponencial Simple
4. Suavizamiento Exponencial Doble
5. Suavizamiento Exponencial Triple

Dichos modelos de pronósticos se llevaron a cabo para cada clasificación de la Imagen 1.

#### **4.5. Implementación del Modelo de Pronósticos**

Se llevará a cabo la implementación del modelo óptimo obtenido del focused forecast.

Adicionalmente se creará una base de datos donde se podrá ingresar los consumos realizados mes a mes.

Asimismo, se formulará los modelos óptimos en Excel o en otra plataforma para poder generar los pronósticos de los modelos óptimos.

#### **4.6. Monitoreo del Sistema de Desempeño**

La última fase de la metodología es poder monitorear y controlar el sistema de planificación creada e implementada en la empresa (Vejar, R. 2017). Debido a falta de tiempo durante el estudio esta etapa se omitirá y no se llevará a cabo.

### **5. Desarrollo**

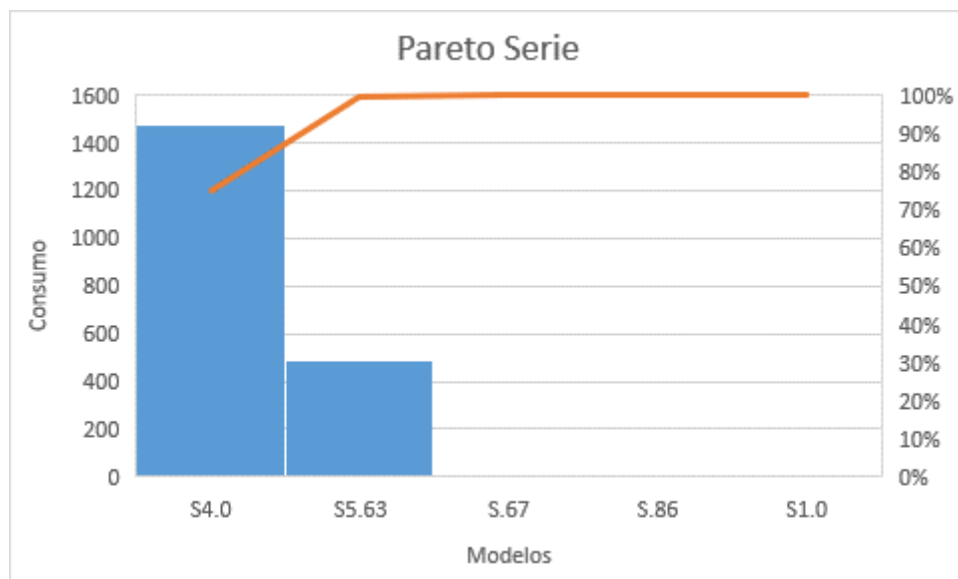
En esta sección de desarrollo, se presentará el proceso que se llevó a cabo de los siguientes puntos presentados en la metodología.

#### **5.1. Análisis de Data**

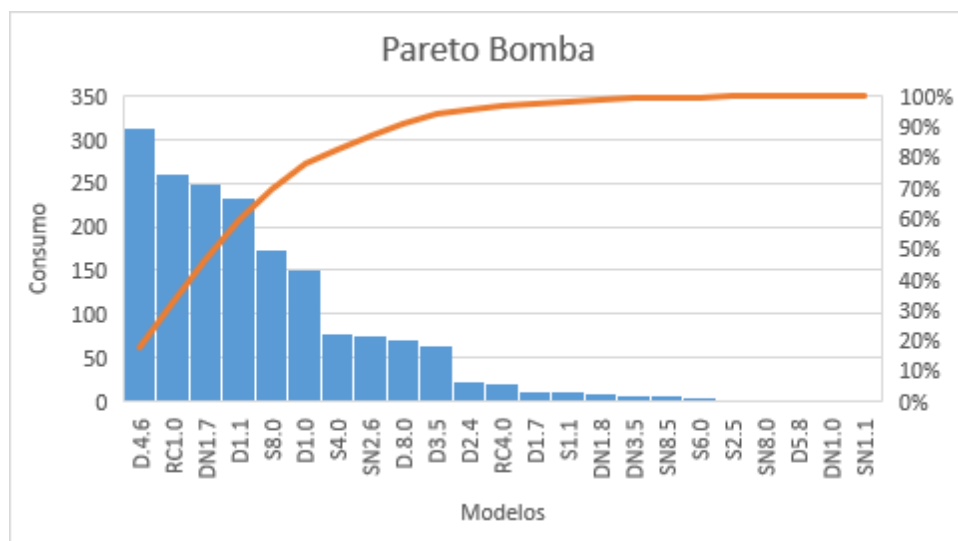
Como podemos observar la Imagen 1 existen 3 categorizaciones Bombas, Motores, y Series de las cuales hay diferentes modelos para cada una de las agrupaciones. En la categorización de bombas existen 24 diferentes modelos, mientras que para motores hay 33 modelos diferentes y finalmente para series hay

