



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA INDUSTRIAL

TRABAJO DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERO INDUSTRIAL

TEMA:

“DISEÑO DE UN MODELO PARA EL PRONÓSTICO DE LA DEMANDA PARA
UNA EMPRESA EMBOTELLADORA DE AGUA PURIFICADA MEDIANTE REDES
NEURONALES”

AUTOR: JOSELYN ALEXANDRA CHICAIZA IPIALES

DIRECTOR: ING. ISRAEL DAVID HERRERA GRANDA MSC.

IBARRA – ECUADOR

2019



UNIVERSIDAD TÉCNICA DEL NORTE

BIBLIOTECA UNIVERSITARIA

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
CÉDULA IDENTIDAD:	DE	1003982715	
APELLIDOS NOMBRES:	Y	CHICAIZA IPIALES JOSELYN ALEXANDRA	
DIRECCIÓN:	PIMAMPIRO, ESPEJO Y ROCAFUERTE		
EMAIL:	jachicaiza@utn.edu.ec		
TELÉFONO FIJO:	-	TELÉFONO MÓVIL:	0979833181

DATOS DE LA OBRA	
TÍTULO:	DISEÑO DE UN MODELO PARA EL PRONÓSTICO DE LA DEMANDA PARA UNA EMPRESA EMBOTELLADORA DE AGUA PURIFICADA MEDIANTE REDES NEURONALES
AUTOR :	CHICAIZA IPIALES JOSELYN ALEXANDRA
FECHA:	
PROGRAMA:	PREGRADO
TITULO POR EL QUE OPTA:	INGENIERA INDUSTRIAL
ASESOR /DIRECTOR:	ING. ISRAEL HERRERA GRANDA MSC

2. CONSTANCIAS

El manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto la obra es original y que es el titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 25 días del mes de abril de 2019

EL AUTOR:


.....

Joselyn Alexandra Chicaiza Ipiales



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA INDUSTRIAL EN CIENCIAS APLICADAS

CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO A FAVOR DE LA
UNIVERSIDAD TÉCNICA DEL NORTE

Yo, Joselyn Alexandra Chicaiza Ipiales, con cédula de identidad Nro. 100398271-5, manifiesto mi voluntad de ceder a la Universidad Técnica del Norte los derechos patrimoniales consagrados en la Ley de Propiedad Intelectual del Ecuador, artículos 4, 5 y 6, en calidad de autor de la obra o trabajo de grado denominado: "DISEÑO DE UN MODELO PARA EL PRONÓSTICO DE LA DEMANDA PARA UNA EMPRESA EMBOTELLADORA DE AGUA PURIFICADA MEDIANTE REDES NEURONALES" que ha sido desarrollado para optar por el título de: INGENIERO INDUSTRIAL en la Universidad Técnica del Norte, quedando la universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia suscribo este documento en el momento que hago entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Técnica del Norte.

Firma

Nombre: Joselyn Alexandra Chicaiza Ipiales

Cédula: 100398271-5

Ibarra, mes del 2019



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA INDUSTRIAL EN CIENCIAS APLICADAS

DECLARACIÓN

Yo, Joselyn Alexandra Chicaiza Ipiales declaro que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Universidad Técnica del Norte puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normativa institucional vigente.

Firma

Nombre: Joselyn Alexandra Chicaiza Ipiales

Cédula: 100398271-5

Ibarra, mes del 2019



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA INDUSTRIAL EN CIENCIAS APLICADAS

CERTIFICACIÓN

Ing. Israel David Herrera Granda Director de Trabajo de Grado desarrollado por la señorita estudiante Joselyn Alexandra Chicaiza Ipiales.

CERTIFICA:

Que, el Proyecto de Trabajo de grado titulado “DISEÑO DE UN MODELO PARA EL PRONÓSTICO DE LA DEMANDA PARA UNA EMPRESA EMBOTELLADORA DE AGUA PURIFICADA MEDIANTE REDES NEURONALES”, ha sido elaborada en su totalidad por la señorita estudiante Joselyn Alexandra Chicaiza Ipiales bajo mi dirección, para la obtención del título de Ingeniero Industrial. Luego de ser revisada, considerando que se encuentra concluido y cumple con las exigencias y requisitos académicos de la Facultad de Ingeniería en Ciencias Aplicadas, Carrera de Ingeniería Industrial, autoriza su presentación y defensa para que pueda ser juzgado por el tribunal correspondiente.

.....
Ing. Israel David Herrera Granda MSc.

DIRECTOR DE TESIS

DEDICATORIA

A Dios y a la Virgen María por regalarme la vida y por estar conmigo en cada paso que doy, por iluminar mi mente y por haber puesto en mi camino a aquellas personas que han sido un apoyo y compañía durante todo el tiempo de estudio.

*A mis padres **Héctor Chicaiza y María Ipiales:***

Quienes han sido el motivo por el cual he cumplido uno de tantos sueños, además ellos son la razón de mi vida, un ejemplo a seguir y me han motivado a superarme como persona y como profesional inculcándome valores y principios.

*A mis hermanos **Vinicio y Ailyn Chicaiza Ipiales:***

Por estar conmigo, confiar en mí y apoyarme siempre, los quiero mucho y me siento muy orgullosa de ellos.

Y a todas esas personas que a pesar de no tener la oportunidad de estudiar han sabido emprender y salir adelante.

Joselyn Alexandra Chicaiza Ipiales

AGRADECIMIENTO

En el presente proyecto, agradezco a Dios y a la Santísima Virgen María dos seres perfectos quienes me han colmado de bendiciones, por tener un hogar lleno de amor y felicidad y por permitirme conocer personas realmente valiosas durante mi vida.

A mis padres Héctor Chicaiza y María Ipiales quienes me han apoyado incondicionalmente, brindado sus consejos, dado todo su cariño, su amor especialmente en esos momentos los momentos más desalentadores de la vida.

A mis hermanos Vinicio y Ailyn por permitirme compartir muchos momentos especiales llenos de alegría, amor, paz y felicidad. Además de motivarme para el alcance de mis metas.

A mi enamorado Cristian Chuquín, por ser un apoyo y una bendición de persona, acompañándome en este camino de aprendizaje educativo y personal.

A la Universidad Técnica del Norte, en especial a la Carrera de Ingeniería Industrial, por haberme permitido adquirir conocimientos, experiencias y consejos que servirán de guía para desempeñarme de una manera eficiente en el ámbito laboral y personal, además por darme la oportunidad de obtener mi título profesional.

A todos mis docentes quienes me motivaron, apoyaron y aconsejaron durante mi desarrollo profesional más allá de las aulas de clase.

A mi tutor Ingeniero Israel David Herrera Granda. MSc, quien ha sabido guiarme con su experiencia, conocimientos, sugerencias y por la motivación durante el periodo de realización de este proyecto.

A la empresa embotelladora de agua por darme la oportunidad de desarrollar mi trabajo de grado en sus instalaciones.

Y a todos mis amigos con quienes he compartido momentos de aprendizaje para la vida profesional y personal.

Joselyn Alexandra Chicaiza Ipiales

ÍNDICE

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE	ii
CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE GRADO A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE	iv
DECLARACIÓN	v
CERTIFICACIÓN DEL TUTOR	vi
DEDICATORIA	vii
AGRADECIMIENTO.....	viii
ÍNDICE	ix
RESUMEN.....	1
ABSTRACT.....	2
GLOSARIO DE TÉRMINOS.....	3
CAPÍTULO I: GENERALIDADES	5
1.1. ANTECEDENTES	5
1.2. PLANTEAMIENTO DEL PROBLEMA	7
1.3. OBJETIVOS	7
1.3.1. General.....	7
1.3.2. Específicos	7
1.4. JUSTIFICACIÓN.....	8
1.5. ALCANCE.....	9
CAPÍTULO II	10
2. MARCO TEÓRICO.....	10
2.1. PRONÓSTICOS DE LA DEMANDA	10
2.1.1. Definición de la demanda de un producto	10
2.1.2. Definición de pronosticar.....	10
2.1.3. Proceso de pronóstico	10
2.2. HORIZONTES DE TIEMPO	11
2.2.1. Pronóstico a corto plazo.....	12
2.2.2. Pronóstico a mediano plazo	12
2.2.3. Pronóstico a largo plazo.....	12
2.3. PATRONES DE DATOS EN LAS SERIES DE TIEMPO.....	13
2.3.1. Tendencia.....	14
2.3.2. El componente cíclico.....	14
2.3.3. Estacionalidad.....	15

2.3.4.	Patrón de horizontal (estacionario)	16
2.3.5.	Irregularidad o aleatoriedad:	16
2.4.	Análisis de la demanda de la serie histórica	17
2.4.1.	Coeficiente de variación	17
2.4.2.	Coeficiente de variabilidad	18
2.5.	Exploración de patrones de datos con análisis de auto correlación de Pearson....	18
2.5.1.	Definición de auto correlación.....	18
2.6.	MÉTODOS DE PRONÓSTICOS	19
2.6.1.	Cualitativos	19
2.6.2.	Cuantitativos	20
2.7.	REDES NEURONALES	20
2.7.1.	Definición general de una red neuronal	21
2.7.2.	Elementos básicos que componen una red neuronal.....	21
2.7.3.	Definición como método de pronóstico.....	21
2.7.4.	Proceso de pronóstico mediante redes neuronales.....	21
2.7.5.	Redes neuronales y regresiones lineales	22
2.7.6.	Intervalos de predicción.....	22
2.7.7.	Tipos de Redes Neuronales.....	23
2.7.8.	Aplicaciones de Redes Neuronales.....	25
2.8.	PRECISIÓN EN LOS PRONÓSTICOS	27
2.8.1.	El error de pronóstico.....	27
2.8.2.	Medidas de error para evaluar la precisión de los pronósticos.	28
2.9.	SOFTWARE DE APLICACIÓN R.....	33
2.9.1.	Definición	33
2.9.2.	Como funciona R	33
2.9.3.	Objetos en R.....	34
2.9.4.	Paquetes para pronósticos de la demanda.....	36
CAPÍTULO III.....		40
3.	METODOLOGÍA DE PRONÓSTICOS	40
3.1.	CARACTERIZACIÓN DE LA ORGANIZACIÓN ESTUDIADA	41
3.1.1.	Productos ofrecidos.....	42
3.1.2.	Clientes-sector.....	42
3.1.3.	Proveedores.....	42
3.1.4.	Recurso humano.....	42
3.1.5.	Misión	42
3.1.6.	Visión.....	43
3.1.7.	Mapa de procesos.....	43
3.1.8.	Contexto interno.....	43
3.2.	RECOLECCIÓN DE DATOS	45

3.2.1.	Paso de Registros	45
3.2.2.	Selección de Datos	45
3.3.	ANÁLISIS DE LA SERIE HISTÓRICA	46
3.3.1.	Caracterización de la demanda	47
3.3.2.	Coeficiente de variación y variabilidad	48
3.3.3.	Estudio de patrones de datos.....	48
3.3.3.3.	Descomposición de la serie histórica.....	56
3.3.4.	Análisis de datos extrapolativos.....	58
3.4.	SELECCIÓN DE PRONÓSTICOS	59
3.5.	DESARROLLO DE PRONÓSTICOS	60
3.5.1.	Metodología de Hanke y el software POM.....	60
3.5.2.	Metodología de IBM SPSS Statistics Versión 22.....	61
3.5.3.	Metodología de Software Forecast Pro.....	62
3.5.4.	Metodología de Redes Neuronales con R.....	63
CAPÍTULO IV.....		65
4.1.	INICIACIÓN DEL DESARROLLO DE LA RED NEURONAL.....	65
4.1.1.	Configuración de estacionalidad.....	65
4.1.2.	Análisis de tendencia	67
4.2.	Configuración estructura multicapa de la RN.....	68
4.3.	ENTRENAMIENTO DE LA RED NEURONAL Y PRONÓSTICOS MEDIANTE REDES NEURONALES.....	70
4.4.	SELECCIÓN DEL MODELO	71
CONCLUSIONES		73
RECOMENDACIONES		74
REFERENCIAS BIBLIOGRÁFICAS.....		75
ANEXOS.....		79

ÍNDICE DE FIGURAS

Figura 1. Fase operativa del proceso de pronóstico	11
Figura 2. Demanda registrada a lo largo de 4 años, con una tendencia de crecimiento y estacionalidad indicada.	13
Figura 3. Serie de tiempo del producto interior bruto desde 1950 con tendencia.....	14
Figura 4. Serie histórica con patrón cíclico.....	15
Figura 5. Serie histórica con patrón estacional.	15
Figura 6. Serie histórica con patrón horizontal o estacionario.	16
Figura 7. Serie histórica con variación irregular o aleatoria.	17
Figura 8. Clasificación de pronósticos.	19
Figura 9. Ejemplo de una red neuronal totalmente conectada.	21
Figura 10. Proceso de pronóstico de la red neuronal.	22
Figura 11. Tipos de Redes neuronales.	23
Figura 12. Una visión esquemática del funcionamiento de R.....	34
Figura 13. El software de aprendizaje profundo y la pila de hardware.....	37
Figura 14. Autorregresivo MLP para la predicción de series de tiempo.	39
Figura 15. Flujograma de metodología de la investigación.	40
Figura 16. Mapa de procesos	43
Figura 17. Flujograma del análisis de datos.....	46
Figura 18. Construcción de la serie de tiempo.....	47
Figura 19. Gráfico de autocorrelaciones.	49
Figura 20. Serie temporal desde el año 2016 hasta el 2019 de la empresa de estudio.....	56
Figura 21. Descomposición de la serie de tiempo.....	57
Figura 22. Prueba de Dickey-Fuller	57
Figura 23. Código valores perdidos y frecuencia.....	58
Figura 24. Código Resumen Estadístico	58
Figura 25. Diagrama de cajas.....	59
Figura 26. Datos de pedidos de la embotelladora en POM.....	60
Figura 27. Ingreso de datos a SPSS V.22.....	62
Figura 28. Estacionalidad por descomposición multiplicativa.	65
Figura 29. Código de fase2	66

Figura 30 Red neuronal con configuración en la capa de entrada-Fase 02.....	66
Figura 31. Pronóstico de la demanda fase 2.....	67
Figura 32. Tendencia mediante la descomposición multiplicativa	67
Figura 33. Código de la fase 3	68
Figura 34.Pronóstico de la fase 3	68
Figura 35.Código de fase 4	68
Figura 36. Fase 4 RN óptima	69
Figura 37. Fase 4 pronostico óptimo.....	69
Figura 38.Código y resultados de la fase final	70
Figura 39. Pronóstico óptimo final.....	70
Figura 40. Fase 2 RN óptimo.	71
Figura 41. Pronóstico de la embotelladora en POM usando el método ingenuo	88
Figura 42. Pronóstico de la embotelladora en POM usando el método suavización.	88
Figura 43. Pronóstico de la embotelladora en POM usando el método suavización exponencial con tendencia exponencial.	88
Figura 44. Resultado de pronósticos con SPSS primera parte	89
Figura 45. Figura 44. Resultado de pronósticos con SPSS segunda parte	90
Figura 46. Interfaz de fase 2 de programación.....	93

ÍNDICE DE TABLAS

Tabla 1. Evaluación ANOVA.	30
Tabla 2. Checklist con enfoque a pronósticos.....	44
Tabla 3. Datos de pedidos desde junio del 2015 hasta enero del 2019	45
Tabla 4. Datos de pedidos desde enero del 2016 hasta diciembre del 2018	46
Tabla 5. Caracterización del a demanda	48
Tabla 6. Análisis de tendencia	50
Tabla 7. Análisis de estacionalidad 1	51
Tabla 8. Análisis 2 de estacionalidad	52
Tabla 9. Análisis 3 de estacionalidad	53
Tabla 10. Análisis 4 de estacionalidad	54
Tabla 11. Análisis 5 de estacionalidad	55
Tabla 12. Resumen del comportamiento de la serie de tiempo.....	59
Tabla 13. Requisitos para selección del método de pronóstico. Fuente: Hanke (2010)	60
Tabla 14. Resumen de Métodos de pronóstico mediante el software POM	61
Tabla 15. Modelo automático según NNFOR.....	64
Tabla 16. Datos del pronóstico del año 2019.....	71
Tabla 17. Características de los modelos de pronóstico	72
Tabla 18. Modelo de pronósticos	79
Tabla 19. Tabla de autocorrelaciones.....	81
Tabla 20. Valores críticos de la distribución Chi-cuadrado. °.....	82
Tabla 21. Valores críticos de la distribución t de Student.....	84
Tabla 22. Valores de autocorrelaciones con la primera diferenciación	85
Tabla 23. Requisitos para selección del método de pronóstico	87
Tabla 24. Reporte de Resultados de pronósticos para el año 2019 de Forecast Pro V.05	91
Tabla 25. Resultados de pruebas con multicapas.....	94

RESUMEN

En el presente trabajo se muestra un modelo de pronóstico de la demanda con redes neuronales diseñado para un pequeño fabricante de agua purificada embotellada en Ecuador, el cual actualmente no cuenta con adecuadas metodologías para el pronóstico de la demanda ocasionándole problemas por incumplimiento de los pedidos a clientes, exceso de inventario y pérdidas económicas. No obstante, al trabajar con predicciones acertadas la empresa tendría una visión anticipada de lo que necesitará en el futuro para satisfacer su demanda de productos, con la cual será capaz de organizar adecuadamente su cadena de suministros; es decir, garantizar un uso razonable y a tiempo de los recursos. Para dar solución a los problemas que enfrenta la empresa se inició con el levantamiento de la demanda histórica de botellones durante los últimos 36 meses a través de registros de los pedidos de clientes. Para la construcción de la serie histórica se establecieron como variables de entrada las fechas y los volúmenes de demanda ocurridos. Luego se pasa al diseño de modelos de pronósticos fundamentados en métodos clásicos y de redes neuronales multicapa, los cuales se evaluaron por medio de indicadores cuantitativos del error. La aplicación de estos métodos se realizó mediante el lenguaje de programación R. A continuación, se incluye una etapa de entrenamiento y mejora de la red y se evalúa contra los resultados de los métodos clásicos de pronósticos, a partir del mejor modelo se pronosticó los próximos 12 meses a futuro. Finalmente se demuestra la factibilidad del uso de las redes neuronales en el pronóstico de la demanda de botellones de agua purificada.

ABSTRACT

This paper shows a neural networks-based demand forecasting model designed for a small manufacturer of bottled water in Ecuador, which currently doesn't have adequate demand forecast methodologies, causing problems of customer orders noncompliance, inventory excess and economic losses. However, by working with accurate predictions, the manufacturer will have an anticipated vision of future needs to satisfy the demand for manufactured products, in other words, to guarantee on time and reasonable use of the resources. To solve the problems that this small manufacturer must face a historic demand data acquisition process was done through the last 36 months customer order records. In the construction of the historical time series, that was analyzed, demand dates and volumes were established as input variables. Then the design of forecast models was done, based on classical methods and multilayer neural networks, which were evaluated by means of quantitative error indicators. The application of these methods was done through the R programming language. After this, a stage of training and improvement of the network is included, it was evaluated against the results of the classic forecasting methods, and the next 12 months were predicted by means of the best obtained model. Finally, the feasibility, of the use of neural networks in the forecast of demand for purified water bottles, is demonstrated.

Glosario de términos

Pronosticar

Predecir el futuro con la mayor precisión posible, dada toda la información disponible, incluidos los datos históricos y el conocimiento de cualquier evento futuro que pueda afectar los pronósticos.(Hyndman & Athnasopoulos, 2018)

Planificación

Es una respuesta a los pronósticos y objetivos. La planificación implica determinar las acciones apropiadas que se requieren para que sus pronósticos coincidan con sus objetivos. (Hyndman & Athnasopoulos, 2018)

Red neuronal

Sistema de computación compuesto por un gran número de elementos de procesos muy interconectados, elementos simples, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas (Matich, 2001).

Redes neuronales artificiales

Son redes masivamente interconectadas en paralelo de elementos simples, usualmente adaptativos y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real de la misma manera que hace el sistema nervioso biológico (Matich, 2001).

Autocorrelación

Es la correlación entre una variable atrasada uno o más periodos consigo misma. Correlograma o función de autocorrelación es la representación gráfica de las autocorrelaciones para varios retrasos en una serie de tiempo (Hanke, 2010).

Perceptrón

Un perceptrón es un algoritmo de clasificación que puede hacer una clasificación basada en una función de predictor lineal que combina pesos o parámetros del vector de características. Es decir, es una unidad básica de la red neuronal artificial que toma múltiples entradas y produce salidas binarias. En terminología de aprendizaje automático, es un algoritmo de aprendizaje supervisado que puede clasificar una entrada en clases binarias 0 o 1. (Ramasubramanian & Singh, 2019)

Época

Hacer referencia a cada iteración sobre todos los datos de entrenamiento. (Chollet & Allaire, 2017)

Axón

Es el canal por donde corre la información., es decir, las neuronas se encargan de recibir información a través del axón. (Salcedo, 2018)

Capa

Una capa es un módulo de procesamiento de datos que toma como entrada uno o más tensores y que genera uno o más tensores.(Chollet & Allaire, 2017)

Capa oculta

La unidad oculta es una dimensión en el espacio de representación de la capa. (Chollet & Allaire, 2017)

Parsimonia

La parsimonia se refiere al conjunto de metodologías que radican en la idea que la mejor hipótesis para explicar un proceso es aquella que requiere el menor número de supuestos.(Hernández, 2004)

CAPÍTULO I: GENERALIDADES

1.1. Antecedentes

Dentro del enfoque empresarial, los pequeños y grandes negocios dedicados a la manufactura se enfrentan diariamente a entornos inciertos, uno de los más representativos es el estudio y pronóstico de la demanda de productos que los clientes requieren de un cierto fabricante. Es decir, si este último fuera capaz de conocer anticipadamente lo que sus clientes requieren este sería capaz de abastecerse anticipadamente de materias primas, repuestos e insumos sin caer en adquisiciones innecesarias y en el desperdicio de sus recursos económicos. Lo cual implica una ventaja competitiva y es la base para efectuar una adecuada gestión de una cadena de suministros.