5 modelos diferentes. Para determinar que modelos son los más importantes en base al consumo se realizó un análisis de Pareto para cada categoría.

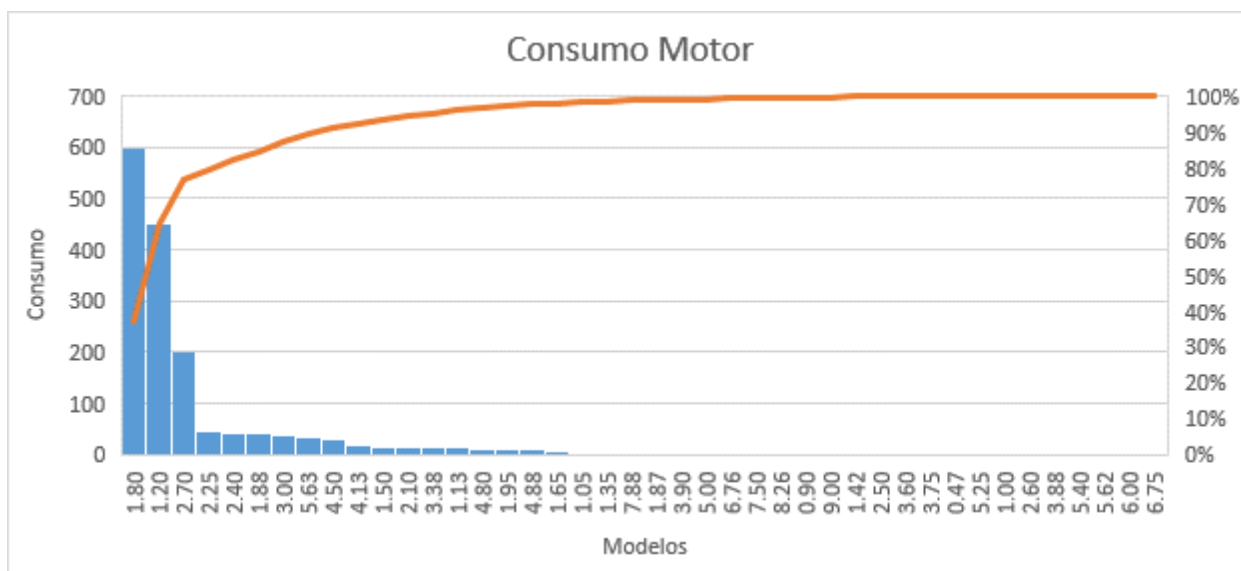
**Grafica 1:** Análisis de Pareto de la Categorización Serie



**Grafica 2:** Análisis de Pareto de la Categorización Bomba





**Grafica 3:** Análisis de Pareto de la Categorización Motor

De esta manera se obtuvo los diferentes modelos que se van a pronosticar de las diferentes categorías existentes. La siguiente tabla resume que modelos son los de mayor consumo según el análisis de Pareto y los cuales se llevarán a cabo en los pronósticos.

**Tabla 1:** Resumen de los modelos con mayor consumo según su clasificación

Bomba	Motor	Serie
D4.6	1.80	S4.0
RC1.0	1.20	S5.63
DN1.7	2.70	
D1.1		
S8.0		
D1.0		

Asimismo, como existen diferentes categorías dentro de una sarta, existen 5 diferentes clientes del consumo total. Estos cinco clientes no tienen el mismo consumo entre ellos; lo cual se identificó en un análisis de Pareto.

**Grafica 4:** Análisis de Pareto del Consumo de clientes



De igual manera se analizarán todos los clientes, ya que es una medida muy importante para la empresa. Una vez obtenido los modelos que se deben pronosticar se llevó a cabo el proceso de selección y validación del modelo donde se realizó los diferentes pronósticos mencionados anteriormente.

## 5.2. Selección y Validación del modelo

Para el proceso de selección y validación del modelo se utilizó la información recolectada durante el análisis de data para determinar que modelos tienen mayor consumo. Una vez hallados todos los modelos de cada característica con mayor consumo se buscó el mejor modelo de pronósticos. Se usó la metodología de focused forecast la cual realiza una comparación entre modelos seleccionados y selecciona el que menor Error porcentual medio absoluto (MAPE) tiene. Se realizó los siguientes pronósticos de series de tiempo en Minitab: Promedios Móviles, Suavizamiento Exponencial Simple, Suavizamiento Exponencial Doble, Suavizamiento Exponencial Triple; mientras que el pronóstico de

redes neuronales se utilizó el software Weka para llevar a cabo el pronóstico de Perceptrón Multicapa.

Este proceso descrito se realizó para cada una de los modelos de las categorías.

### 5.3.Resultados de la Selección y Validación del modelo

La tabla 2 muestra de manera resumida el mejor modelo que se obtuvo usando Minitab y Weka para cada categoría mencionada anteriormente.

**Tabla 2:** Modelos Óptimos según sus Categorías

<b>Categoría</b>	<b>Mejor Modelo</b>
Consumo Total	Perceptrón Multicapa
Serie S4.0	Suavizamiento Exponencial Triple
Serie S5.63	Promedio Móviles
Bomba D4.6	Promedio Móviles
Bomba RC1.0	Promedio Móviles
Bomba DN1.7	Promedio Móviles
Bomba D1.1	Promedio Móviles
Bomba S8.0	Promedio Móviles
Bomba D1.0	Promedio Móviles
Motor 1.2	Promedio Móviles
Motor1.8	Promedio Móviles
Motor 2.7	Promedio Móviles

Como podemos observar los diferentes pronósticos realizados en función al consumo se pudo identificar que el modelo óptimo para el consumo total es Perceptrón Multicapa, mientras que para series S4.0 es Suavizamineto Exponencial Triple y para el resto de categorías es Promedios Móviles. Asimismo, podemos observar en Anexos 1 el Error Porcentual Absoluto Medio (MAPE) del consumo total, donde el modelo Perceptrón Multicapa tiene el menor error de 13.53%. Por otro lado, Anexos 2 nos demuestra el Error Porcentual Absoluto Medio (MAPE) para ambas series, donde se puede identificar que para la serie S4.0 el menor error es el modelo de Suavizamiento Exponencial Triple con un MAPE de 18.57%, mientras que para la serie S5.63 el menor error es de Promedios Móviles con un MAPE del 37.38%. Asimismo, Anexos 3 y 4 nos demuestra el Error Porcentual Absoluto Medio (MAPE) de los modelos de bombas y motores, donde ambas tablas nos demuestran que el modelo con menor error MAPE es Promedio Móviles.

Asimismo, para poder determinar el consumo de cada cliente no se llevó a cabo los pronósticos individuales por cliente y por modelo en base a su categoría; debido a un resultado de un error porcentual medio absoluto (MAPE) muy elevado. Lo que se realizó en este proceso fue una partición porcentual del consumo global de cada categoría para bombas y motores dependiendo de su modelo. La tabla 3 nos resume la partición de los modelos de motores y bombas en base a su consumo total.