El uso adecuado de los recursos en un pequeño negocio es un aspecto de gran importancia sobre todo porque este aún se encuentra en etapas de desarrollo y en los cuales una inadecuada decisión les provocaría grandes afectaciones llegando en algunos casos a ocasionar el cierre de sus operaciones.

Dentro del campo del pronóstico de la demanda y más específicamente el pronóstico de la demanda de productos terminados se han realizado varios estudios entre los cuales se puede citar al trabajo de Aburto en el año 2017, el cual desarrolla un enfoque híbrido para el pronóstico de la demanda de productos terminados partiendo del análisis de un modelo ARIMA e introduciéndolo en una red neuronal la cual intenta reproducir los patrones de una serie histórica obtenida sobre la demanda de productos de consumo diario en un supermercado (Aburto & Weber, 2007).

Por otra parte, Saha en el año 2014 propone la implementación de un modelo genérico de pronóstico de la demanda de servidores basado en redes neuronales (RN) el cual usa una demanda histórica de 52 semanas y se modificaron sus parámetros de tal modo que se puede asegurar un rango de precisión del pronóstico entre el 84 y 89% (Saha, Lam, & Boldrin, 2015).

El trabajo de Slimani en el año 2015 se enfoca en encontrar la estructura óptima de perceptrón de múltiples capas (MPL) para el pronóstico de la demanda de los productos de un supermercado en Marruecos y también se plantea la idea de implementar dicho pronóstico con RN en una cadena de suministro corta con un enfoque en teoría de juegos(Slimani, El Farissi, & Achchab, 2016).

Abraham et al. En el año 2017 proponen el diseño, entrenamiento y simulación de una RN para el pronóstico de la demanda de soja producida y exportada en Mato Grosso – Brasil, dicho modelo se implementó en el software Matlab, y los resultados de este pronóstico indicaron anticipadamente que la demanda se incrementaría en alrededor de un 26% en comparación con el año anterior, lo cual implicó que los productores incrementen su producción, movilizand o alrededor de 6 millones de toneladas de soja en los 5 primeros meses del año 2017 (Abraham, dos Reis, Colossetti, de Souza, & Tolo i, 2017).

Actualmente las aplicaciones de las RN en el pronóstico de la demanda de productos han diversificado su campo de acción, por ejemplo, Fu et al. En el año 2018 proponen un enfoque integrando entre RN y un método paramétrico para el pronóstico de la demanda intermitente de semiconductores en Taiwán (Fu, Chien, & Lin, 2018), Por otro lado Ezekwesili et al. Prueban modelos de pronóstico basados en RN y métodos de Bootstrap para mejorar la precisión del pronóstico de la demanda de repuestos de aviones comerciales(Ezekwesili, Shahzad, Baboli, & Tonadre, 2018), Mientras que Yang et al. En el año 2018 en China, colectan información de ventas en más de 10 millones de puntos de ventas de una franquicia de productos de panadería con los cuales construyen series históricas y se usan para pronosticar la demanda de productos a corto plazo o por horas por medio de redes neuronales(Yang & Sutrisno, 2018).

1.2.Planteamiento del problema

La empresa estudiada en el presente trabajo es un pequeño negocio de manufactura y distribución de botellones de agua embotellada que opera en la zona norte de Ecuador, entre sus políticas de servicio al cliente se ha implementado un indicador de puntualidad de las entregas, el mismo que se inicialmente se encontraba en un 80%. No obstante, se pretende maximizarlo con el uso de un modelo de pronóstico que permita planificar los recursos de la empresa para consecuentemente elevar la puntualidad en la entrega de los pedidos.

El objetivo de este estudio es maximizar el indicador de puntualidad en entregas al cliente para consecuentemente elevar la satisfacción de los clientes, mediante el modelo de pronóstico de redes neuronales.

El estudio de la demanda de botellones a través del tiempo, busca analizar y predecir su comportamiento a futuro utilizando la metodología de redes neuronales artificiales, además de diagnosticar el proceso de pronósticos con el que contaba inicialmente la empresa. Finalmente se diseña un marco para el pronóstico de la demanda en la empresa de estudio.

1.3.Objetivos

1.3.1. General

Diseñar un modelo para el pronóstico de la demanda de botellones de agua de la empresa local mediante redes neuronales.

1.3.2. Específicos

- Determinar la metodología más adecuada a través de una versión del estado del arte.
- Realizar el diagnóstico del proceso de pronósticos actual de la empresa.
- Gestionar los datos de la demanda para analizar su comportamiento.
- Diseñar y evaluar un modelo de pronóstico.

1.4. Justificación

“El diagnóstico del Ministerios de Industria y Productividad (MIPRO) detectó problemas en acceso a mercados, gestión empresarial, innovación, acceso a financiamiento, calidad y asociatividad” (El Telégrafo, 2017). Con lo cual se justifica la investigación, es decir con el objetivo de innovar el proceso productivo para hacerlo más eficiente, ya que al obtener un pronóstico con un porcentaje de error pequeño resulta relativamente más precisa la planificación de la producción de la microempresa de estudio, e inclusive la adquisición de materia prima (MP), repuestos e insumos.

Este proyecto también se justifica con el objetivo 5 del eje de economía al servicio de la sociedad del Plan Nacional de Desarrollo el cual menciona el desarrollo de las capacidades del entorno y productivas para alcanzar la soberanía alimentaria y el buen vivir (SENPLADES, 2017), al obtener un modelo óptimo de pronóstico de la demanda la capacidad productiva de la planta puede reorganizarse para cumplir con las metas de producción.

La función de los sistemas de información gerencial no se puede limitar a medir el funcionamiento financiero pasado. En tiempos de crisis el proceso de presupuestación y los pronósticos son críticos para el planeamiento eficaz y para la toma de decisiones cotidiana (PricewaterhouseCoopers, 2009).

El responsable de la logística con frecuencia desafía la necesidad de apoderarse la labor de generar este tipo de información sobre la planeación de corto plazo, el control de inventarios, determinar la magnitud de los pedidos o la programación del transporte (Ballou, 2004).

1.5.Alcance

El proyecto de tesis está orientado a la investigación para diseñar un modelo para determinar el pronóstico de la demanda de botellones de agua purificada, la cual está ubicada en la ciudad de Ibarra, en la provincia de Imbabura.

El modelo de pronóstico que se pretende alcanzar se describe como un modelo cuantitativo, a mediano plazo (anual) cuya variable es la demanda mediante el lenguaje de programación R.

La demanda de estudio comprende al producto A de la empresa que son los botellones de agua purificada de 20 litros cada unidad, el cual se produce a través de ósmosis inversa

CAPÍTULO II

2. Marco Teórico

En este capítulo se realiza la indagación del estado del arte. Se pretende contribuir al estudio mediante conceptos fundamentales, necesarios para comprender el desarrollo de la investigación. De manera que va acorde al orden metodológico que se sigue para obtener los resultados, además de que permite una retroalimentación, necesaria para comprender y darle sentido al presente documento.

2.1.Pronósticos de la demanda

2.1.1. Definición de la demanda de un producto

La demanda de un producto se define como el volumen total que sería adquirido de dicho producto por un grupo de compradores determinado, en un periodo de tiempo fijado y a partir de unas condiciones de entorno y esfuerzo comercial determinados (Sellers Rubio & Casado Díaz, 2013).

2.1.2. Definición de pronosticar

Es realizar un enunciado sobre el valor futuro de una variable de interés, fundamentado ya sea por el análisis de datos históricos disponibles, por el juicio de expertos en el tema o por una combinación de ambas cosas(Montemayor, 2013).

2.1.3. Proceso de pronóstico

Este proceso se compone de dos fases, nivel estratégico y nivel operativo.

2.1.3.1.Fase 1: Nivel estratégico

En el nivel estratégico, se toman decisiones en cuanto a qué pronosticar, cómo usar los pronósticos y quién será responsable de la generación de los pronósticos(Hanke, 2010).

2.1.3.2. Fase 2 Nivel operativo

La fase operativa del pronóstico consiste en la recopilación de datos, la generación del pronóstico y la evaluación de los pronósticos en curso. El proceso del pronóstico es como cualquier otro proceso se debe controlar y verificar, caso contrario sus efectos se compararía con una espiral fuera de control.(Hanke, 2010). En la figura 1 se puede apreciar mejor el proceso de esta fase.

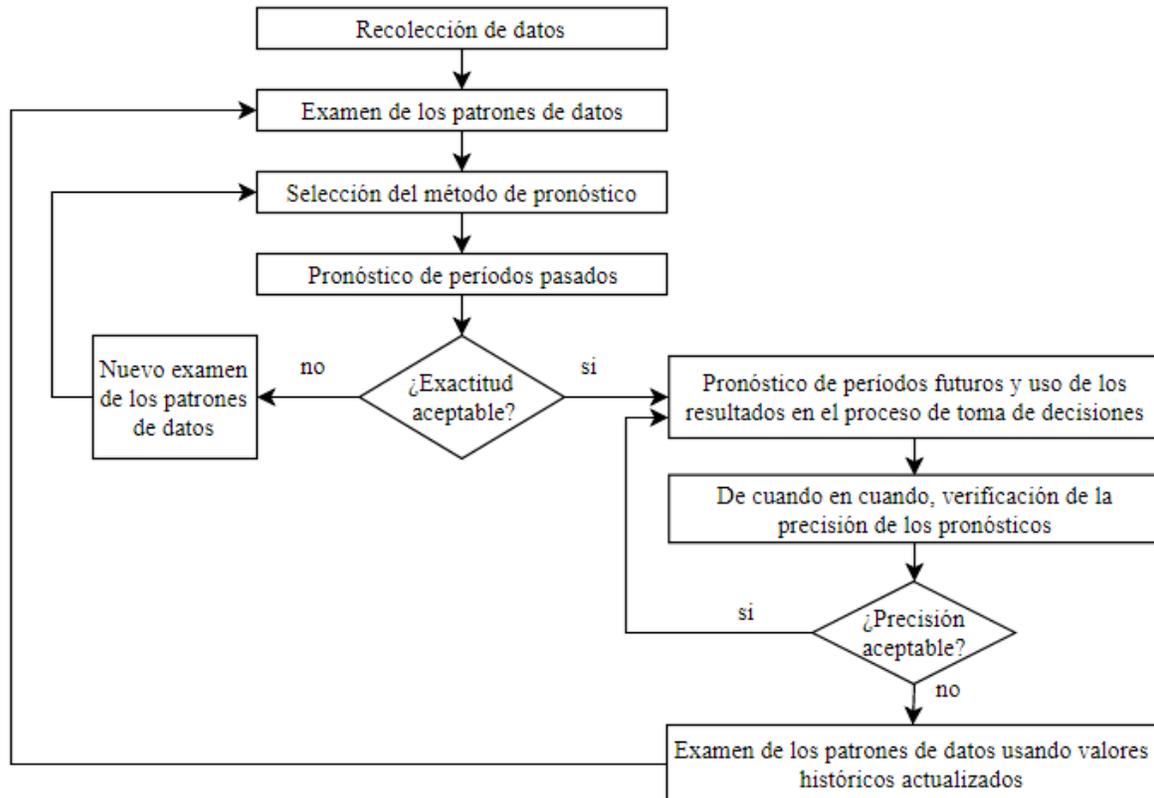


Figura 1. Fase operativa del proceso de pronóstico
Fuente: (Hanke, 2010)

2.2. Horizontes de tiempo

Según Heizer y Render, un pronóstico se puede clasificar por el horizonte de tiempo futuro que cubre(Heizer, Render, & Munson, 2017). Los horizontes de tiempo se dividen en tres categorías:

2.2.1. Pronóstico a corto plazo

Este pronóstico asume un período de tiempo de hasta 1 año, pero de forma general es inferior a 3 meses. Es útil para la realización de la planificación de compras, planificación de trabajos, niveles de fuerza de trabajo, asignaciones de trabajo y niveles de producción.

2.2.2. Pronóstico a mediano plazo

Un pronóstico a mediano plazo, o intermedio, generalmente tiene desde 3 meses hasta 3 años. Se utiliza en la planificación de ventas, la planificación de la producción y el presupuesto, la presupuestación en efectivo y el análisis de varios planes operativos.

2.2.3. Pronóstico a largo plazo

Generalmente comprende un lapso de tiempo de 3 años o más, los pronósticos a largo plazo se utilizan en la planificación de nuevos productos, gastos de capital, ubicación o expansión de instalaciones, e investigación y desarrollo.

2.2.4. Diferencias de pronósticos a mediano y largo plazos vs corto plazo

Los pronósticos a mediano y largo plazo se distinguen de los pronósticos a corto plazo por tres características:

- Primero, los pronósticos intermedios y de largo alcance tratan problemas más completos que respaldan las decisiones de gestión con respecto a la planificación, los productos, las plantas y los procesos.
- En segundo lugar, el pronóstico a corto plazo generalmente emplea metodologías diferentes a las del pronóstico a largo plazo. Las técnicas matemáticas, como los promedios móviles, el suavizado exponencial y la extrapolación de tendencias, son comunes a las proyecciones de corto plazo. Los métodos más amplios y menos cuantitativos son útiles para predecir problemas como si un nuevo producto, por

ejemplo, si el grabador de discos ópticos, debería introducirse en la línea de productos de una empresa.

- Finalmente, los factores que influyen en la demanda cambian todos los días por ello, los pronósticos a corto plazo tienden a ser más precisos que los pronósticos a largo plazo. Por lo que, a medida que el horizonte temporal aumenta, es probable que la precisión del pronóstico sea menor. Por ello se dice que las previsiones de ventas deben actualizarse regularmente para mantener su valor e integridad. Después de cada período de ventas, los pronósticos deben ser revisados y revisados.

2.3.Patrones de datos en las series de tiempo

Para el análisis de las series de tiempo se requiere desglosar datos pasados en patrones o componentes y luego proyectarlos hacia adelante. La figura 2 ilustra una demanda en un período de 4 años. Muestra el promedio, la tendencia, los componentes estacionales y las variaciones aleatorias en torno a la curva de demanda. La demanda promedio es la suma de la demanda de cada período dividida por el número de períodos de datos.(Heizer et al., 2017)

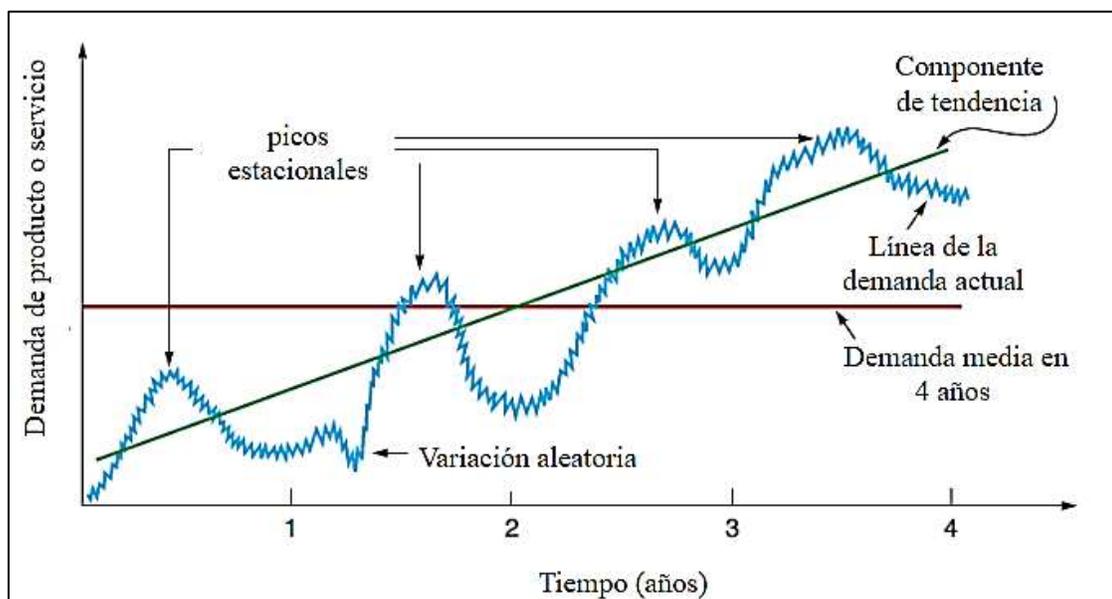


Figura 2. Demanda registrada a lo largo de 4 años, con una tendencia de crecimiento y estacionalidad indicada.
Fuente: (Heizer et al., 2017)

2.3.1. Tendencia

La tendencia es el componente de largo plazo que representa el incremento o decremento en la serie de tiempo, durante un extenso periodo (Hanke, 2010). Este patrón existe cuando las series crecen o decrecen consistentemente sobre un largo periodo de tiempo. Las series que muestran tendencia están influenciadas por la actividad económica, un ejemplo de estas series es el Producto Interno Bruto, PIB, que mide la producción de bienes y servicios de un país.(Montemayor, 2013)

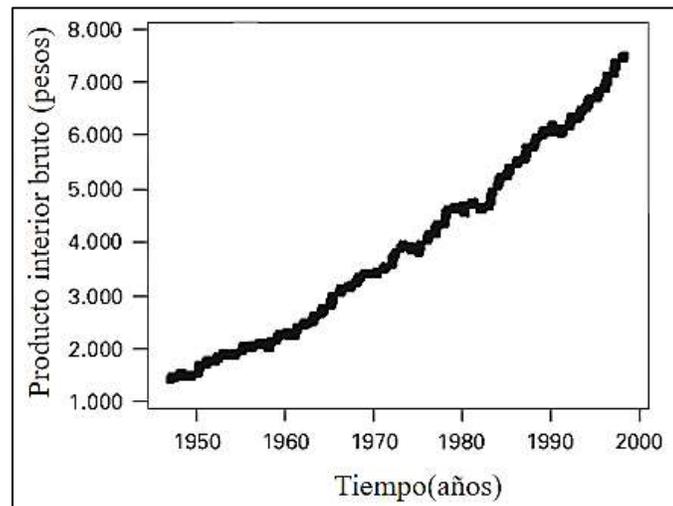


Figura 3. Serie de tiempo del producto interior bruto desde 1950 con tendencia.
Fuente: (Newbold, Carlson, & Thorne, 2008)

2.3.2. El componente cíclico

El componente cíclico es la oscilación en torno a de la tendencia (Hanke, 2010). El comportamiento de este patrón existe cuando una serie tiene tendencia, se puede observar un patrón adicional, un crecimiento o decrecimiento constante cada cierto tiempo, tres años o más, por ejemplo en México marcadamente cada cambio de sexenio, cada seis años, se observaba una caída en el comportamiento del PIB, haciendo visible un patrón cíclico (Montemayor, 2013).

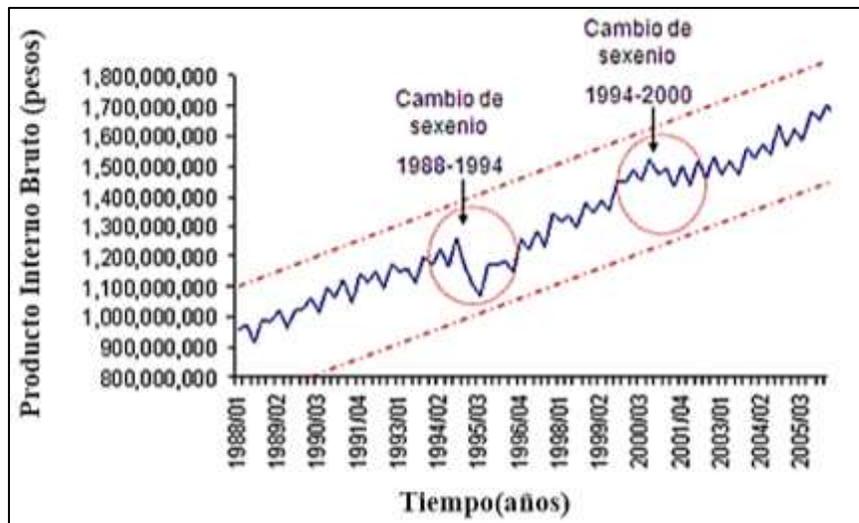


Figura 4. Serie histórica con patrón cíclico.

Fuente: (Montemayor, 2013)

2.3.3. Estacionalidad

La estacional es un patrón de cambio que se repite año tras año (Hanke, 2010). Cuando una serie se ve influenciada por factores que se repiten en la misma temporada del año, se dice que tiene un patrón estacional. Ejemplos de variables con patrón estacional son las ventas de trajes de baño, con un incremento marcado en cada verano, las ventas de artículos navideños, con un incremento marcado cada diciembre, las monedas y billetes en poder del público, etc. El patrón estacional sólo puede existir en series que se miden con una frecuencia mensual, bimestral, trimestral, etc., pero no anual, y mide la variación que hay en una serie cada enero, febrero, marzo, entre otros (Montemayor, 2013).

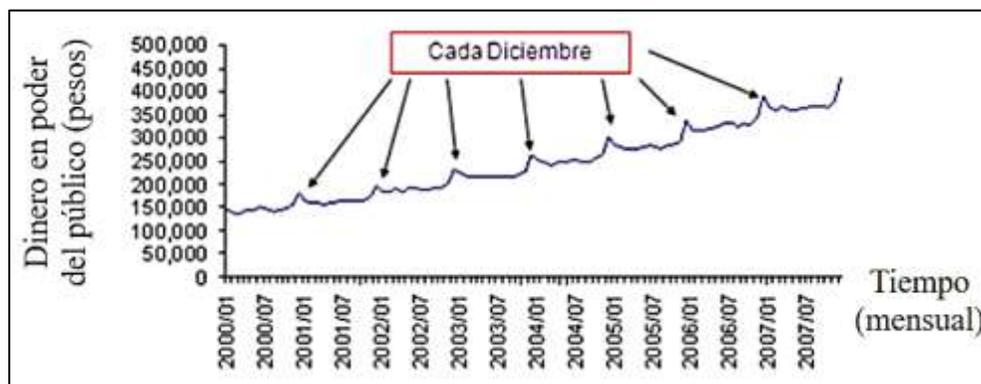


Figura 5. Serie histórica con patrón estacional.

Fuente: (Montemayor, 2013)

2.3.4. Patrón de horizontal (estacionario)

Cuando los valores de una variable oscilan a través del tiempo alrededor de un nivel constante o medio, existe un patrón horizontal o estacionario. Un ejemplo de una variable con este comportamiento son las ventas de sal, que demuestran un comportamiento estable, y no incrementan o disminuyen consistentemente a través del tiempo como se puede ver en la figura 6 (Montemayor, 2013).

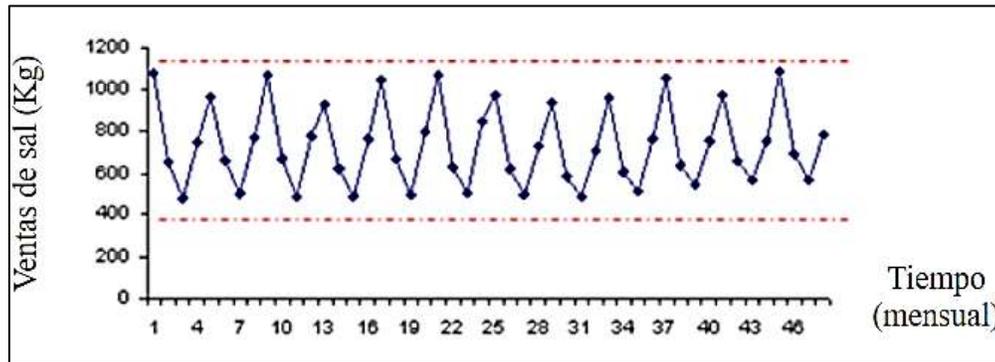


Figura 6. Serie histórica con patrón horizontal o estacionario.

Fuente: (Montemayor, 2013)

2.3.5. Irregularidad o aleatoriedad:

La variación irregular o aleatoria está presente en los patrones horizontales, de tendencia y estacionalidad; son cambios en la serie de corto plazo que por su aleatoriedad son difíciles modelarlos matemáticamente y por consecuencia no se proyectan al futuro para realizar pronósticos. Un ejemplo son las variaciones observadas en la serie histórica del tipo de cambio, pesos por dólar, atribuidas a especulaciones debido a movimientos sociales, acontecimientos políticos, desastres, etc. que influyen en las decisiones de los inversionistas (Montemayor, 2013).

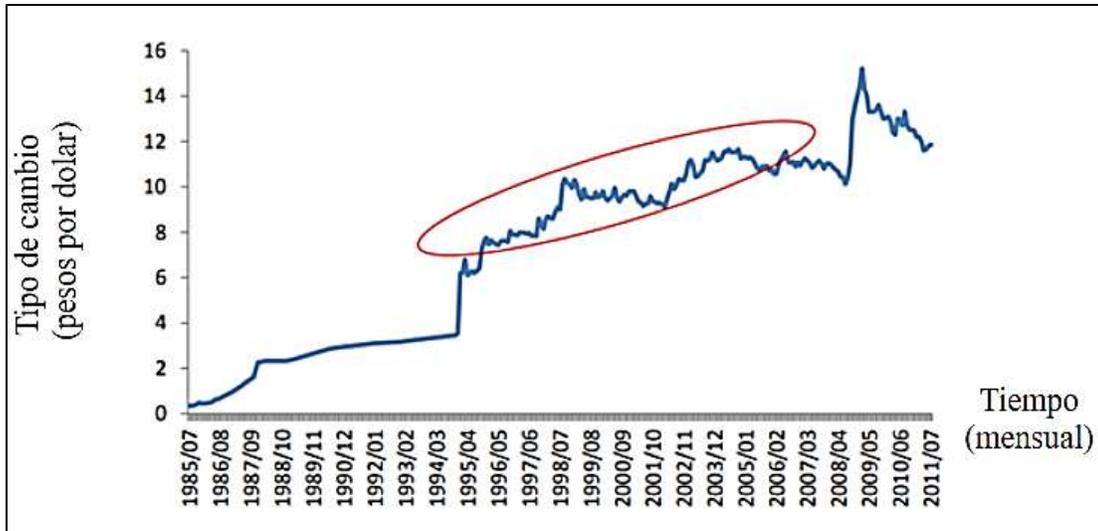


Figura 7. Serie histórica con variación irregular o aleatoria.
Fuente: (Montemayor, 2013)

2.4. Análisis de la demanda de la serie histórica

2.4.1. Coeficiente de variación

Una forma de determinar si una demanda es perpetua o errática constituye en calcular el coeficiente de variación de la distribución de la demanda. Aplicando la ecuación [1]. Como se observa, el coeficiente de variación está definido por la demanda promedio sobre la desviación estándar (Vidal, 2010).

$$VC = \frac{\frac{\sum_{t=1}^n x_t}{n}}{\sqrt{\frac{\sum_{t=1}^n (x_t - \bar{x})^2}{n-1}}} \quad [1]$$

x_t = Demanda en cada período t

n = cantidad de períodos

\bar{x} = media

Si el coeficiente de variación es mayor o igual que 1, es decir 100%, la demanda puede clasificarse como errática. En caso contrario, la demanda puede considerarse estacionaria o perpetua. De manera que, entre menor sea el coeficiente de variación de la demanda, menor es su grado de aleatoriedad (Vidal, 2010).

2.4.2. Coeficiente de variabilidad

Este coeficiente se determina asumiendo que la demanda es una variable aleatoria discreta sobre el período de análisis, cada una con probabilidad igual a $1/N$ (Vidal, 2010). El coeficiente de variabilidad se encuentra definido en la ecuación [2].

$$VC = \frac{N \sum_{j=1}^N D_j^2}{[\sum_{j=1}^N D_j]^2} \quad [2]$$

Donde:

D_j = Demanda en cada período

N =cantidad de períodos

Si $VC > 0.2$ entonces la demanda es errática, caso contrario se puede utilizar métodos con la demanda promedio (Vidal, 2010).

2.5.Exploración de patrones de datos con análisis de auto correlación de Pearson

2.5.1. Definición de auto correlación

Se refiere a la correlación que existe entre una variable retrasada uno o más periodos consigo misma (Hanke, 2010).La ecuación [3] es la fórmula para calcular k el coeficiente de autocorrelación (r_k) entre las observaciones Y_t y Y_{t-k} , que se encuentran a k periodos de distancia.

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \hat{Y})(Y_{t-k} - \hat{Y})}{\sum_{t=1}^n (Y_t - \hat{Y})^2} \quad ; k=0, 1, 2 \dots \quad [3]$$

Donde:

r_k =coeficiente de autocorrelación para un retraso de k periodos

\hat{Y} = media de los valores de la serie

Y_t = observación en el periodo t

Y_{t-k} , = observación k periodos anteriores o durante un periodo $t - k$

2.6. Métodos de pronósticos

Existe una gran variedad de pronósticos, el cual se puede apreciar en la figura 9 (Montemayor, 2013).

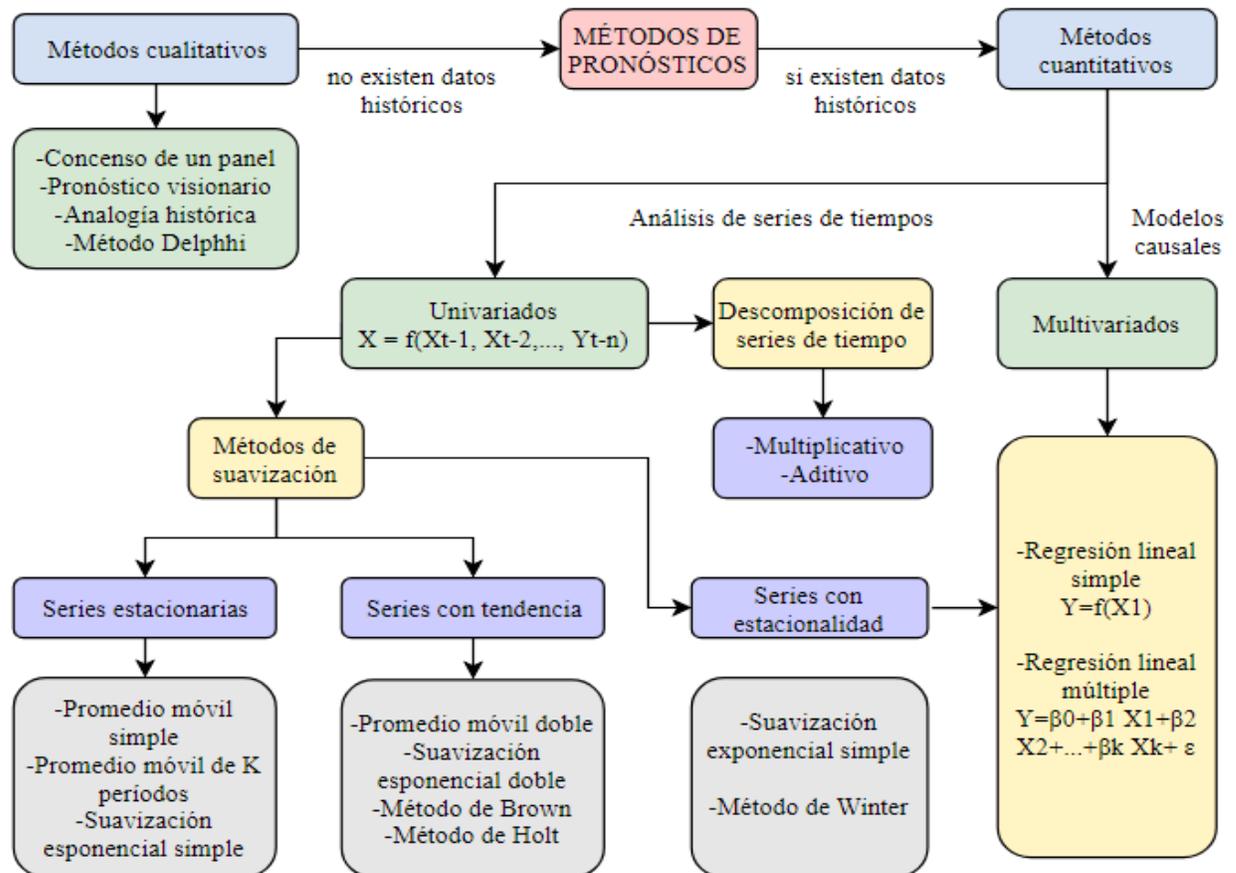


Figura 8. Clasificación de pronósticos.

Fuente: (Montemayor, 2013)

2.6.1. Cualitativos

Se considera que una técnica puramente cualitativa es aquella que evidentemente no requiere manipulación de datos alguna, tan sólo se usa el juicio del pronosticador (Hanke, 2010). A continuación se presenta un preámbulo de cada uno de los tipos de pronósticos cualitativos.

2.6.1.1. Consenso de un panel

Según la teoría de Montemayor, este método aprovecha la experiencia e información de un grupo de expertos para realizar pronósticos; en su aplicación se los selecciona y junta para analizar

la situación y en consenso llegar a un acuerdo sobre los valores futuros de las variables a predecir (Montemayor, 2013).

2.6.1.2. Pronóstico visionario

Todas las personas pueden realizar este tipo de pronóstico, sean expertas o no en el tema de interés; parte de la información que se tiene a la mano o de la experiencia, y con ello se realiza una conjetura de lo que va a suceder en el futuro (Montemayor, 2013).

2.6.1.3. Analogía histórica

Según la teoría de Montemayor este método aprovecha la experiencia que se tiene en un mercado para incursionar en uno nuevo , lo cual serviría para lanzar nuevos productos (Montemayor, 2013).

2.6.1.4. Método Delphi

Delphi no es un procedimiento diseñado para desafiar a la estadística o a los procedimientos basados en un modelo, contra los cuales el juicio humano ha demostrado ser inferior: es una propuesta para usarse en situaciones que requieren de juicio y pronósticos en las que los métodos estadísticos puros basados en un modelo resultan imprácticos o no son posibles por la falta de datos históricos, económicos o técnicos apropiados (Hanke, 2010).

2.6.2. Cuantitativos

Son pronósticos que se basan en datos cuantitativos, en el Anexo A se presenta la descripción de los métodos cuantitativos más relevantes, la clasificación en modelos y sus usos. En donde se hace referencia al modelo de redes neuronales. (Hanke, 2010).

2.7. Redes Neuronales

Las redes neuronales son modelos aplicables a muchos campos de investigación, como se puede apreciar en el siguiente contenido.

2.7.1. Definición general de una red neuronal

Las redes neuronales artificiales son redes masivamente interconectadas en paralelo de elementos simples usualmente adaptativos y organizados jerárquicamente, los cuales intentan una interacción con los objetos del mundo real parecido al sistema nervioso biológico(Matich, 2001).

2.7.2. Elementos básicos que componen una red neuronal

En la figura 9 se puede apreciar la estructura de una red neuronal. La misma está conformada por neuronas interconectadas y arregladas en tres capas. Los datos de la capa de entrada pasan por la capa oculta y salen por la capa de salida. Cabe recalcar que la capa oculta puede estar estructurada por varias capas (Matich, 2001).

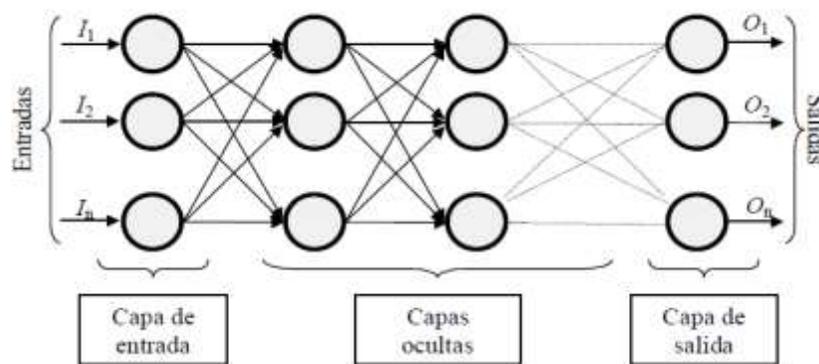


Figura 9. Ejemplo de una red neuronal totalmente conectada.
Fuente: (Matich, 2001)

2.7.3. Definición como método de pronóstico

Las redes neuronales artificiales son métodos de pronóstico que basadas en modelos matemáticos simples del cerebro. Permiten relaciones complejas no lineales entre la variable de respuesta y sus predictores(Hyndman & Athnasopoulos, 2018)

2.7.4. Proceso de pronóstico mediante redes neuronales

El modelo de predicción de la red neuronal se establecerá en función de los factores de influencia, con las entradas siendo los factores que afectan la demanda, y la salida es la

demanda(Hu, Sun, & Wen, 2014). En la figura 10 se muestra el proceso básico de un modelo de pronóstico mediante redes neuronales.

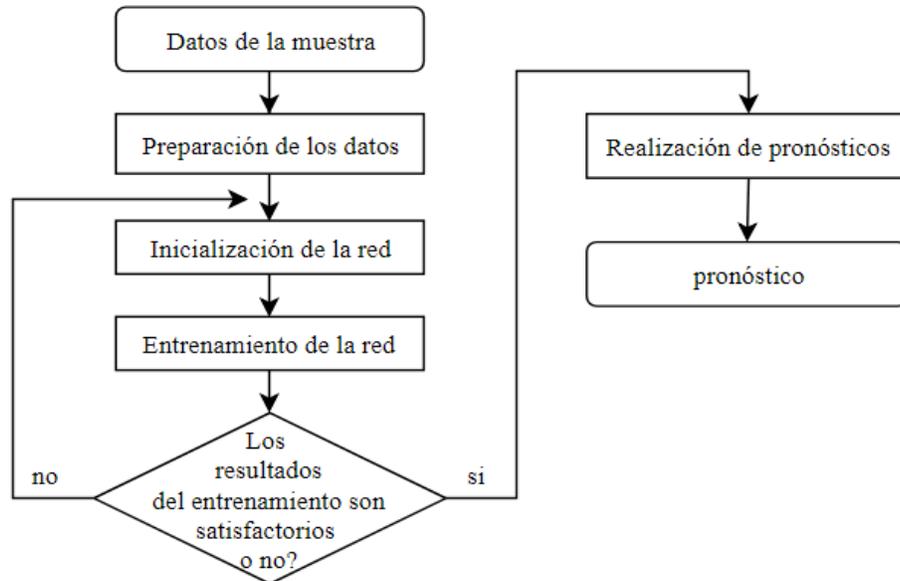


Figura 10. Proceso de pronóstico de la red neuronal.
Fuente: (Hu et al., 2014)

2.7.5. Redes neuronales y regresiones lineales

Las redes más simples no contienen capas ocultas y equivale a utilizar regresiones lineales (Hyndman & Athnasopoulos, 2018). La composición de una red neuronal por varias neuronas, mientras más neuronas más complejo será modelo (Scenio, 2018).

2.7.6. Intervalos de predicción

A diferencia de la mayoría de los métodos que se usan comúnmente, las redes neuronales no se basan en un modelo estocástico bien definido, por lo que no es sencillo definir intervalos de predicción para los pronósticos resultantes. Sin embargo, se puede calcular los intervalos de predicción utilizando la simulación en la que se generan futuras rutas de muestreo utilizando residuos del primer pronóstico.(Hyndman & Athnasopoulos, 2018).

2.7.6.1. Red de avance de múltiples capas

Es aquella donde cada capa de nodos recibe entradas de las capas anteriores. Es decir, las salidas de los nodos en una capa son entradas hacia la siguiente capa. Las entradas a cada nodo se combinan utilizando una combinación lineal ponderada. (Hyndman & Athnasopoulos, 2018)

2.7.7. Tipos de Redes Neuronales

Existen algunos tipos de redes neuronales, según la teoría de (Valeru & Senabre, 2012) se dividen en redes neuronales supervisadas, no supervisadas y redes híbridas, como se puede observar en la Figura 11.

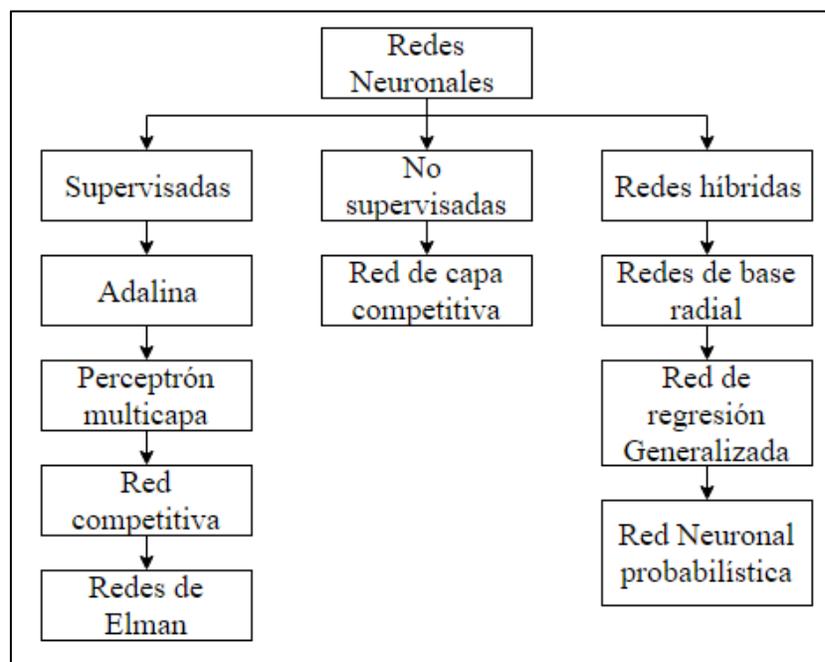


Figura 11. Tipos de Redes neuronales.
Fuente: (Valeru & Senabre, 2012)

2.7.7.1. Supervisadas

Adalina

ES un tipo de red considerada como elástica, ya que utiliza una neurona similar a la del perceptrón, pero da una respuesta lineal cuyas entradas pueden ser continuas. Esto permite que las

salidas puedan tomar cualquier valor, en cambio las del perceptrón debe ser de 0 o 1 (Valeru & Senabre, 2012).

Perceptrón Multicapa (MLP)

La red Neuronal como perceptrón nace a partir de añadir capas ocultas a un perceptrón simple. Esta arquitectura suele entrenarse mediante el algoritmo de retro propagación de errores o Back Propagation (BP) (Valeru & Senabre, 2012).

Red competitiva LVQ

El método LVQ se usa para entrenar capas competitivas de forma supervisada. Una capa competitiva aprende automáticamente a clasificar vectores de entrada, sin embargo, las clases que encuentra la capa competitiva dependen únicamente de la distancia entre los vectores de entrada .(Valeru & Senabre, 2012).

Redes de Elman

Es un tipo de Red BP de dos capas, la primera de tipo sigmoidea y la segunda lineal, con realimentación desde la salida de la primera capa hasta la entrada de la misma (Valeru & Senabre, 2012).

2.7.7.2.No supervisadas

Red de capa competitiva

Este tipo de red es no supervisada y unidireccional. Esto quiere decir que las neuronas de la capa competitiva se distribuyen por sí solas para reconocer los vectores de entrada presentados de forma frecuente (Valeru & Senabre, 2012).