**Tabla 3.** Resumen de la Partición del Porcentaje de consumo de los modelos en base a su categoría

Partición del % en base al Consumo	
Bombas	
D4.6	22.78 %
RC1.0	19.83 %
DN1.7	18.71 %
D1.1	16.53 %
S8.0	12.59 %
D1.0	9.56 %
Motores	
1.2	37.02 %
1.8	51.26 %
2.7	11.17 %

Como podemos observar, la tabla 2 resume el porcentaje del consumo que tiene cada modelo en función al consumo total. Se distribuyó porcentualmente el consumo individual de cada modelo en relación al consumo global. Al tener determinado los porcentajes por modelos de bombas y motores se procedió a calcular individualmente el número de bombas y motores que cada modelo debe tener en relación al porcentaje calculado. Al tener una estimación de cuantas sargas se distribuyeron por modelo de bomba y motor, se realizó un análisis individual por modelo y cliente para así tener un estimado del pronóstico del cliente en base al modelo de bomba o motor.

**Tabla 4.** Resumen de la Partición del Porcentaje de consumo del modelo D4.6 de bomba en base a los clientes

Partición del % en base al Consumo	
D4.6 (22.78%)	
Cliente: P	31.79%
Cliente: S	47.53%
Cliente: C	8.33%
Cliente: I	12.03%
Cliente: k	0.30%

La tabla 4 muestra el análisis individual que se realiza por modelo específico de bombas y motores. En este caso se realizó el análisis para el modelo de bomba D4.6. Este modelo tiene un 22.78% del número de sartas totales. En función a esto se distribuye el número de sarta en base al cliente. Como podemos observar, los clientes también tienen una partición porcentual, ya que cada cliente tiene un consumo diferente. En base a su porcentaje se distribuye el número de sartas para cada cliente. Este mismo proceso se llevó a cabo para todos los modelos mencionados anteriormente de bombas y motores. Adicionalmente se calculó error porcentual medio absoluto para los meses ya transcurridos para determinar qué tan adecuado son las unidades distribuidas por cliente y por modelos como se puede observar en la tabla de Anexo 5, donde nos muestra el error porcentual absoluto medio (MAPE) por modelo de bomba y motor.

#### **5.4. Implementación del Modelo de Pronósticos**

Según la tabla 1 podemos analizar que modelos son óptimos para realizar nuestros pronósticos en base al consumo histórico, son Perceptrón Multicapa para el consumo global, Promedio Móviles y Suavizamineto Exponencial Triple para cada uno de los modelos dependiendo de su categoría. Para el pronóstico de Perceptrón Multicapa se realizó el pronóstico para todo el año el cual se realizó en el software de Weka, mientras que los pronósticos de promedios móviles se llevaron a cabo en el sistema Minitab, pero de igual manera se generó un Excel que genera los pronósticos de los modelos mes a mes. Finalmente, los resultados del pronóstico de Suavizamineto Exponencial Triple también se llevaron a cabo un Minitab, pero de igual manera se creó una visualización gráfica en el software Power Bi el cual

utiliza el algoritmo Suavizamiento Exponencial Triple para crear el pronóstico del año restante del consumo.

## **6. Conclusiones**

Tener una planificación de la demanda correcta dentro de una empresa es primordial ya que permite predecir el consumo futuro de productos y abastecerse de la cantidad correcta para no tener excesos en el lugar correcto y al momento correcto (Shefi, 2005). El sistema actual que maneja la empresa en base a los pronósticos generados por el departamento de ventas no es el óptimo debido falta de exactitud. Esto lleva a que los pronósticos se deben generar por el departamento de planificación.

En base al estudio realizado se determinó que para cada categoría existen diferentes modelos de pronósticos que se pueden utilizar, pero los óptimos para la empresa de estudio son de promedio móviles y Suavizamiento Exponencial Triple. Adicionalmente pronosticar por el consumo global genera un menor error porcentual medio absoluto ya que existe menor variación entre los datos históricos del consumo. Existe una mayor variación del consumo por categoría debido a que hay una distribución del consumo entre categorías generando que cada modelo tenga menores cantidades de datos históricos para llevar a cabo sus pronósticos.