2.7.7.3.Híbridas

Red de base radial (RBF)

El modelo de redes de base radial, RBF, aunque de reciente introducción, cada vez cuenta con más aplicaciones prácticas gracias a su simplicidad, generalidad y rapidez de aprendizaje (Valeru & Senabre, 2012).

Red de regresión generalizada (GRNN)

Las redes GRNN se usan normalmente para aproximación de funciones. Poseen una capa de neuronas de base radial y una capa lineal especial (Valeru & Senabre, 2012).

Red neuronal probabilística (PNN)

Las redes PNN pueden ser usadas en problemas de clasificación. Cuando se presenta una entrada, la primera capa computa las distancias desde el vector de entrada a los vectores de entrada del entrenamiento y produce un vector cuyos elementos indican lo próxima que está la entrada respecto a la entrada de entrenamiento (Valeru & Senabre, 2012).

2.7.8. Aplicaciones de Redes Neuronales

Las redes neuronales se pueden utilizar en un gran número y aplicaciones variadas. En un periodo de tiempo sensato se pueden desarrollar redes neuronales con la capacidad de realizar tareas concretas mejor que otras metodologías tecnológicas. Existe diferentes tipos de redes neuronales; cada uno de los cuales tiene una aplicación específica más oportuna (Matich, 2001). Algunas aplicaciones son:

- Biología:
 - Aprender de forma más profunda acerca del cerebro y otros sistemas.
 - Obtención de modelos de la retina de ojos

- Empresa:
 - Evaluación de probabilidad de apareamiento de formaciones geológicas y petrolíferas.
 - Optimización del flujo del tránsito controlando mediante la temporización de los semáforos conveniente.
 - Identificación de candidatos para puestos específicos.
 - Investigación del comportamiento de bases de datos.
 - Optimización de horarios y plazas horarios en líneas aéreas.
- Reconocimiento de caracteres de un texto.
 - Realización de modelos de sistemas para automatización y control.
- Medio ambiente:
 - Análisis de tendencias y patrones ambientales.
 - Previsión del tiempo y su comportamiento climático.
- Finanzas:
 - Previsión del alza de los precios.
 - Cuantificación del riesgo de los créditos.
 - Identificación de falsificaciones.
 - Interpretación de firmas.
- Manufacturación:
 - Realización de robots automatizados y sistemas de control automático como por ejemplo visión artificial y sensores de presión, temperatura, gas, entre otros.
 - Control de producción en líneas de producción.
 - Inspección de la calidad.

- Medicina:
 - Analizadores del habla para ayudar en la audición de sordos profundos.
 - Tratamiento y diagnóstico en base a síntomas de datos analíticos, electrocardiograma, encefalogramas, análisis sanguíneo, entre otros.
 - Monitorización en cirugías.
 - Pronóstico de reacciones adversas en los medicamentos.
 - Profundización de la causa de los ataques cardíacos.
- Militares:
 - Clasificación de las señales de radar.
 - Seguimiento y reconocimiento en el tiro al blanco.
 - Creación de armas inteligentes.
 - Optimización del uso de recursos que son escasos.

Comúnmente estas aplicaciones se enfocan en el reconocimiento de patrones, como buscar un, clasificar patrones, patrón en una serie de ejemplos, completar una señal a partir de valores parciales o reconstruir el patrón correcto partiendo de uno difuso. En cuanto a casos de aplicación, la ventaja de las redes neuronales se halla en su procesado paralelo, adaptativo y no lineal. (Matich, 2001).

2.8. Precisión en los pronósticos

A continuación, se detalla las magnitudes con las que se mide la calidad del pronóstico.

2.8.1. El error de pronóstico.

Es la diferencia entre un valor real observado y su valor de pronóstico.

$$e_t = Y_t - \hat{Y}_t \quad [4]$$

Donde:

e_t = Error de pronóstico en el período t.

Y_t = Valor real en el período t.

\hat{Y}_t = Pronóstico en el período t.

2.8.2. Medidas de error para evaluar la precisión de los pronósticos.

2.8.2.1. Desviación Absoluta de la Media (MAD).

Mide la precisión de un pronóstico mediante la media de la magnitud de los errores del pronóstico, valores absolutos de cada error. El MAD resulta de gran utilidad cuando se necesita medir el error del pronóstico en las mismas unidades de la serie de tiempo original (Hanke, 2010).

$$MAD = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n} \quad [5]$$

En donde:

Y_t = valor real en el período t

\hat{Y}_t = valor del pronóstico en el período t

2.8.2.2. Error Medio Cuadrático (MSE).

En el caso de este indicador, cada error de pronóstico se eleva al cuadrado, después se suman y se dividen esos errores para el número de observaciones, de esta forma se penalizan los errores mayores, este indicador se utiliza para medir la precisión de un modelo de pronóstico ya que mediante este es posible diferenciar entre una técnica que produzca errores moderados a otra que los errores sean pequeños pero que ocasionalmente arroje algunos en extremo grandes (Hanke, 2010).

$$MSE = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n} \quad [6]$$

En donde:

Y_t =valor real en el período t

\hat{Y}_t =valor del pronóstico en el período t

n= número de observaciones

2.8.2.3.Raíz cuadrada del Error Cuadrático Medio (RMSE).

Al igual que el MSE el RMSE sanciona los errores grandes pero este posee la misma unidad de medida de la serie original y se interpreta con mayor facilidad (Hanke, 2010).

$$RMSE = \sqrt{MSE} \quad [7]$$

En donde:

MSE=Error medio cuadrático

2.8.2.4.Porcentaje del Error Medio Absoluto (MAPE).

Ese indicador se utiliza cuando resulta más útil calcular los errores de pronóstico en términos de porcentaje y no en cantidades. Es decir otorga una indicación de qué tan significativos son los errores de pronóstico comparados con los valores de la serie real (Hanke, 2010).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{|Y_t|} \quad [8]$$

En donde:

Y_t =valor real en el período t

\hat{Y}_t =valor del pronóstico en el período t

n= número de observaciones

2.8.2.5.Porcentaje Medio del Error (MPE).

Se utiliza para conocer si un pronóstico está sesgado. Si resulta un porcentaje negativo significativo, el método de pronóstico está sobrestimado de manera consistente; y si es un

porcentaje positivo significativo, el método de pronóstico está subestimado de forma consistente (Hanke, 2010).

$$MPE = \frac{\sum_{t=1}^n \frac{(Y_t - \hat{Y}_t)}{Y_t}}{n} \quad [9]$$

En donde:

Y_t =valor real en el período t

\hat{Y}_t =valor del pronóstico en el período t

n= número de observaciones

2.8.2.6. ANOVA

El análisis de varianza, ANOVA, permite cuantificar la información que aporta la variable dependiente Y, y la separa en dos partes: la que explica la ecuación de regresión y la que explica el error (Montemayor, 2013). La mayoría de los paquetes estadísticos presenta la información del análisis de varianza ANOVA de regresión lineal múltiple como la tabla 1.

Tabla 1. *Evaluación ANOVA.*

Fuente de variación	Suma de cuadrados	Grados de libertad	Cuadrado medio	Estadístico F
Regresión	SCR	K	CMR= SCR/k	$F_{calculada} = \text{CMR}/\text{CME}$
Error	SCE	n-(k+1)	CME= SCE/ [n-(k+1)]	N/A
Total	SCT	n-1	N/A	N/A

Fuente: (Montemayor,2013)

Suma de cuadrados total (SCT)

Según Montemayor, la información que aporta la variable dependiente Y se cuantifica a través de la variabilidad total de Y que contiene la información más representativa de esta variable (Montemayor,2013). La variabilidad total de Y recibe el nombre de Suma de Cuadrados Total y se calcula mediante la misma fórmula de regresión lineal simple:

$$SCT = \sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n Y_i^2 - \frac{1}{n} (\sum_{i=1}^n Y_i)^2 = \sum_{i=1}^n Y_i^2 - n\bar{Y}^2 = SS_{yy} \quad [10]$$

En regresión lineal simple y múltiple la SCT es igual porque no cambia la información de Y, lo que cambia es la información que aporta la ecuación de regresión y el error para explicar a Y.

La variación de Y que es explicada por la ecuación de regresión se conoce como Suma de Cuadrados de Regresión, SCR

$$SCR = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \quad [11]$$

La variación de Y que es explicada por el error se conoce como suma de cuadrados del error (o residual), SCE:

$$SCE = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad [12]$$

Las sumas de cuadrados deben satisfacer la identidad ($SCT = SCR + SCE$) y debido a que miden variabilidad nunca podrán ser negativas. En búsqueda del mejor modelo para predecir a Y, se elegirán variables explicativas donde la SCR sea lo más cercana a SCT y donde la SCE se lo más aproximada a cero

2.8.2.7. Coeficiente de Akaike (AIC) y de Shwarz (BIC)

Se sabe que s^2 está estrechamente relacionado con el coeficiente de determinación ajustado \hat{R}^2 de modo que al seleccionar un modelo con el mínimo s^2 equivale a elegir el mayor \hat{R}^2 . Al incluir más variables en un modelo de regresión no necesariamente se reduce s^2 o aumenta el \hat{R}^2 . El s^2 es solo un estimador insesgado usual de la varianza del error en la regresión, existen otros indicadores como el criterio de información AIC y el criterio de información BIC, cuyas ecuaciones se indican abajo. (Fernández, Martínez, & Fernández, 2013)

Criterio de Akaike (AIC)

$$\ln(AIC) = \ln(S^2) + \frac{2k}{n} \quad [13]$$

Donde:

$$S^2 = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad [14]$$

K= número de parámetros estimados

Criterio de Schwarz

$$\ln(S C) = \ln(S^2) + \left[\left(\frac{k}{n}\right) * \ln(n)\right] \quad [15]$$

Elección entre los criterios S^2 , Akaike y Schwarz para seleccionar un modelo

Elegir adecuadamente entre estos 3 criterios se hace una evaluación de los criterios en función de dos propiedades: la consistencia y la eficiencia asintótica.

Modelo es consistente:

1. Cuando el modelo verdadero está entre los modelos considerados, la probabilidad de seleccionarlo tiende a uno a medida que aumenta el tamaño de muestra.
2. Cuando el modelo verdadero no está entre los modelos considerados, la probabilidad de seleccionar la mejor aproximación al modelo verdadero o generador de datos tiende a uno cuando aumenta el tamaño de muestra.

El ECM es inconsistente porque no penaliza por grados libertad; s^2 si penaliza, pero no lo suficiente. El criterio Akaike penaliza los grados libertad en forma más enérgica que s^2 pero también es inconsistente aun cuando se aumente el tamaño de muestra. El criterio Schwarz que penaliza con la máxima intensidad, si es consistente. El criterio de selección de un modelo asintóticamente eficiente elige una serie de modelos cuyas varianzas del error de pronóstico tiende a la que se obtendría con el modelo verdadero, cuando el tamaño de muestra aumenta. Visto desde este punto de vista el criterio Akaike es asintóticamente eficiente, mientras que el criterio Schwarz no lo es. En la práctica de los pronósticos se recomienda el uso de los dos criterios, cabe señalar que frecuentemente ambos coinciden en la selección del modelo.(Fernández et al., 2013)

2.9. Software de aplicación R

En el mundo de la tecnología existen muchas herramientas para programar, una de ellas es el software R.

2.9.1. Definición

R es un entorno de software libre para computación estadística y gráficos. Compila y se ejecuta en una amplia variedad de plataformas UNIX, Windows y MacOS (Venables, Smith, & R Core Team, 2018)

R es un lenguaje muy flexible orientado a objetos, lo que se entiende como que R es un lenguaje no compilado como C, C++, Fortran, Pascal entre otros y es interpretado como Java; lo que quiere decir que los comandos escritos en el teclado son ejecutados de forma directa sin necesidad de construir ejecutables (Paradis, 2003)

2.9.2. Como funciona R

Una de las características más destacables de R es su enorme flexibilidad. R guarda los resultados como un objeto, de tal manera que se puede hacer un análisis sin necesidad de mostrar su resultado inmediatamente, a diferencia de programas más clásicos que arrojan directamente los resultados de un análisis, (Paradis, 2003). Este funcionamiento se puede apreciar de forma esquemática como se muestra en la figura 12.

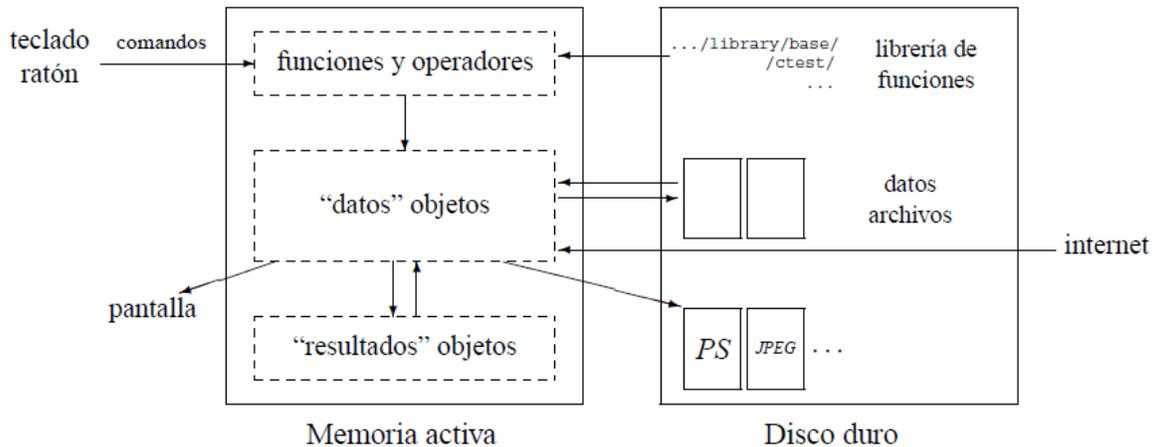


Figura 12. Una visión esquemática del funcionamiento de R
 Fuente: (Paradis, 2003)

Un lenguaje de programación orientado a objetos implica que sus variables, datos, funciones, resultados, etc., se guardan en la memoria activa del computador en forma de objetos con un nombre específico. El usuario puede modificar o manipular estos objetos con operadores aritméticos, lógicos, y comparativos; y funciones, que a su vez son objetos (Paradis, 2003).

2.9.3. Objetos en R

Casi todo en R es un objeto, incluyendo funciones y estructuras de datos. A continuación se enlistan los objetos existentes en el software, además de mencionar ciertos ejemplos para mayor comprensión (Carmona, 2007).

2.9.3.1. Objetos del lenguaje:

Llamadas, expresiones, nombres, entre otros.

2.9.3.2. Expresiones:

Colecciones de expresiones correctas no evaluadas

2.9.3.3. Funciones

Constan de: lista de argumentos, código y entorno

2.9.3.4. Sin objeto

NULL

2.9.3.5. Objetos para los datos:

- *Vector*: colección ordenada de elementos del mismo tipo. Por ejemplo:

```
> x <- c(1, 2, 3); y <- c("a", "b", "c")
```

```
> z <- c(TRUE, TRUE, FALSE)
```

- *Array*: Es una generalización multidimensional del vector, que contiene los mismos elementos del mismo tipo.

- *Data frame*: como el array, pero con columnas de diferentes tipos. Es el objeto más habitual para los datos experimentales. Por ejemplo:

```
> dades <- data.frame(ID=c("gen0", "genB", "genZ"),
```

```
+ subj1 = c(10, 25, 33), subj2 = c(NA, 34, 15),
```

```
+ oncogen = c(TRUE, TRUE, FALSE),
```

```
+ loc = c(1, 30, 125))
```

- *factor*: tipo de vector para datos cualitativos. Por ejemplo:

```
> x <- factor(c(1, 2, 2, 1, 1, 2, 1, 2, 1))
```

- *list*: vector generalizado. Cada lista está formada por componentes que pueden ser otras listas. Cada componente puede ser de distinto tipo. Son contenedores generales de datos. Muy flexibles, pero sin estructura. Muchas funciones devuelven una lista o conjunto de resultados de distinta longitud y distinto tipo. Por ejemplo:

```
> una.lista <- c(un.vector = 1:10,
```

```
+ una.palabra = "hola",
```

```
+ una.matriz = matrix(rnorm(20), ncol = 5),
```

```
+ lista2 = c(a = 5,
```

```
+ b = factor(c("a", "b"))))
```

2.9.4. Paquetes para pronósticos de la demanda

El lenguaje R contiene muchos paquetes para desempeñar distintas funciones. Es decir, R consta de un sistema base y de paquetes adicionales que extiende su funcionalidad. A continuación, se realiza un énfasis en los paquetes que resultan asociados con pronósticos, redes neuronales y productividad en el proceso de obtención del resultado.

2.9.4.1.Keras

En el campo de la literatura, Keras significa cuerno en griego. Es una referencia a una imagen literaria de la literatura griega y latina antigua, encontrada por primera vez en la Odisea, donde los espíritus de los sueños dividen entre aquellos que engañan a los hombres con visiones falsas, que llegan a la Tierra a través de una puerta de marfil. , y aquellos que anuncian un futuro que llegará a pasar, que lleguen por una puerta de cuerno (Allaire, Chollet, RStudio, & Google, 2019).

Específicamente dentro de R, Keras es una biblioteca a nivel de modelo, que proporciona bloques de construcción de alto nivel para el desarrollo de Modelos de aprendizaje profundo (Venables et al., 2018).

2.9.4.2.Tensorflow

Es una biblioteca de software de código abierto para Machine Intelligence. La interfaz R para TensorFlow le permite trabajar de manera productiva utilizando un alto nivel de Keras y de las APIs de Estimator, y cuando necesita más control, proporciona acceso completo a la API principal de TensorFlow (TensorFlow & RStudio, 2018).

La API de Keras para TensorFlow proporciona una interfaz de alto nivel para redes neuronales, con un enfoque en permitir una experimentación rápida (TensorFlow & RStudio, 2018).

2.9.4.3. Keras y tensorflow

Debido a que Keras no maneja operaciones de bajo nivel como la manipulación del tensor y la diferenciación. En su lugar, se basa en una biblioteca tensorial especializada y bien optimizada para hacerlo (Chollet & Allaire, 2017).

Así, sirviendo como motor de backend de Keras. En lugar de elegir una sola biblioteca tensorial y vinculando la implementación de Keras a esa biblioteca, Keras maneja el problema en una forma modular. Por lo tanto, se pueden enchufar varios motores procesadores de datos detrás de R perfectamente en Keras.(Chollet & Allaire, 2017). Así como se ilustra en la figura 13.

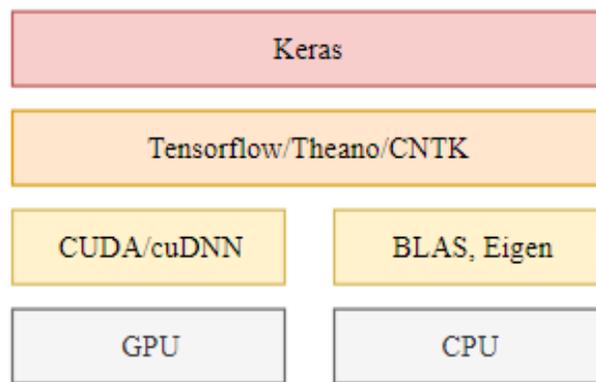


Figura 13. El software de aprendizaje profundo y la pila de hardware.

Fuente: (Chollet & Allaire, 2017)

2.9.4.4. NNFOR

Según (Kourentzes, 2019), el paquete NNFOR para R es una herramienta que facilita el pronóstico de series de tiempo con perceptrones de múltiples capas (MLP) y máquinas de aprendizaje extremo (ELM). Actualmente, se basa en el paquete neuralnet para R, que proporciona toda la maquinaria para entrenar a los MLP. La capacitación de los ELM se escribe dentro del paquete NNFOR. Se toma en cuenta que, dado que la red neuronal no puede aprovechar el procesamiento de GPU, las redes grandes tienden a ser muy lentas para entrenar. La diferencia de las implementaciones de redes neuronales existentes para R en las que proporcionan código para diseñar redes automáticamente con un rendimiento de pronóstico razonable, pero también proporciona un

control profundo al usuario experimentado. La especificación automática está diseñada teniendo en cuenta la parsimonia. Esto aumenta la robustez de las redes resultantes, pero también ayuda a reducir el tiempo de entrenamiento.

Predicción de series de tiempo con perceptrones multicapa

Las series de tiempo de pronóstico con NN emplean convencionalmente una topología de avance del Perceptrón multicapa (MLP) establecido en analogía con un modelo autorregresivo no lineal de orden p , NAR (p), al cual también se limitará nuestro análisis. En la predicción de series de tiempo con MLP, para un punto en el tiempo t a h -pasos pronóstico anticipado \hat{y}_{t+h} se calcula utilizando $n = p$ observaciones retrasadas $y_t, y_{t-1}, \dots, y_{t-n+1}$ de n puntos anteriores en el tiempo $t, t-1, t-2, \dots, t-n+1$, con $n = I$ que denota el número de unidades de entrada de la MLP. La forma funcional de un MLP de una sola capa con un solo nodo de salida para es:

$$f(Y, w) = \beta_o + \sum_{h=1}^H \beta_h g(\gamma_{oi} + \sum_{i=1}^I \gamma_{hi} \gamma_i) \quad [16]$$

Con $Y = [y_t, y_{t-1}, \dots, y_{t-i+1}]$ el vector de las observaciones retrasadas de la serie de tiempo que proporciona las entradas de red. Los parámetros de red se indican como pesos $w = (\beta, \gamma)$, $\beta = [\beta_1, \beta_2, \dots, \beta_H]$ y $\gamma = [\gamma_{11}, \gamma_{12}, \dots, \gamma_{21}, \dots, \gamma_{h1}]$ para la salida y la capa oculta respectivamente, con β_0 y γ_{0i} que denotan los sesgos de cada nodo. I y H especifican el número de unidades de entrada y ocultas en la red y $g(\cdot)$ es una función de transferencia no lineal, que utiliza convencionalmente las funciones logísticas sigmoideas o tangenciales hiperbólicas. En consecuencia, cada nodo oculto h calcula un modelo NAR (p) en los nodos de entrada $p = I$, que se combinan en \hat{y} por una suma ponderada de un solo nodo de salida, aunque son posibles varias salidas (Crone & Kourentzes, 2010). Una arquitectura MLP se muestra en la figura 14.

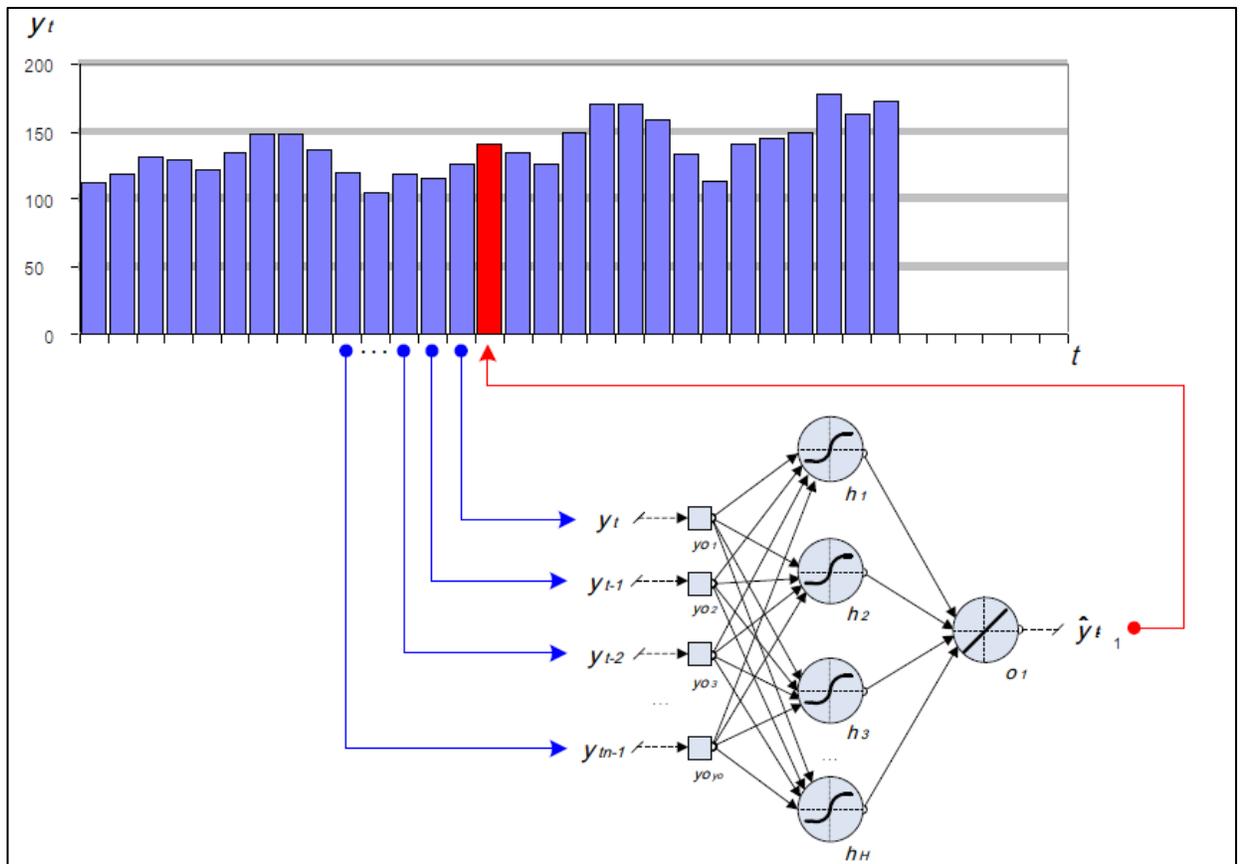


Figura 14. Autorregresivo MLP para la predicción de series de tiempo.
Fuente: (Crone & Kourentzes, 2010)

CAPÍTULO III

3. Metodología de pronósticos

El este capítulo se presenta la metodología de la investigación basada en metodología de (Hu et al., 2014). El procedimiento se resume en la figura 15.

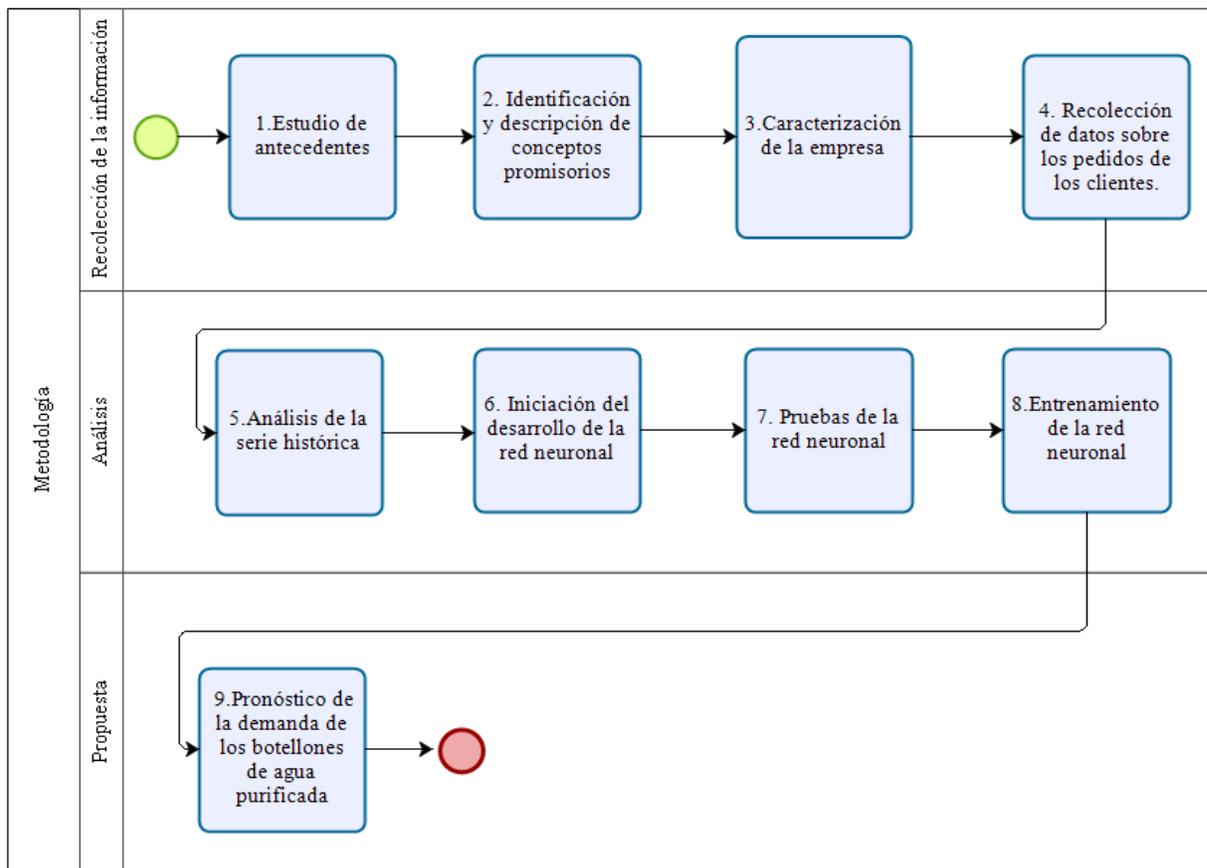


Figura 15. Flujograma de metodología de la investigación.

La metodología se divide en tres formas de investigación y cada una contiene un proceso que se desarrolla en la investigación. En la parte de recolección de datos se observa cuatro etapas de la investigación de manera que el estudio de antecedentes hace referencia al capítulo I, en donde se realiza un estudio del estado del arte. La identificación y descripción de los conceptos de la investigación se encuentra detallado en el capítulo II del presente documento. La etapa tres y cuatro forman parte del capítulo III. La caracterización de la empresa comprende la descripción

del objeto de estudio que es la empresa, además que sea realiza un diagnóstico con enfoque a pronósticos mediante un checklist y la etapa de recolección de datos define los datos que se van a utilizar para el desarrollo del pronóstico.

El apartado de análisis contiene las cuatro etapas siguientes de la investigación en la cual el análisis de la serie histórica forma parte del capítulo III, en donde se caracteriza la demanda, además de que estudia su comportamiento y patrones. Como parte del análisis se presenta también el desarrollo del capítulo IV en la etapa seis, siete y ocho. La etapa seis que contiene la iniciación del desarrollo de la red neuronal, en esta etapa se define la primera capa de la red neuronal. A continuación se procede a la etapa 7 en donde se define la configuración de múltiples capas escondidas. Como última etapa del apartado de análisis se tiene el entrenamiento de la red neuronal, la cual delimita la cantidad de redes neuronales a entrenar, para el aprendizaje.

El apartado de la propuesta nueve contiene una sola fase la cual forma parte de los resultados de toda la investigación además de que se compara con los resultados obtenidos de la Red Neuronal óptima vs otros métodos tradicionales mediante el indicador MSE.

3.1. Caracterización de la organización estudiada

En esta parte del documento se pretende dar un preámbulo de la organización, para conocer tanto el producto, y el contexto interno. Los datos de este apartado representan gran importancia para el estudio, ya que a partir de estos se puede destacar información para tener una noción de la manera en que se han llevado a cabo los pronósticos.

La entidad de estudio es una empresa ecuatoriana, dedicada a embotellar y comercializar agua purificada envasada, ofrece a todos sus clientes agua 100% pura, elaborada a través de los más altos estándares de calidad mediante ósmosis inversa, que brinda los minerales esenciales que el cuerpo humano necesita.

3.1.1. Productos ofrecidos

La empresa ofrece a sus clientes un producto que está compuesto de agua purificada envasada en botellones PET retornable en lotes de unidades, en presentaciones de botellón de 20 L.

3.1.2. Clientes-sector

Empresas como instituciones educativas, instituciones públicas, hoteles restaurantes, panaderías, clubes. Generalmente el producto se distribuye a la zona 1 del país.

3.1.3. Proveedores

Sus proveedores son empresas nacionales dedicadas a la producción de material de empaque plástico como botellas, tapas, bolsas, etiquetas, producidas a partir de derivados del petróleo como los polietilenos, los polivinilos y los tereftalatos. Además, otras empresas nacionales encargadas de proveernos equipo de protección y materiales de limpieza de calidad.

3.1.4. Recurso humano

La empresa cuenta con seis colaboradores directos entre personal operativo y administrativo, distribuidos dentro de la conformación organizacional de la empresa.

En cuanto a personal administrativo, la empresa cuenta con un Gerente General, Gerente Administrativo y Operacional, quienes velan por el desarrollo de la empresa.

En la parte operativa laboran un envasador, un operario polifuncional, un conductor de transporte y un distribuidor.

3.1.5. Misión

Brindar Agua 100% pura, cumpliendo con todos los estándares de calidad exigidos, garantizando a todos nuestros clientes el mejor servicio, bajo un ambiente de trabajo armónico que permita el desarrollo y crecimiento personal de nuestros empleados y colaboradores.

3.1.6. Visión

Ser la empresa líder en comercialización y distribución de agua purificada del país y ser la mejor en el desarrollo en el área de purificación dentro de las provincias de Imbabura y Carchi, con crecimiento que duplique su valor cada año, manteniendo una relación continua con todos nuestros clientes a través del servicio

3.1.7. Mapa de procesos

Considerando que el proyecto desea realizar un pronóstico, es importante conocer los procesos de la empresa en estudio, como se puede observar en la figura 16.

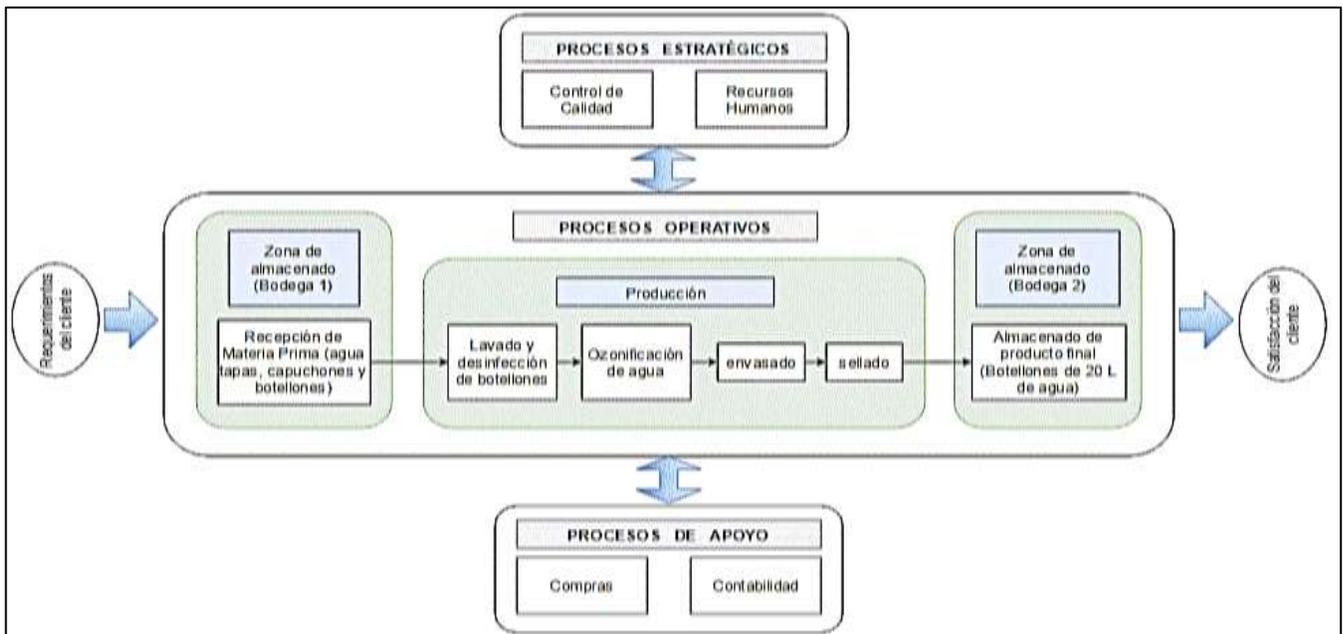


Figura 16. Mapa de procesos

3.1.8. Contexto interno

En este apartado se realiza el diagnóstico mediante un checklist con un enfoque a pronósticos, tomando en cuenta los macroprocesos de la empresa. De manera que se obtenga un estado inicial y evidenciar las consecuencias de no contar con el buen manejo de pronósticos. La herramienta que se utilizó se puede observar en la tabla 2.

Tabla 2. Checklist con enfoque a pronósticos

CHECKLIST			
PROCESO	CRITERIOS	VALOR	OBSERVACIONES
Estratégico	Conoce el estado de sus ventas de los últimos 3 años	0	N/A
	Clasifica sus productos	1	A:Botellones de agua purificada (20L) B:Botellas de agua(500ml)
	Su producto a presentado variación de precios en los últimos 3 años	1	Por la inflación
	Clasificación de clientes	1	Por grupos: En su mayoría son organizaciones públicas
	Porcentaje de atención al cliente	1	Si cuenta con el indicador de porcentaje de atención al cliente
	Existe un responsable del manejo de registros en su empresa	1	Gerente Administrador y distribuidor
	Registros de producción	1	Diario
Operativo	Período de producción	1	Semanal: 5 días/semana- 4 horas diarias aproximadamente, en temporada de vacaciones:4 días/semana.
	Volumen medio de producción Diaria	1	100 unidades
	Sustento	1	Experiencia y media de producción mensual
	Capacidad de la planta	1	25 unidades/hora
	Controla niveles de inventario	0	
	Registro de ventas y pedidos	1	Diarios
	Con cuanto tiempo planifican su producción	1	Mensual
Apoyo	Planificación de pedidos de materiales	1	Mensual
	Planifican la mano de obra	0	Trabajan diariamente 2 personas sin planificación
	Tipo de pronósticos	1	Cualitativo
	Método de pronostico	1	Visionario
	Incertidumbre cuantificada de pronósticos	0	No hay valores certeros
	Calidad de pronósticos confiable	0	
	Metas de producción	0	
	Distribución de productos	1	Frecuencia: diaria, en vehículo propio
TOTAL SI=1		16	
TOTAL NO=0		6	

3.2.Recolección de datos

A continuación, se presenta el desarrollo de obtención de los datos previos para el análisis, así como su descripción. Lo cual implica el paso de registros y la selección de los datos y el intervalo de tiempo conveniente para la construcción de la serie histórica.

3.2.1. Paso de Registros

La empresa embotelladora de agua, maneja un registro manual, diario que consta de pedidos, ventas y devolución de botellones vacíos. Ya que los datos se mantienen de esa manera, se opta por el paso del registro a un software que permita operaciones matemáticas, en este caso se usa el paquete de office con su aplicación Excel 2013, para su posterior manejo. El registro data del 01 de junio del 2015 hasta el 15 de enero del 2019. Su resumen se puede apreciar en la tabla 3.

Tabla 3.*Datos de pedidos desde junio del 2015 hasta enero del 2019*

Años/ Meses	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2015						461	1643	1687	1681	1750	1678	1787
2016	1796	1528	1897	1900	1781	1831	1639	1548	1850	1779	1775	1726
2017	1801	1431	1865	1536	1832	1761	1315	1779	1774	1803	1770	1598
2018	1817	1527	1556	1716	1708	1381	1478	1453	1415	1714	1537	1385
2019	514											

3.2.2. Selección de Datos

La muestra con la que se trabaja corresponde a 3 años de actividad productiva y registro de datos por parte de la empresa. Esta cantidad se considera oportuna para el desarrollo de pronósticos. En la tabla 4 contiene los datos históricos de pedidos de los últimos 3 años, distribuida en 12 meses.

Tabla 4. Datos de pedidos desde enero del 2016 hasta diciembre del 2018

Años/ Meses	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2016	1796	1528	1897	1900	1781	1831	1639	1548	1850	1779	1775	1726
2017	1801	1431	1865	1536	1832	1761	1315	1779	1774	1803	1770	1598
2018	1817	1527	1556	1716	1708	1381	1478	1453	1415	1714	1537	1385

3.3. Análisis de la serie histórica

Este apartado consta de algunas partes para tener un preámbulo del comportamiento de nuestra serie histórica, para lo cual se aplica los conceptos iniciales respecto a tendencia, estacionalidad y el componente aleatorio. Este apartado es importante para tener noción de la elección del método clásico adecuado para el pronóstico. Para este apartado se siguió los pasos de la figura 17.

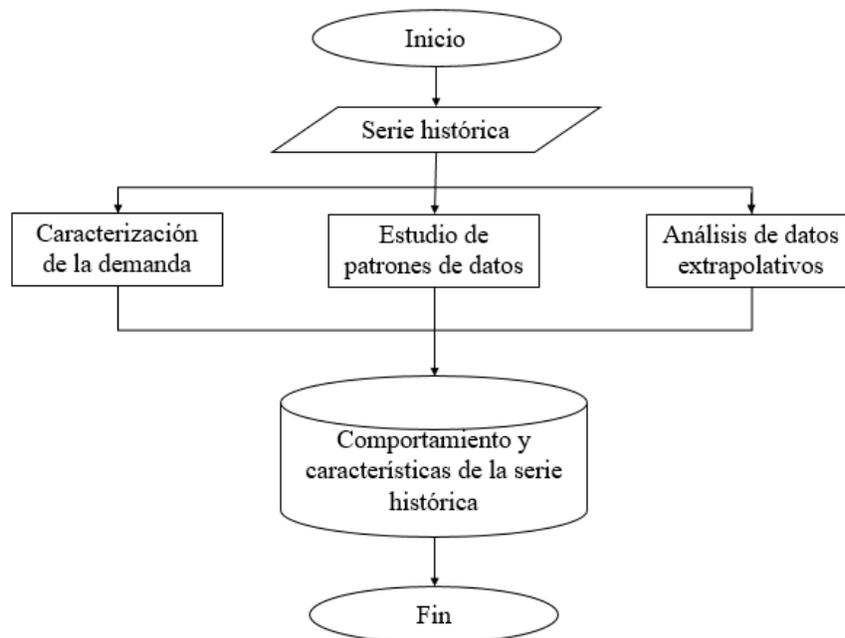


Figura 17. Flujograma del análisis de datos

El input del flujograma es la serie histórica, de la cual se procede a realizar tres análisis. La caracterización de la demanda se lo realiza mediante el coeficiente variación y variabilidad. Para el estudio de patrones se realiza un análisis de autocorrelaciones para detectar mediante hipótesis

la existencia de tendencia y de estacionalidad. Como parte del estudio de patrones se realiza el análisis de estacionaridad mediante la prueba de Dickey Fuller. En cuanto al análisis de datos extrapolativos se caracteriza los valores perdidos, el análisis de frecuencia, la media, mediana, mínimo, máximo primer, tercer cuartiles y por último un diagrama de cajas.

3.3.1. Caracterización de la demanda

De acuerdo al flujograma anterior comenzamos con la construcción de la serie histórica. En este apartado se empieza con el uso del software SPSS versión 22.

3.3.1.1.Revisión de datos:

Como primer paso se ingresa la serie histórica al software PSS y para la revisión de los patrones de datos se comienza con el análisis visual de los datos mediante la figura 18. Además, se puede realizar un análisis de variación y variabilidad con la herramienta de Excel.