Por otra parte, se debe analizar los resultados obtenidos de cada pronostico ya que puede existir altas fluctuaciones en los consumos, por lo que se recomienda que los pronósticos que se analicen sean de los consumos totales de bombas y motores. Asimismo, se debe optar siempre por el modelo con menor error porcentual medio absoluto ya que esta medida establece la exactitud y comportamiento del modelo. A pesar de que un pronóstico no siempre va a tener un cien por ciento de exactitud los pronósticos generados dan una buena estimación de lo que se va a consumir en el futuro en base al consumo del pasado.

Durante el trayecto del proyecto las limitaciones surgieron en la fase de recolección de data. Dicho proceso tuvo varios incidentes ya que la data histórica y su base de datos solo eran a partir del 2018 en adelante. Esto llevo a que se lleve a cabo un proceso manual para llenar la base de datos con órdenes

de compras desde el 2016, los cuales son los datos más antiguos que pudieron ser otorgados. Cabe recalcar que estas limitaciones no afectaron los resultados del proyecto si no solo fueron inconvenientes en dicha trayectoria.

Asimismo, otra limitación que se construyó durante la trayectoria de este proyecto fue en la generación de pronósticos de bombas y motores por cliente. Al tratar de pronosticar individualmente por cliente y su específico modelo de bomba o motor se obtuvo errores muy elevados de pronósticos, por lo cual se optó realizar la partición de motores por cliente y su modelo específico. Cabe recalcar que al realizar la partición individual se generó errores muy elevados en dichos pronósticos. Al tener errores muy elevados y no confiables se sugirió que los pronósticos solo sean analizados individualmente ya por modelo de bomba y motor o por el consumo total del cliente.

## 7. Referencias

- Aburto L., Weber R.; (2007). Improved supply chain management based on hybrid demand forecasts. *Applied Soft Computing*, 7, 136–144.
- Adhikari, R. & Agrawal, R. (enero de 2013). *An Introductory Study on Time Series Modeling and Forecasting*. LAP Lambert Academic Publishing.
- Armstrong, J.S. (2001). Evaluating forecasting methods. Chapter 14 in *Principles of forecasting: a handbook for researchers and practitioners*, ed., J.S. Armstrong. Kluwer Academic Publishers: Norwell, MA
- Burgaentzle, F. (2016). *Pronósticos y modelos de inventarios en la industria de alimentos: caso de estudio de una empresa láctea ecuatoriana*. (Tesis Pregrado). Universidad San Francisco de Quito, Quito.
- Cómo se extrae el petróleo - Todo el proceso. (octubre 20 del 2019). Recuperado en <https://www.repsol.com/es/energia-innovacion/la-energia-que-mueve-el-mundo/todo-sobre-el-petroleo/index.cshtml>
- Cortes, A., Bonilla, L., y Espitia, A. (2019). Planeación y control de la producción aplicada a una empresa de productos líquidos de aseo. *Semilleros*, 5(9), 1-16.
- Chen, F. & Ou, T. (2011). Constructing a sales forecasting model by integrating GRA and ELM: a case study for retail industry. *International Journal of Electronic Business Management*, Vol. 9, No. 2, pp. 107-121.
- Da Veiga, C., Da Veiga, C. & Duclós, L. (2010). The accuracy of demand forecast models as a critical factor in the financial performance of the food industry. *Future Studies Research Journal*, v.2, n.2, pp. 81-104.
- El mercado de servicios petroleros se expande. (octubre 6 del 2014). Recuperado en <https://www.revistalideres.ec/lideres/mercado-servicios-petroleros-expande.html>
- Gomez, J. (junio de 2012). *Metodología para calcular el abastecimiento de una empresa de partes automotrices: caso de estudio*. Instituto Politécnico Nacional. México, D.F.



Hillier, F. & Lieberman, G. (2010). *Introducción a la investigación de operaciones*. Mc Graw Hill: México

Hyndman, R. & Koehler, A. (2005). Another look at measures of forecast accuracy.

Jiménez, J., Abad, J., y Fernández, R. (2006). La capacidad predictiva en los métodos Box-Jenkins y Holt-Winters: Una aplicación al sector turístico. *Revista Europea de Dirección Y Economía de la Empresa*, 15(30), 185-198.