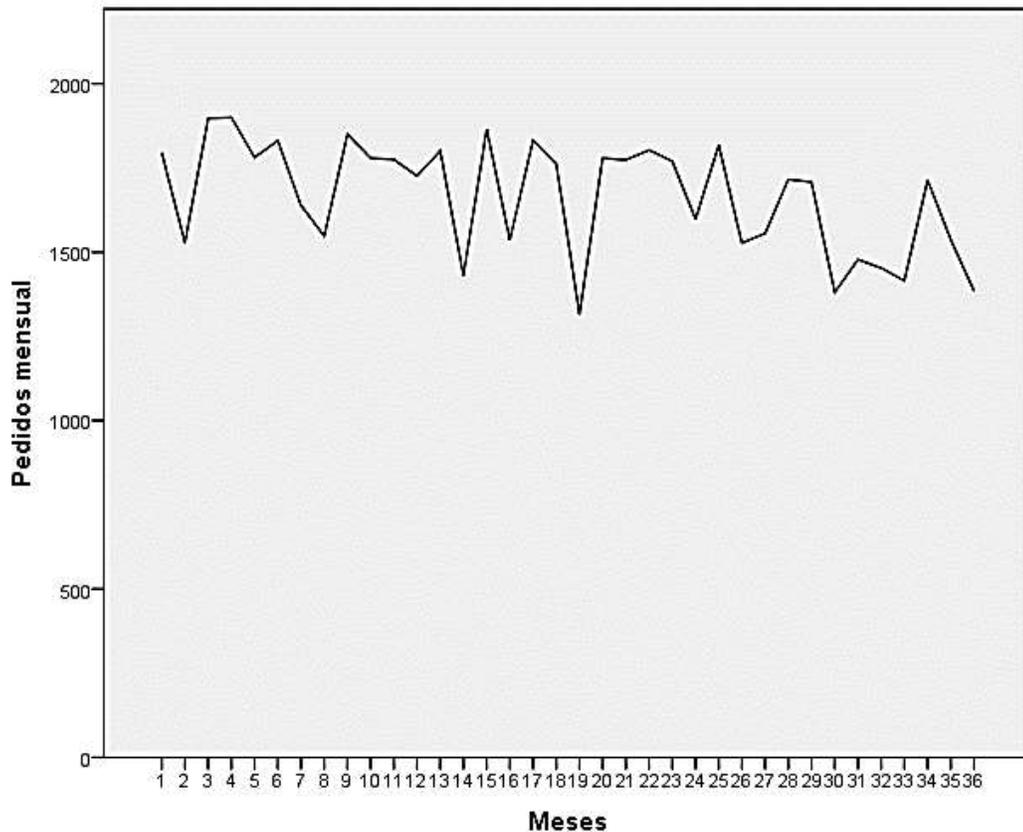


Figura 18. Construcción de la serie de tiempo

3.3.2. Coeficiente de variación y variabilidad

Tabla 5. Caracterización del a demanda

DESVIACIÓN ESTANDAR	DEMANDA PROMEDIO	COEFICIENTE DE VARIACIÓN	TIPO DE DEMANDA	VARIANZA	(DEMANDA PROMEDIO) ²	Coeficiente de variabilidad
168,26	1666,72	0,10	PERPETUA	27526,59	2777962,97	0.0099

Debido a que el coeficiente de la demanda es menor que 1, se clasifica la demanda como perpetua, es decir que se caracteriza por un bajo grado de aleatoriedad.

El coeficiente de variabilidad de la serie histórica es menor a 2, lo que quiere decir que se puede utilizar métodos clásicos, pero como se requiere de una medida de error cuadrática media se utiliza la metodología de redes neuronales.

3.3.3. Estudio de patrones de datos

Este apartado se divide en 3 análisis utilizando un diagrama de autocorrelaciones y validación de hipótesis mediante la metodología de Hanke y utilizando el programa SPSS V.22, por otra parte se realiza un análisis utilizando el programa de R Project, en el cual se realiza la descomposición multiplicativa de la serie histórica y por último la prueba de Dickey-Fuller para probar la estacionaridad.

3.3.3.1. Gráfico de autocorrelaciones:

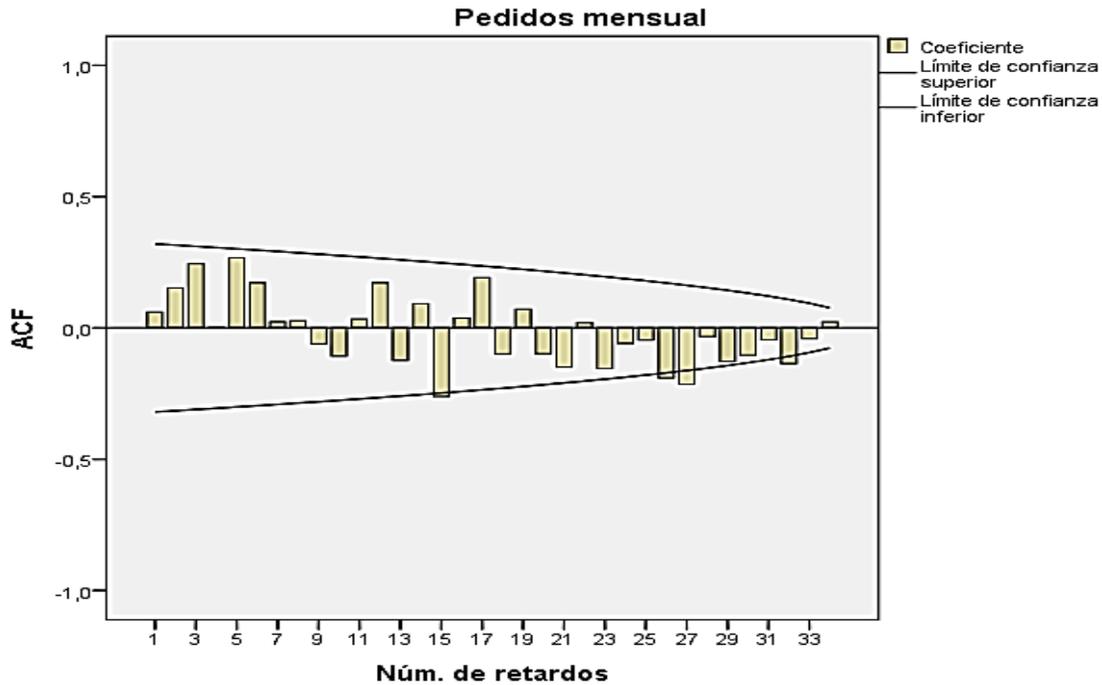


Figura 19. Gráfico de autocorrelaciones.

Interpretación según el gráfico de autocorrelaciones:

Los datos cada vez van disminuyendo, puede ser por presencia de tendencia. Además de que presenta ciertos que sobresalen del límite de confianza disparos que hay que analizar el supuesto de estacionalidad.

3.3.3.2. Análisis estadístico de supuestos

A continuación, se procede a la demostración estadística mediante la aceptación o no aceptación de las hipótesis nulas.

Análisis de tendencia

Para la demostración de la tendencia se considera las hipótesis que se muestran en la tabla 6.

Tabla 6. Análisis de tendencia

ANÁLISIS DE TENDENCIA	Notación	Valor	Descripción	Fuente
Parámetros	H_0	verdadera/falsa	hipótesis nula	propia
	H_1	verdadera/falsa	hipótesis alternativa	propia
	RC	ecuación	Región crítica	propia
	Q	44,260	Valor en los R_k períodos	tabla de autocorrelaciones
	$c^2_{\alpha; m}$	43,7729	el valor de Chi cuadrado	tabla de Chi cuadrado
	α	0,05	el 1- nivel de confianza	
	m	30	cantidad de muestra	
Desarrollo	Notación		Descripción	
Ecuaciones	$H_0 = r_{k=1}; 30$		Los coeficientes para los 36 períodos de retraso no son significativos	
	$H_1 = r_{k=1}; 30 \neq 0$		Los coeficientes para los 36 períodos de retraso son significativos)	
	RC: $Q > c^2_{\alpha; m}$		Región crítica se cumple si el valor de los 30 períodos es mayor que el valor de chi cuadrado	
	si RC=Verdadero; H_0 se rechaza		Condición	
Solución	RC: $44,260 > 43,7729$		Se cumple la región crítica, se rechaza H_0 por lo tanto se acepta H_1 , los coeficientes de auto correlación para los 30 períodos son significativos, así que hay presencia de tendencia.	

Ahora se puede revisar la distribución de chi cuadrado que se encuentra en el Anexo C. Se denota que 44,260 es mayor que 43,7729. Se cumple la región crítica, se rechaza H_0 por lo tanto se acepta H_1 , los coeficientes de auto correlación para los 30 períodos son significativos, así que hay presencia de tendencia.

Análisis de estacionalidad:

Para el análisis de la estacionalidad se utiliza la gráfica de autocorrelaciones, ver la figura 19, para detectar los disparos que sobresalen de los límites de confianza ya sí puede analizar las estacionalidades.

- *Análisis 1*

Tabla 7. Análisis de estacionalidad 1

ANÁLISIS DE ESTACIONALIDAD	Notación	Valor	Descripción	Fuente
Parámetros	H_0	verdadera/falsa	hipótesis nula	propia
	H_1	verdadera/falsa	hipótesis alternativa	propia
	IC	ecuación	intervalo de confianza	propia
	n	36	datos de la muestra	propia
	n-1	35	grados de libertad	tabla de T de Student
	$\alpha/2$	0,025	región crítica= (1-nivel de confianza)/2 ;nivel de confianza 0,95	
	$\alpha/2 ;(n-1)$	$(t_{0,025;35})=1,960$	Parámetros para encontrar el coeficiente de T de Student. $\alpha/2$ =columnas ;(n-1)=filas	
	γ_{15}	-0,346	autocorrelación en el retardo 15	Tabla de autocorrelaciones
	$SE_{\gamma_{15}}$	0,124	error típico en el retardo 15	
Desarrollo	Notación		Descripción	
Ecuaciones	$H_0 = \gamma_{15} = 0$		Los coeficientes de autocorrelación no son significativos	
	$H_1 = \gamma_{15} \neq 0$		Los coeficientes de autocorrelación son significativos)	
	$IC= 0 \pm \alpha/2 ;(n-1) * (SE_{\gamma_{15}})$		intervalo de confianza	
	$\gamma_{15} > IC_{\gamma_{15}}$		Si la autocorrelación del retado 15 es mayor que el Intervalo de confianza, entonces se acepta la H_0	
Solución	$IC= 0 \pm 1,960 * 0,124 = \pm 0,243$		El intervalo de confianza resulta ser $\pm 0,243$	
	$\gamma_{15} > IC_{\gamma_{15}}$ $-0.346 > -0,243$		Como no se cumple el intervalo de confianza, se acepta H_0 y se rechaza H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.	

Se denota que -0,346 es menor que -0,243. Es decir, no se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.

- *Análisis 2*

Tabla 8. *Análisis 2 de estacionalidad*

ANÁLISIS DE ESTACIONALIDAD	Notación	Valor	Descripción	Fuente
	γ_6	0,026	autocorrelación en el retardo 6	Tabla de autocorrelaciones
	SE_{γ_6}	0,150	error típico en el retardo 6	Tabla de autocorrelaciones
Desarrollo	Notación		Descripción	
Ecuaciones	$H_0 = \gamma_6 = 0$		Los coeficientes de autocorrelación no son significativos	
	$H_1 = \gamma_6 \neq 0$		Los coeficientes de autocorrelación son significativos)	
	$IC = 0 \pm t_{\alpha/2}; (n-1) * (SE \gamma_6)$		intervalo de confianza	
	$\gamma_6 > IC_{\gamma_6}$		Si la autocorrelación del retado 6 es mayor que el Intervalo de confianza, entonces se acepta la H_0	
Solución	$IC = 0 \pm 1,960 * 0,150$ $IC = \pm 0,294$		El intervalo de confianza resulta ser $\pm 0,294$	
	$\gamma_{15} > IC_{\gamma_{15}}$ $0,026 > -0,294$		No se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.	

Se denota que 0,026 es menor que 0,294. Es decir, no se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.

- *Análisis 3*

Tabla 9. Análisis 3 de estacionalidad

ANÁLISIS DE ESTACIONALIDAD	Notación	Valor	Descripción	Fuente
	Υ_{12}	0,026	autocorrelación en el retardo 12	Tabla de autocorrelaciones
	$SE_{\Upsilon_{12}}$	0,150	error típico en el retardo 12	Tabla de autocorrelaciones
Desarrollo	Notación		Descripción	
Ecuaciones	$H_0 = \Upsilon_{12} = 0$		Los coeficientes de autocorrelación no son significativos	
	$H_1 = \Upsilon_{12} \neq 0$		Los coeficientes de autocorrelación son significativos)	
	$IC = 0 \pm t_{\alpha/2}; (n-1) * (SE \Upsilon_{12})$		intervalo de confianza	
	$\Upsilon_{12} > IC_{\Upsilon_{12}}$		Si la autocorrelación del retardo 12 es mayor que el Intervalo de confianza, entonces se acepta la H_0	
Solución	$IC = 0 \pm 1,960 * 0,133$ $IC = \pm 0,260$		El intervalo de confianza resulta ser $\pm 0,260$	
	$\Upsilon_{12} > IC_{\Upsilon_{12}}$ $0,201 > 0,260$		No se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.	

Se denota que 0,201 es menor que 0,260. No se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.

- *Análisis 4*

Tabla 10. Análisis 4 de estacionalidad

ANÁLISIS DE ESTACIONALIDAD	Notación	Valor	Descripción	Fuente
	Υ_{18}	0,153	autocorrelación en el retardo 18	Tabla de autocorrelaciones
	$SE_{\Upsilon_{18}}$	0,115	error típico en el retardo 18	Tabla de autocorrelaciones
Desarrollo	Notación		Descripción	
Ecuaciones	$H_0 = \Upsilon_{18} = 0$		Los coeficientes de autocorrelación no son significativos	
	$H_1 = \Upsilon_{18} \neq 0$		Los coeficientes de autocorrelación son significativos)	
	$IC = 0 \pm t_{\alpha/2}; (n-1) * (SE \Upsilon_{12})$		intervalo de confianza	
	$\Upsilon_{18} > IC_{\Upsilon_{18}}$		Si la autocorrelación del retado 12 es mayor que el Intervalo de confianza, entonces se acepta la H_0	
Solución	$IC = 0 \pm 1,960 * 0,115$ $IC = \pm 0,2254$		El intervalo de confianza resulta ser $\pm 0,260$	
	$\Upsilon_{18} > IC_{\Upsilon_{18}}$ $0,153 > 0,2254$		No se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.	

Se denota que $-0,153$ es mayor que $-0,2254$. Es decir, cumple el intervalo de confianza, por lo que se rechaza H_0 y acepto H_1 . El coeficiente de autocorrelación es significativo. Por lo tanto, hay estacionalidad.

- *Análisis 5*

Tabla 11. Análisis 5 de estacionalidad

ANÁLISIS DE ESTACIONALIDAD	Notación	Valor	Descripción	Fuente
	Υ_{24}	0,153	autocorrelación en el retardo 24	Tabla de autocorrelaciones
	$SE_{\Upsilon_{24}}$	0,115	error típico en el retardo 24	Tabla de autocorrelaciones
Desarrollo	Notación		Descripción	
Ecuaciones	$H_0 = \Upsilon_{24} = 0$		Los coeficientes de autocorrelación no son significativos	
	$H_1 = \Upsilon_{24} \neq 0$		Los coeficientes de autocorrelación son significativos)	
	$IC = 0 \pm t_{\alpha/2}; (n-1) * (SE_{\Upsilon_{24}})$		intervalo de confianza	
	$\Upsilon_{24} > IC_{\Upsilon_{24}}$		Si la autocorrelación del retado 24 es mayor que el Intervalo de confianza, entonces se acepta la H_0	
Solución	$IC = 0 \pm 1,960 * 0,092$ $IC = \pm 0,18$		El intervalo de confianza resulta ser $\pm 0,260$	
	$\Upsilon_{24} > IC_{\Upsilon_{24}}$ $0,016 > 0,18$		No se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.	

Se denota que 0,016 es menor que 0,18. No se cumple el intervalo de confianza, por lo que se acepta H_0 y rechazo H_1 . El coeficiente de autocorrelación no es significativo. Por lo tanto, no hay estacionalidad.

Interpretación de estacionalidad:

El análisis muestra que es incorrecta la hipótesis de que cada 6 meses había estacionalidad

3.3.3.3.Descomposición de la serie histórica

Construcción del a serie histórica

Inicialmente se ejecuta el código en el programa R que se encuentra en el Anexo F. Es necesario tener en cuenta que se debe trabajar con algunos paquetes de R para el análisis de datos, que se pueden observar a continuación:

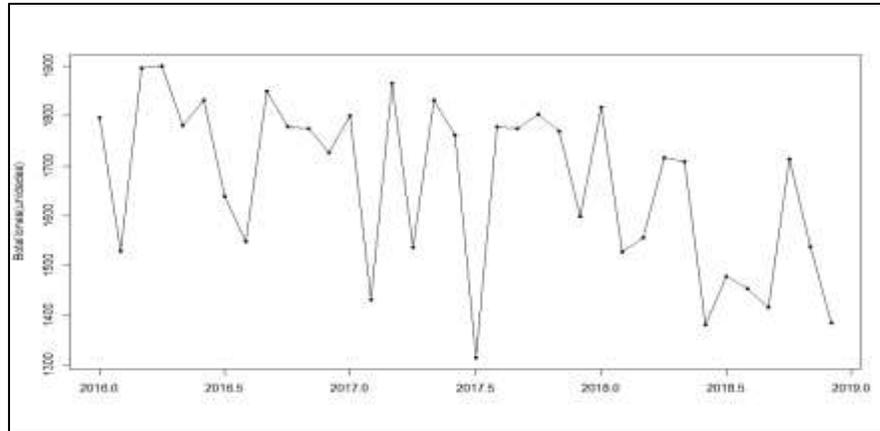


Figura 20. Serie temporal desde el año 2016 hasta el 2019 de la empresa de estudio.

Descomposición de la serie de tiempo: tendencia, estacionalidad y aleatoriedad.

La descomposición de la serie de tiempo resulta necesaria para el análisis tanto gráfico como cuantitativo. En la siguiente gráfica se puede describir el comportamiento de los datos a través del tiempo, en cuanto a tendencia, estacionalidad y su aleatoriedad.

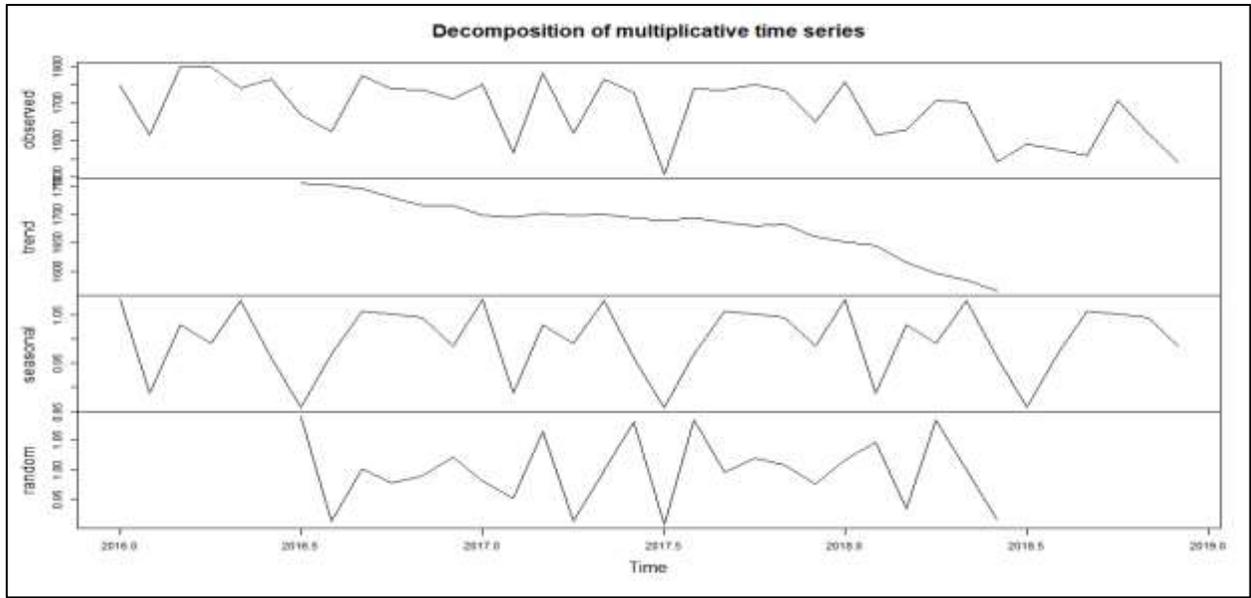


Figura 21. Descomposición de la serie de tiempo.

3.3.3.4. Análisis de comportamiento estacionario

Una serie temporal estacionaria presenta las condiciones de que la media, la varianza y la covarianza no son funciones del tiempo. Este análisis se hace necesario para poder adaptar la serie a un modelo de pronóstico ARIMA

```

Augmented Dickey-Fuller Test
data: y
Dickey-Fuller = -3.6844, Lag order = 3, p-value = 0.04057
alternative hypothesis: stationary

```

Figura 22. Prueba de Dickey-Fuller

De acuerdo con regla general, cuando el valor de p es inferior al 5%, se tiene pruebas sólidas contra la hipótesis nula, por lo que se rechaza la hipótesis nula. De acuerdo con los resultados de la prueba anterior, el valor p es 0.04057, que es < 0.05 , por lo tanto rechazamos el nulo a favor de la hipótesis alternativa de que la serie de tiempo es estacionaria (Kimnewzealand, 2017).

3.3.4. Análisis de datos extrapolativos

3.3.4.1. Valorizaciones iniciales

Al ejecutar el código en R del Anexo F se obtiene los siguientes datos que a continuación se subdividen para mayor comprensión.

3.3.4.2. Valores perdidos y frecuencia (Frequency)

Como se puede observar la figura23, el análisis de valores perdidos, su valor es 0, lo que significa que la serie de tiempo está completa en cada año. Además, el análisis de frecuencia muestra una frecuencia de 12, es decir, estamos trabajando con una serie mensual.

```
> ## Verificar valores faltantes
> sum(is.na(y))
[1] 0
> ##Verificar la frecuencia
> frequency(y)
[1] 12
```

Figura 23. Código valores perdidos y frecuencia

3.3.4.3. Resumen(summary)

Nos permite apreciar un resumen estadístico básico de la serie temporal, como la media, el primer cuartil, la mediana, la media, el tercer cuartil y el valor máximo, como se muestra en la figura 24.

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
1315	1534	1721	1667	1797	1900

Figura 24. Código Resumen Estadístico

3.3.4.4. Diagrama de cajas (Boxplot)

Para el análisis de la estacionalidad se utiliza como herramienta un diagrama de cajas para ver los efectos estacionales. En la siguiente ilustración se observa el comportamiento de la gráfica con respecto a los datos agregados. En donde se puede notar que existe más altos que la media en los meses 3,6 y 9; lo que quiere decir que allí se concentra la mayor demanda de botellones. Como se muestra en la figura 25.

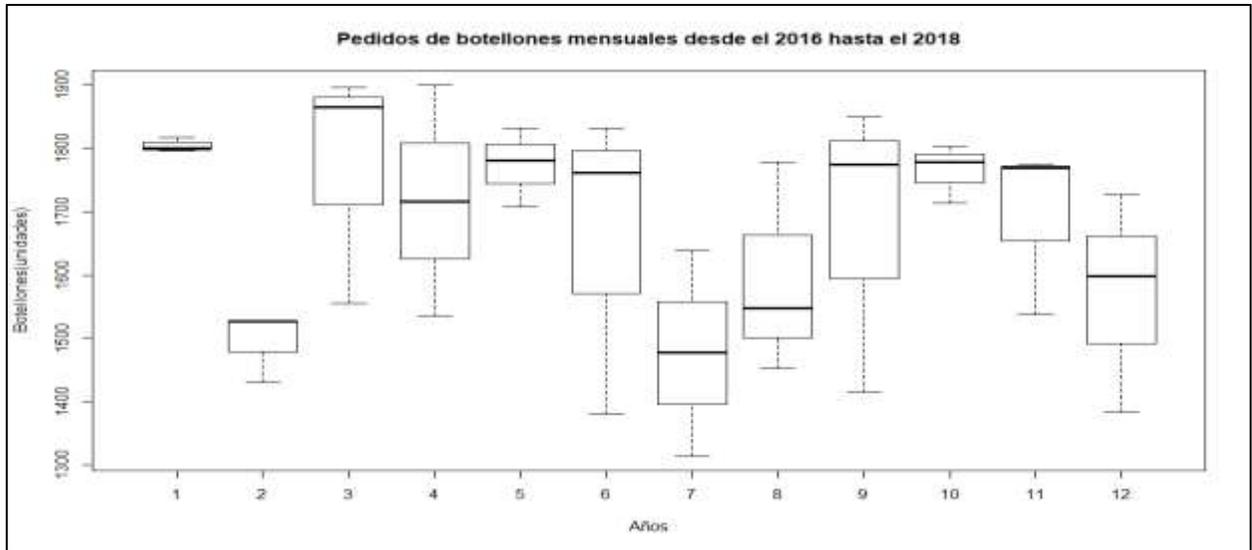


Figura 25. Diagrama de cajas.

3.3.4.5.. Resumen del comportamiento de la serie de tiempo

Tabla 12. Resumen del comportamiento de la serie de tiempo

Características de la serie histórica	Descripción
Patrón de datos:	Es una serie con tendencia y estacionaria
Horizonte de tiempo:	Corto Plazo
Tipo de modelo:	Serie de tiempo
Cantidad de datos:	36

3.4. Selección de pronósticos

La selección de los métodos de pronóstico tradicional se hace de acuerdo a la tabla del Anexo G en donde se puede apreciar los métodos que se puede utilizar según las características de la serie. A continuación, en la tabla 13 se puede apreciar los métodos escogidos respecto a las características que presenta la serie.

Tabla 13. Requisitos para selección del método de pronóstico.

Método	Patrón de series de tiempo	Horizonte de tiempo	Tipo de modelo	Requisitos mínimos de datos	
				No estacionales	Estacionales
Informal	ST,T,S	S	TS	1	
Suavizamiento exponencial lineal	T	S	TS	3	
Suavizamiento exponencial cuadrático	T	S	TS	4	
Regresión simple	T	I	C	10	
Modelos de tendencia exponencial	T	I,L	TS	10	
Ajuste la curva s	T	I,L	TS	10	
Modelos de Gompertz	T	I,L	TS	10	
Curvas de crecimiento	T	I,L	TS	10	

Patrones de datos: estacionarios (ST), tendencia (T), estacional (S), cíclico (C)
 Horizonte de tiempo: Costo plazo-menor de 3 meses (S),intermedio (I),Largo plazo (L)
 Tipo de modelo: serie de tiempo (TS), causal (C)
 Estacionalidad: longitud de estacionalidad (s)
 Variable: número de variables (v)

Fuente: Hanke (2010)

3.5.Desarrollo de Pronósticos

3.5.1. Metodología de Hanke y el software POM

Como primera instancia, se ingresan los datos al software a utilizar, en este caso POM, como se observa en la figura 26.

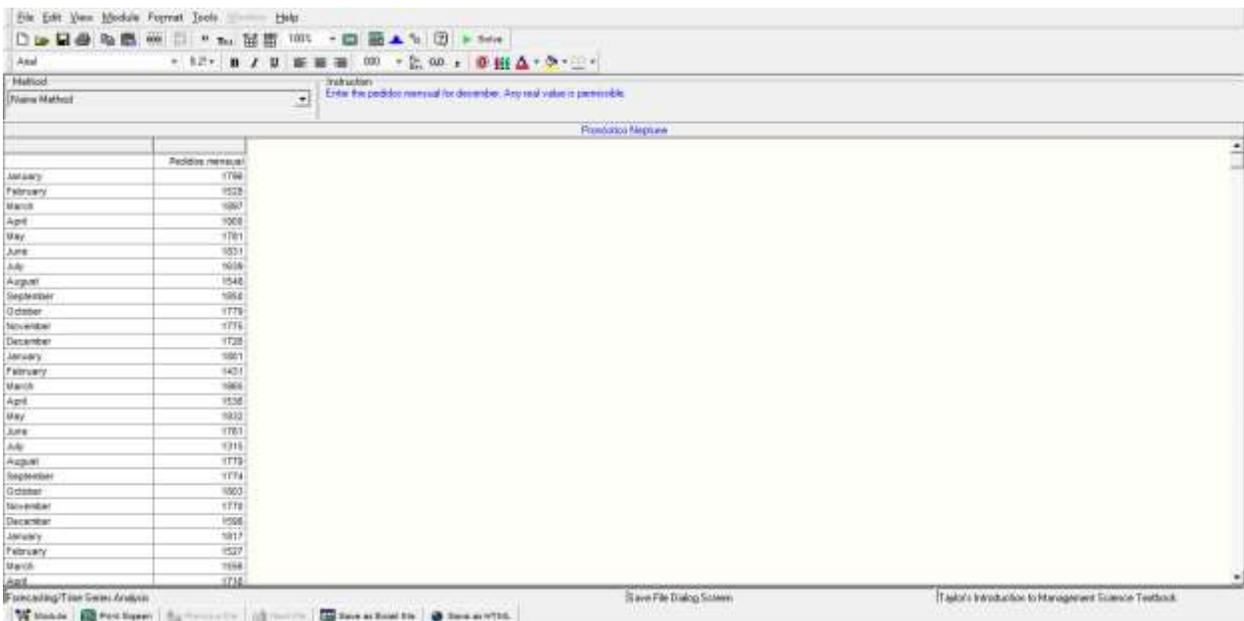


Figura 26. Datos de pedidos de la embotelladora en POM

3.5.1.1. Métodos aplicados en el software POM

A partir del análisis de datos se puede seleccionar los métodos que ofrece el software POM, de los cuales forman parte el método informal, el método de suavización exponencial y el método de tendencia exponencial, lo cual se puede observar en el Anexo H. Cada gráfico consta de los errores de pronóstico y la cantidad pronosticada para un período, siendo este la cantidad máxima a pronosticar por parte del software mencionado. En la tabla 14 se puede observar un resumen de lo mencionado.

Tabla 14. Resumen de Métodos de pronóstico mediante el software POM

Pronósticos con POM		MÉTODOS		
		Método ingenuo	suavización exponencial lineal	modelos de tendencia exponencial
Medidas de error	Bias(Error medio)	-11,743	-60,354	-58,694
	MAD(Desviación Absoluta Media)	173,229	131,35	131,33
	MSE(Error Cuadrático Medio)	50479,97	27192,88	26988,92
	Error Estándar(demon=n-2=33)	231,386	169,826	169,188
	MAPE(Error Porcentual Absoluto Medio)		8,507	8,496
Pronóstico	Siguiente período	1385	1584,76	1850,167

3.5.2. Metodología de IBM SPSS Statistics Versión 22

3.5.2.1. Ingreso de datos

Se ingresan la serie histórica al software, de manera que se definan las variables utilizadas: pedidos, años y meses. Se caracteriza a la variable pedidos como una variable numérica de escala y sin decimales. Las variables de tiempo son nominales y se configuran en dos partes; la variable de años se considera como una variable numérica y la variable de meses se la configura como fecha para que se pueda añadir los meses a la serie histórica. El resultado se obtiene como se observa en la figura 27.

Año	Fecha	Pedidos
2016	Jan	1796
2016	Feb	1528
2016	Mar	1897
2016	Apr	1900
2016	May	1781
2016	Jun	1831
2016	Jul	1639
2016	Aug	1548
2016	Sep	1850
2016	Oct	1779
2016	Nov	1775
2016	Dec	1726
2017	Jan	1801
2017	Feb	1431
2017	Mar	1865
2017	Apr	1536

Figura 27. Ingreso de datos a SPSS V.22

3.5.2.2. Modelo de pronóstico

Después de ello se considera analizar un modelo de pronóstico que se configura a través de la interfaz de SPSS. Como primera instancia se configura las variables de entrada. En este caso se une los meses y los años para formar una variable mensual, definiendo que el año tiene 12 meses. Luego se designa a cada variable como dependiente e independiente; en este caso la variable dependiente se trata de los pedidos y la variable independiente el tiempo que es mensual. Después se realiza otras configuraciones de resultado y de gráficas, nos da los resultados como se puede observar en el Anexo I. De manera que selecciona automáticamente el aditivo de Winters.

3.5.3. Metodología de Software Forecast Pro

3.5.3.1. Ingreso de Datos

En este caso se configura una hoja de cálculo, en el paquete de office, luego se ingresa dicha hoja en el software para que interprete los datos de pedidos.

3.5.3.2. Elección del mejor método de pronóstico

El software detecta los datos y los interpreta por defecto, por lo cual se configura ciertos parámetros para obtener un resultado óptimo. En la plataforma, cabe recalcar que se genera un

reporte de datos, como se ve en el Anexo J y. De este reporte se destaca los resultados más importantes, que se observan en la parte de resultados.

3.5.4. Metodología de Redes Neuronales con R

3.5.4.1. Generalidades

Tipo de redes neuronales a utilizar

- Redes neuronales con perceptrones de múltiples capas (MLP)

Uso de paquetes

- `library(ggplot2)`.- Se basa en la gramática de los gráficos, la idea de que puede construir todos los gráficos a partir de los mismos componentes: un conjunto de datos, un conjunto de geomarcas visuales que representan puntos de datos y un sistema de coordenadas.
- `library(nnfor)`. Se utiliza para el pronóstico de series de tiempo con perceptrones de múltiples capas. Permite la especificación de redes totalmente automática, semi-manual o totalmente manual. (Kourentzes, 2019)

3.5.4.2. Tipo de pronóstico que arroja

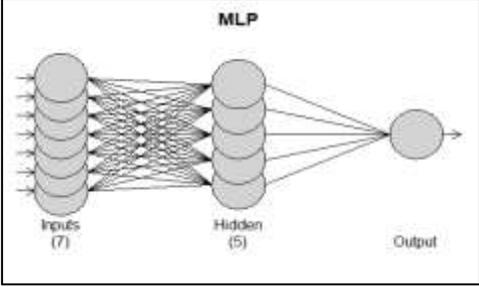
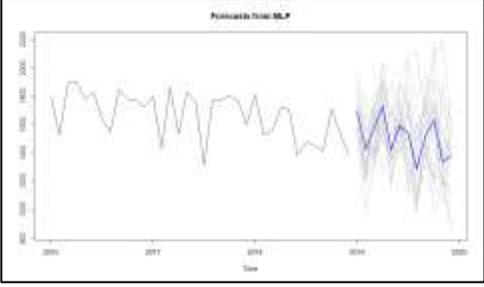
Extrapolativo univariado

Extrapolativo ya que predice la continuación de patrones históricos de la serie histórica (Méndez & López, 2014), y univariado debido a que utiliza una variable, la demanda. (Kourentzes, 2019)

3.5.4.3. Desarrollo de la Red Neuronal automática de NNFOR.

En esta primera fase se puede observar que por defecto el paquete NNFOR encuentra el óptimo de forma automática. Como se observa en la tabla 15.

Tabla 15. *Modelo automático según NNFOR*

N° Prueba	Características del modelo	
01	<p style="text-align: center;">Entrenamiento01</p>  <p style="text-align: center;">MLP</p> <p style="text-align: center;">Inputs (7) Hidden (5) Output</p>	<p style="text-align: center;">Pronóstico01</p>  <p style="text-align: center;">Pronóstico Time MLP</p>
	MSE:	44.0968

Análisis de resultados

Como se observa en la gráfica el pronóstico inicial y sugerido por el paquete NNFOR conlleva un error de MSE de 44,097, pero la ventaja de la aplicación de redes neuronales nos dirige a una mejor interpretación. La salida indica que la red resultante tiene 5 nodos ocultos, se entrenó 20 veces y se combinaron los diferentes pronósticos utilizando el operador de la mediana. La función `mlp()` genera automáticamente conjuntos de redes, cuyo entrenamiento comienza con diferentes pesos iniciales aleatorios. Además, proporciona las entradas que se incluyeron en la red.

CAPÍTULO IV

4. Propuesta

En este apartado comprende la configuración de la Red Neuronal MLP. Como primera instancia se presenta la iniciación del desarrollo de la red neuronal, la cual representa las neuronas iniciales del modelo de la red, es decir la primera capa, la cual es posible establecer mediante el análisis de datos realizado en el capítulo anterior. Después de esto se continúa con las pruebas de la red neuronal en donde se define la configuración de las capas escondidas. Establecido todo lo anterior se procede al entrenamiento de las redes neuronales.

4.1. Iniciación del desarrollo de la red neuronal

En este apartado se define la primera capa de la red neuronal, de manera que a continuación se describe la configuración en cuanto a estacionalidad y tendencia de la serie histórica

4.1.1. Configuración de estacionalidad

En la figura 28 se encuentra caracterizada gráficamente la descomposición de la serie de tiempo, en donde se encuentra la estacionalidad, la cual se describe con los siguientes patrones:

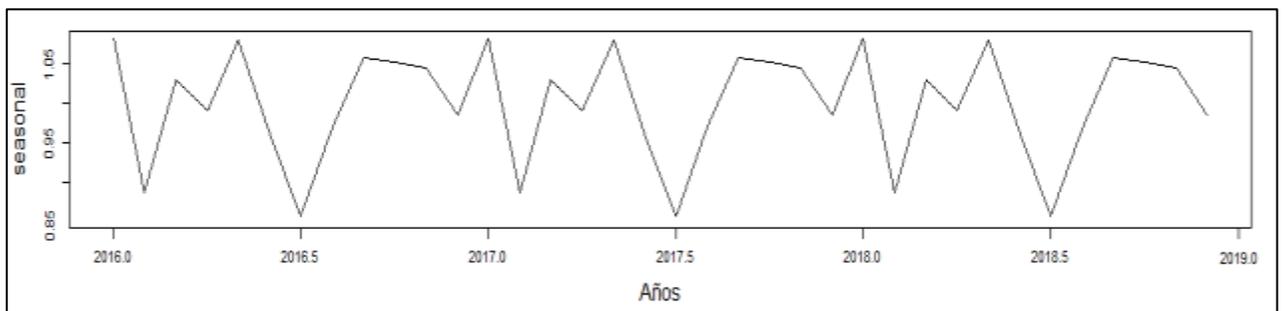


Figura 28. Estacionalidad por descomposición multiplicativa.

De acuerdo al apartado de la estacionalidad de la descomposición multiplicativa se obtiene un patrón anual que parte desde cada año y se repite de forma anual.

De manera que la existencia de 3 patrones, pero para aprovechar el análisis de patrones de la red neuronal se divide cada patrón en 4 partes, de manera que se utiliza 12 neuronas iniciales, lo cual quiere decir que se realiza de forma trimestral.

Entonces el número de perceptrones primera capa= $36/3=12$

Para ahorrar tiempo en la capacitación de cada prueba se utiliza el valor predeterminado de 20 iteraciones de la misma red, cuyo valor implica un compromiso entre la velocidad de entrenamiento y el rendimiento. De manera que el código y resultados se plantean según la Figura 29. La red neuronal se presenta en la figura 30 de acuerdo a la configuración de la primera capa y su modo óptimo de capas escondidas. El pronóstico según esta fase se presenta en la Figura 31.

```
> fit1<-mlp(y,sel.lag=FALSE, lag=1:12, reps = 20)
> print(fit1)
MLP fit with 5 hidden nodes and 20 repetitions.
Series modelled in differences: D1.
Univariate lags: (1,2,3,4,5,6,7,8,9,10,11,12)
Forecast combined using the median operator.
MSE: 7.3677.
```

Figura 29. Código de fase2

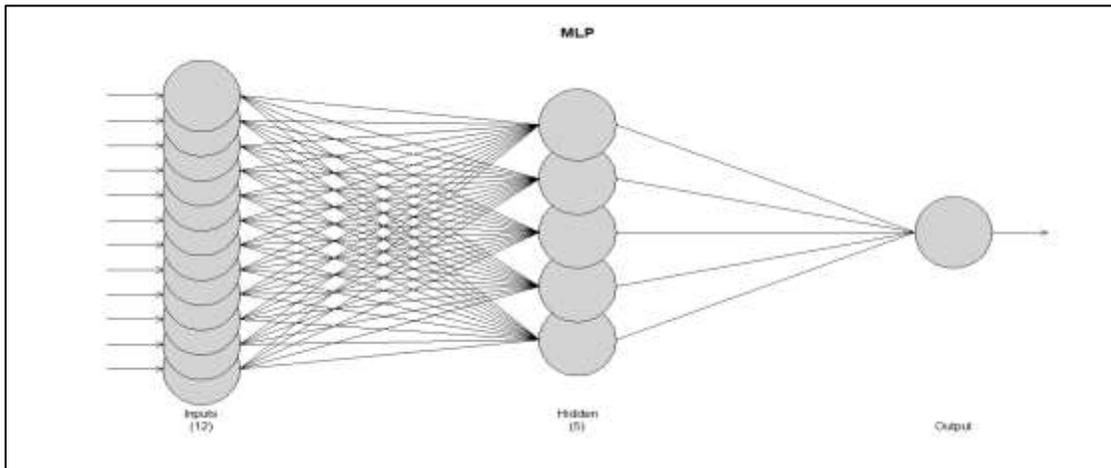


Figura 30 Red neuronal con configuración en la capa de entrada-Fase 02

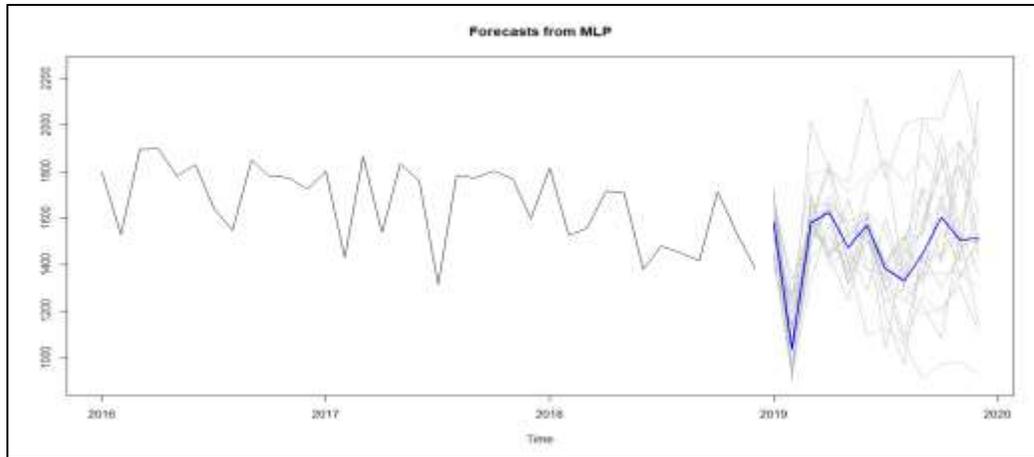


Figura 31. Pronóstico de la demanda fase 2

4.1.2. Análisis de tendencia

Las redes neuronales no son muy buenas para modelar tendencias, como la red modelada presenta estacionalidad y tendencia se puede realizar diferenciaciones asociadas a la estacionalidad trimestral, en este caso se pone uno porque la serie presenta tendencia en toda la serie histórica.