Jiménez, T. (29 de marzo de 2015). Las empresas de servicios petroleros salen de compras. Recuperado de <https://www.energia16.com/las-companias-de-servicios-petroleros-salen-de-compras/>

Juárez, A., Zúñiga, C., Flores, J., y Sánchez, D. (2016). Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos. *Estudios Gerenciales*, 32, 387-396.

Juárez, C., y Flores, J. (2016). Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos. *Estudios Gerenciales*, 31, 387-396.

La producción petrolera de Ecuador ronde los 539 000 barriles de crudo al día. (julio 11 del 2019). *El Comercio*.

Longoni, M., et al. (2010). Modelos de Redes Neuronales Perceptrón Multicapa y de Base radial para la predicción del rendimiento académico de alumno universitarios. *Congreso Argentino de Ciencia de la Computación*, 1-10.

Lema, J. (septiembre 28 del 2018). Jonathan Lema. Recuperado en <https://www.dynadrill.com.ec/el-futuro-de-las-empresas-de-servicios-petroleros-en-el-ecuador/>

Makridakis, S. & Hibon, M. (enero de 1979). Accuracy of Forecasting: An Empirical Investigation. *Journal of the Royal Statistical Society Series A*. 142 (2)

Montgomery, D., Jennings, C., y Kulahci, M. (2008). *Introduction to Time Series Analysis and Forecasting*. New Jersey. Wiley Interscience.

Pavisić, I., Mendoza, J. (2000). *Diseño de una política de gestión de inventarios de artículo*

independientes con tiempo de reposición y demanda estocásticas.

Pérez, R., Mosquera, S., y Bravo, J. (2012). Aplicación de modelos de pronósticos en producto de consumo masivo. *Biotecnología en el Sector Agropecuario y Agroindustrial*, 10(2), 117-125.

Rakicevic, Z., y Vujosevic, M. (2015). Focus Forecasting in Supply Chain: The case study of fast moving consumer goods Company in Serbia. *Serbian Journal of Management*, 10(1), 3-17.

Ríos, F., Martínez, A., Palomo, T., Cáceres, S., y Díaz, M. (2008). Inventarios probabilísticos con demanda independiente de revisión continua. *Ciencia Ergo*, 15(3), 251-258.

Ríos, R. (2007). Operaciones continuas 24 horas de fractura en pozos petroleros. (Tesis Pregrado). Universidad San Francisco de Quito, Quito.

Rodríguez, L. (2005). Cadena de demanda. (Tesis Pregrado). Universidad San Francisco de Quito, Quito.

Rúales, A., y Laguna, J. (2014). Comparación de predicción basada en redes neuronales contra métodos estadísticos en pronósticos de ventas. *Ingeniería Industrial. Actualidad y Nuevas Tendencias*, 5(12), 91-105.

Sahu, P., & Kumar, R. (2013). Demand Forecasting for Sales of Milk Product (Paneer) In Chattisgarh. *International Journal of Inventive Engineering and Sciences*, 1(9), 10-13.

Sandri, P. (2017). El petróleo aun será la mayor Fuente de energía del planeta en el 2040.

Santa Cruz R. & Correa C. (marzo 7 del 2017). Prevención de demanda intermitente con métodos de series de tiempo y redes neuronales artificiales: Estudio de caso. *DYNA*, Vol. 84, 203, 1-15.

Sarta de Perforación. (n.d.). Recuperado en <https://www.glossary.oilfield.slb.com/es/Terms/d/drillstring.aspx>

Sheffi, Y. (2005, Agosto 22). A Demand for Steady Supply. Recuperado abril 15, 2017, desde <http://sheffi.mit.edu/demand-steady-supply>

Toro, E., Mejía, D., y Salazar, H. (2004). Pronósticos de ventas usando redes neuronales. *Scientia Et*

Technica, 26, 25-30.

Total Market. (2019). Recuperado de [https://csimarket.com/Industry/Industry\\_Data.php](https://csimarket.com/Industry/Industry_Data.php)

Vejar, R. (2017). Mejoramiento e implementación de un sistema de planificación de demanda en una empresa distribuidora de farmacéuticos y análisis de datos de productos top en puntos de ventas seleccionados. (Tesis Pregrado). Universidad San Francisco de Quito, Quito.

Vidal, H., Lodoño, J., y Contreras, F. (2004) Aplicación de modelos de inventarios en una cadena de abastecimiento de productos de consume masivo con una bodega y N puntos de venta. Ingeniera y Competitividad.

Vieira, C. (n.d.). Schlumberger presentó XX Expo Conference Ecuador Oil & Power 2019. Recuperado de <https://www.spe-ecuador.org/schlumberger-presento-xx-expo-conference-ecuador-oil-power-2019>

Villavicencio, J. (2019) Introducción a series de tiempo. Link Click. 1-3.

Wright, C. & Mejía, S. (2017). Optimización del Proceso de compras de una empresa de alimentos mediante pronósticos de la demanda y planificación de manejo de inventario. (Tesis Pregrado). Universidad San Francisco de Quito, Quito.

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. Neurocomputing, 50, 159–175.

Viena. (noviembre 7 del 2019). El Consumo de petrolero supera en 2020 por primera vez los 100 millones de barriles diarios, según OPEP. Europapress.  
<https://www.europapress.es/economia/energia-00341/noticia-consumo-petroleo-superara-2020-primera-vez-100-millones-barriles-diarios-opep-20190711155754.html>

## 8. Anexos

### 8.1. Anexo 1:

**Tabla 5:** Resumen de los resultados del MAPE de los modelos de pronósticos obtenidos para el Consumo Total de Sartas

	<b>Error porcentual medio absoluto (MAPE)</b>	
	Consumo Total	
Promedio Móviles	15.46%	
SE. Simple	14.80%	
SE. Doble	16.87%	
SE. Triple	15.57%	
Perceptrón Multicapa	13.53%	

### 8.2. Anexo 2:

**Tabla 6:** Resumen de los resultados del MAPE de los modelos de pronósticos obtenidos para la categoría de Series

	<b>Error porcentual medio absoluto (MAPE)</b>	
	Serie S4.0	Serie S5.63
Promedio Móviles	19.28%	37.38%
SE. Simple	18.57%	39.38%
SE. Doble	19.34%	40.87%
SE. Triple	18.33%	38.65%
Perceptrón Multicapa	28.5%	171.00%

### 8.3. Anexo 3:

**Tabla 7:** Resumen de los resultados del MAPE de los modelos de pronósticos obtenidos para la categoría de Bombas.

	<b>Error porcentual medio absoluto (MAPE)</b>					
	Bomba D4.6	Bomba RC1.0	Bomba DN1.7	Bomba D1.1	Bomba S8.0	Bomba D1.0
Promedio Móviles	35.80%	31.95%	29.74%	31.66%	34.49%	31.66%
SE. Simple	55.99%	35.11%	47.30%	50.80%	44.76%	58.31%
SE. Doble	48.77%	34.40%	53.31%	58.31%	59.64%	50.80%
SE. Triple	46.97%	36.03%	50.4%	54.42%	57.16%	54.42%
Perceptrón Multicapa	1198%	37.66%	N/A	N/A	N/A	N/A

### 8.4. Anexo 4:

**Tabla 8:** Resumen de los resultados del MAPE de los modelos de pronósticos obtenidos para la categoría de Motores

	<b>Error porcentual medio absoluto (MAPE)</b>		
	Motor 1.2	Motor 1.8	Motor 2.7
Promedio Móviles	28.54%	21.50%	44.09%
SE. Simple	59.45%	32.43%	48.41%
SE. Doble	69.33%	35.79%	64.53%
SE. Triple	57.17%	33.55%	79.20%
Perceptrón Multicapa	185.18%	102.62%	182.39%

### 8.5. Anexo 5:

**Tabla 9:** Resumen de los resultados del MAPE de la partición de modelos de pronósticos de Bombas y Motores

	Bomba D4.6	Bomba RC1.0	Bomba DN1.7	Bomba D1.1	Bomba S8.0	Bomba D1.0	Motor 1.2	Motor 1.8	Motor 2.7
<b>Error MAPE</b>	51.67%	73.33%	56.67%	70.00%	50.00%	46.67%	85.11%	48.06%	100.00%