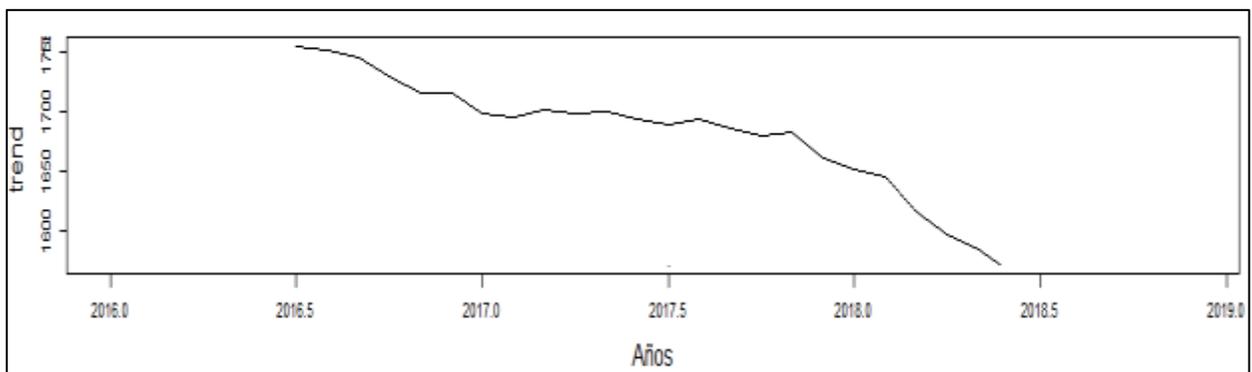


Figura 32. Tendencia mediante la descomposición multiplicativa

Como se observa en la Figura 32 la tendencia tiene una pendiente negativa, además de que inicia desde la mitad del año 2016 hasta la mitad del año 2018.

Este apartado está asociado con el análisis de los perceptrones de la primera capa, lo cual sugiere que se analice a partir del 2do trimestre, hasta el 10mo trimestre, de manera que la programación se presenta en la figura 33. La estructura de la red neuronal se mantiene como la figura 30 de la fase 2 y su pronóstico se presenta como la figura 34.

```

> fit1<-mlp(y,sel.lag=FALSE, lag=1:12,difforder=c(2,10),reps = 20)
> print(fit1)
MLP fit with 5 hidden nodes and 20 repetitions.
Series modelled in differences: D3D10.
Univariate lags: (1,2,3,4,5,6,7,8,9,10,11,12)
Forecast combined using the median operator.
MSE: 8.9263.

```

Figura 33. Código de la fase 3

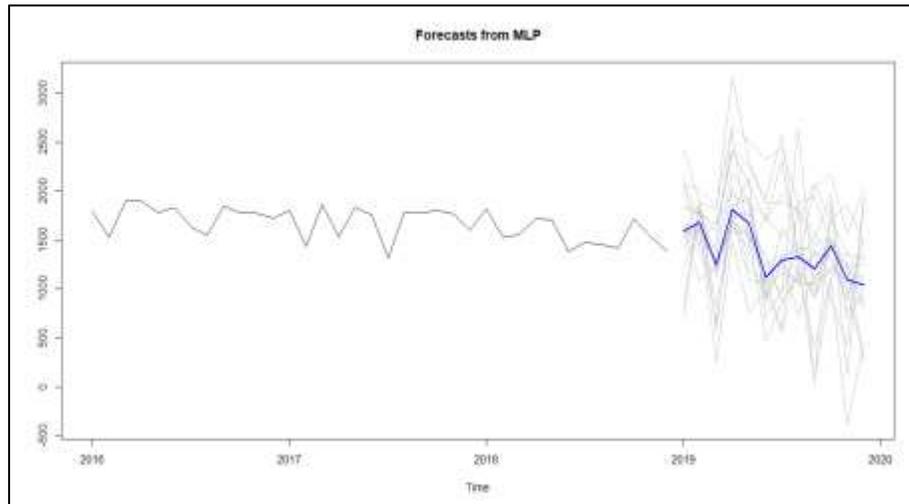


Figura 34. Pronóstico de la fase 3

4.2. Configuración estructura multicapa de la RN

Este apartado corresponde a la añadidura de capas y nodos. En el Anexo K, se puede observar cómo se comportan las combinaciones de la red. De acuerdo a la literatura hay que configurarla con múltiplos menores a la capa anterior por ello se va anulando continuamente y se escoge el valor de error en donde el error se va estabilizando. A continuación, se presenta la red óptima en cuanto a este parámetro.

```

> fit1<-mlp(y,hd = c(22,26,12),sel.lag=FALSE, lag=1:12,difforder=c(3,10),reps = 20)
> print(fit1)
MLP fit with (22,26,12) hidden nodes and 20 repetitions.
Series modelled in differences: D3D10.
Univariate lags: (1,2,3,4,5,6,7,8,9,10,11,12)
Forecast combined using the median operator.
MSE: 1.378.

```

Figura 35. Código de fase 4

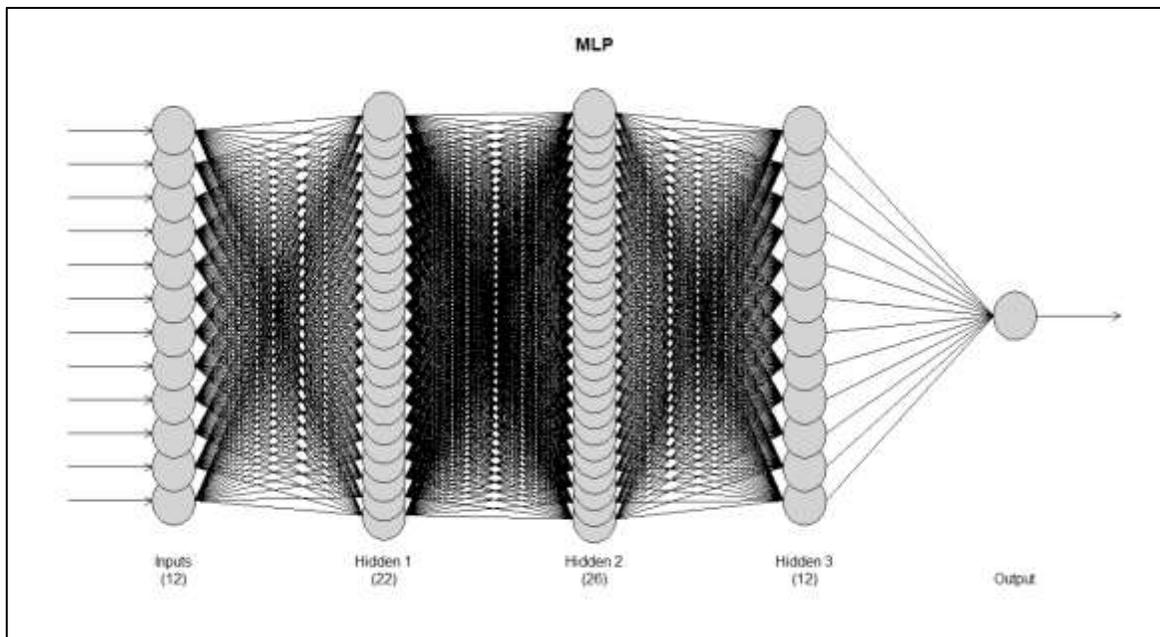


Figura 36. Fase 4 RN óptima

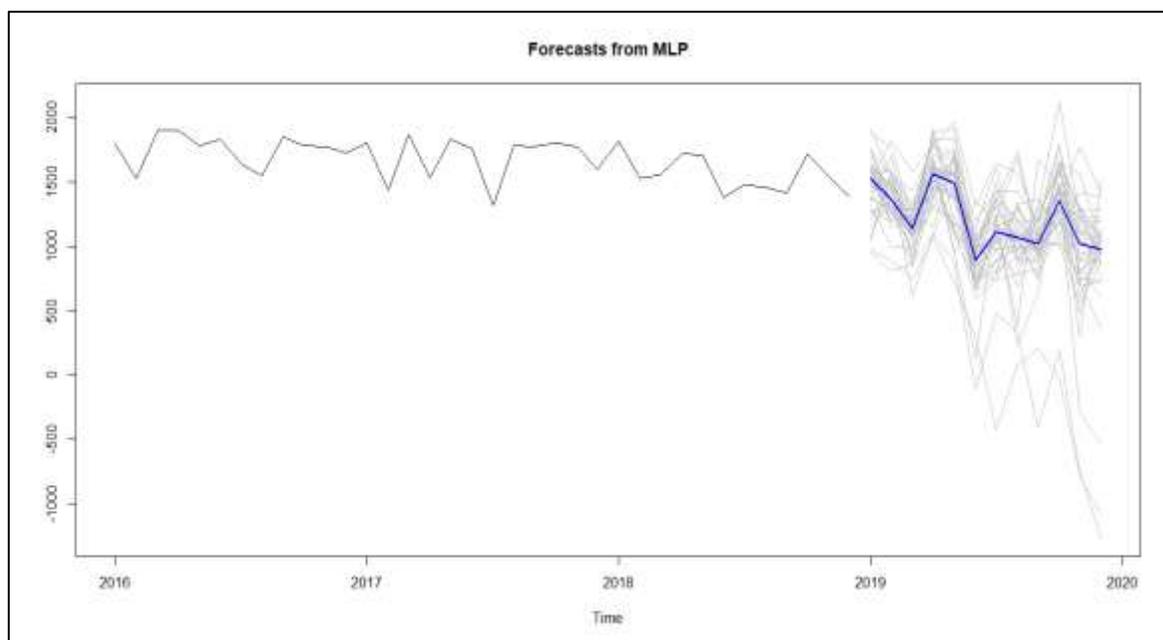


Figura 37. Fase 4 pronostico óptimo.

Análisis de resultados de la fase 4

En esta fase se desarrolla las capas y nodos de la red, para configurarla, de modo que esa es la gráfica óptima en cuanto a nodos y capas, quedando como resultado 22 perceptrones en la primera

capa escondida, 26 en la siguiente y en la última 12. Con esta combinación se obtiene un MSE de 1,378.

4.3. Entrenamiento de la Red Neuronal y pronósticos mediante Redes Neuronales

A continuación, se presenta el resultado del desarrollo de las redes neuronales y sus debidas configuraciones. Se presenta como una red de 12 regresiones lineales, se la analizó cada 12 patrones y de esta se despliegan 3 capas escondidas con 22 perceptrones en la primera capa, con 26 en la segunda y con 12 en la última. Se iteró 20 veces el modelo seleccionando el óptimo, además se la entrenó 10 veces hasta el punto de que el error se transformara en una constante. El error de pronóstico es 0,9577 como se puede observar en el siguiente resultado de la consola de R-project de la figura 42. En el Anexo M, se puede observar el código de la Red Neuronal óptima y su respectivo entrenamiento.

```
> fit1<-mlp(y,hd = c(22,26,12),sel.lag=FALSE, lag=1:12,difforder=c(3,10),reps = 20)
> print(fit1)
MLP fit with (22,26,12) hidden nodes and 20 repetitions.
Series modelled in differences: D3D10.
Univariate lags: (1,2,3,4,5,6,7,8,9,10,11,12)
Forecast combined using the median operator.
MSE: 0.9577
```

Figura 38. Código y resultados de la fase final

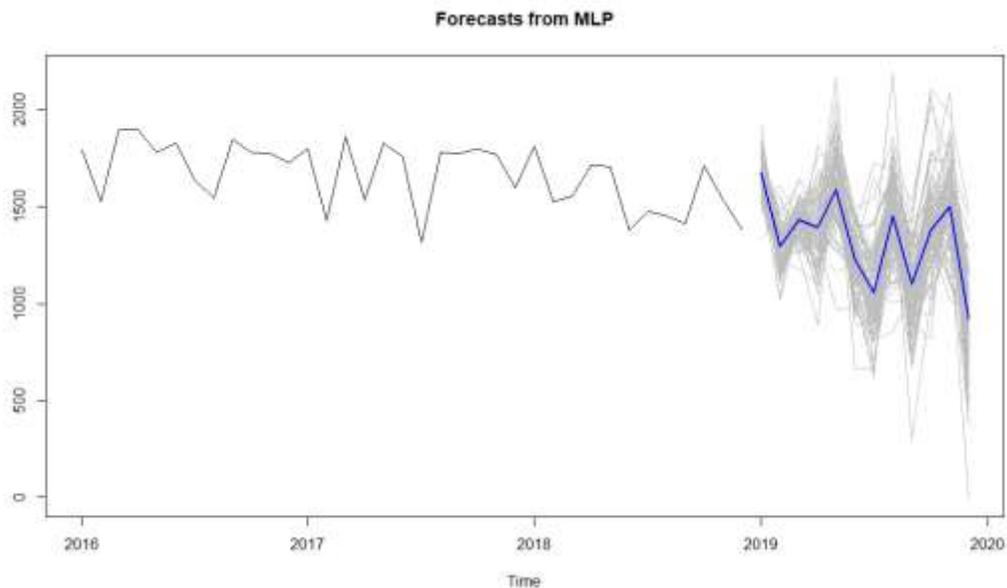


Figura 39. Pronóstico óptimo final.

A continuación se puede observar la estructura en la cula trabaja la red neuronal de capas multiples.

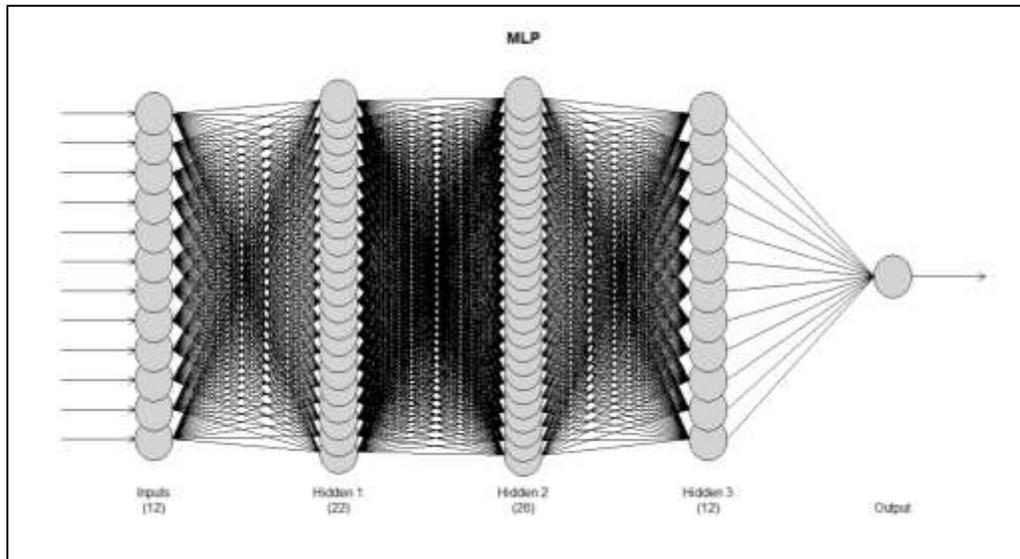


Figura 40. Fase 2 RN óptimo.

EL resultado de los datos del pronóstico para el año 2019 mediante el uso de redes neuronales se puede apreciar en la tabla 16.

Tabla 16. Datos del pronóstico del año 2019

Año/ Meses	Enero	Febrero	Marzo	Abril	Mayo	Junio
2019	1663,491	1310,196	1460,746	1351,770	1625,865	1216.798
Año/ Meses	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
2019	1012.459	1471.138	1059.157	1325.625	1599.504	834.401

4.4. Selección del modelo

De acuerdo a la tabla anterior el método seleccionado sería el de Redes neuronales multicapas ya que este presente el mínimo error respecto al indicador MSE y RMSE. Además de que el número de períodos a pronosticar es programable, permitiendo la flexibilidad necesaria para posteriores planificaciones de la empresa de estudio. Cabe aclarar que en el caso del uso del POM V.04 se restringe a un obtener como resultado el pronóstico de un solo período. De manera que para el pronóstico de un mes se presenta un MSE de 26988,92 con el modelo de

tendencia exponencial, cuyo valor dista considerablemente del resultado de 0,96 obtenido con el modelo de red neuronal MLP para doce períodos, de manera que debería el MSE propuesto por el software POM V.04 debería ser más alto para 12 períodos.

A continuación se presenta la comparación de resultados en cuanto a 12 períodos en base a la Red Neuronal óptima, Forecst Pro V.05 , SPSS V22 y el modelo actual con el que se maneja la empresa de estudio.

Tabla 17. Características de los modelos de pronóstico

<i>Parámetros</i>		<i>Red Neuronal óptima</i>	<i>Forecast Pro V5.0</i>	<i>SPSS V22</i>	<i>Modelo de la empresa</i>
Características del modelo		Redes neuronales con perceptrones multicapa (MLP)	Suavizamiento exponencial	Aditivo de Winters	Pronóstico Visionario
		Aprendizaje con el método de Backpropation (BP) y utiliza un algoritmo con un Filtro Neural de Iteración (INF)			
		Package: nnfor			
		Capa de entrada : 12 neuronas Capa escondida 1: 22 neuronas Capa escondida 2:26 neuronas Capa escondida 3:12 neuronas			
Pronóstico para el 2019	Enero	1663,49	1601	1598	1900
	Febrero	1310,2	1359	1288	1600
	Marzo	1460,75	1552	1566	1900
	Abril	1351,77	1519	1510	1900
	Mayo	1625,87	1563	1567	1900
	Junio	1216,8	1453	1451	1900
	Julio	1012,46	1332	1270	1600
	Agosto	1471,14	1417	1386	1600
	Septiembre	1059,16	1466	1473	1900
	Octubre	1325,63	1550	1558	1900
	Noviembre	1599,5	1484	1487	1900
	Diciembre	834,4	1383	1363	1600
MSE		0,96	14400	11406,24	537289
RMSE		0,98	120	106,8	733

CONCLUSIONES

- La revisión del estado del arte comprende una indagación de nuevos sentidos y direcciones que han tomado los avances tecnológicos en cuanto a utilización de las redes neuronales para la elaboración de pronósticos es cada vez más precisos en cuanto a la demanda de productos en el mundo.
- El diagnóstico de la empresa se lo realizó mediante un checklist, de donde se pudo obtener información relevante tal como el manejo de la información de la empresa en cuanto a datos de pedidos, lo cual permite hacer predicciones acertadas orientadas a los pedidos de los clientes. Además información de la planificación por el método visionario por la que se maneja la empresa, que permitió la comparación del MSE con el modelo de Redes neuronales MLP.
- En cuanto a gestión de datos se prepararon los recursos a utilizar en redes neuronales, tales como recolección de datos y análisis de datos para la construcción del modelo óptimo de redes neuronales. Además se realizó los pronósticos con los métodos tradicionales para poder comparar con el modelo de red neuronal óptimo.
- Debido a la capacidad que poseen las redes neuronales de aprender en base a patrones, se utilizó los patrones de tiempo en este caso la tendencia y el comportamiento patrón anual, por lo que fue posible hacer uso de ellas en problemas de predicción. En el proceso de entrenamiento de una red neuronal es muy importante el criterio de parada, se debe tener en cuenta para lograr una buena generalización de la red neuronal a la hora de operar. Una de las formas de obtener una buena generalización es no ser tan rígido con el aprendizaje del conjunto de entrenamiento, por ello es importante realizar entrenamientos de la red mediante iteraciones.

RECOMENDACIONES

- Se recomienda que para la actualización de información sobre métodos de pronóstico con redes neuronales participar de proyectos y grupos virtuales, ya que existen grandes sociedades en red sobre esto, además de que la tecnología crece a pasos agigantados
- Se recomienda realizar un diagnóstico con enfoque a pronósticos cada año para corroborar el avance en cuanto a servicio al cliente, además de que es muy importante seguir almacenando los datos de pedidos y otros para ir realizando modelos más fuertes con análisis multivariable.
- Se recomienda utilizar el método de redes neuronales multicapas para casos de pronósticos en donde la demanda tenga un comportamiento con aleatoriedad y presente un comportamiento no lineal.
- Se recomienda utilizar los resultados para temas de planificación, y control de metas en los distribuidores de la empresa de estudio.

Referencias Bibliográficas

- Abraham, E. R., dos Reis, J. G. M., Colossetti, A. P., de Souza, A. E., & Tolo, R. C. (2017). Neural Network System to Forecast the Soybean Exportation on Brazilian Port of Santos. *IFIP International Conference on Advances in Production Management Systems*, 83–90. https://doi.org/10.1007/978-3-319-66926-7_10
- Aburto, L., & Weber, R. (2007). A Sequential Hybrid Forecasting System for Demand Prediction. *Machine Learning and Data Mining in Pattern Recognition. MLDM 2007. Lecture Notes in Computer Science*, vol 4571., 518–532. https://doi.org/10.1007/978-3-540-73499-4_39
- Allaire, J., Chollet, F., RStudio, & Google. (2019). Keras. Retrieved from <https://keras.rstudio.com/>
- Ballou, R. (2004). *Logística. Administración de la cadena de suministro*. (Pearson Educación, Ed.) (5ta ed.). México.
- Carmona, F. (2007). *Curso Básico de R*. Retrieved from http://www.ub.edu/stat/docencia/EADB/Curso_basico_de_R-bn.pdf
- Chollet, F., & Allaire, J. (2017). *Deep Learning with R*. (MEAP edition, Ed.).
- Crone, S., & Kourentzes, N. (2010). Feature selection for time series prediction - a combined filter and wrapper approach for neural networks. <https://doi.org/10.1016/j.neucom.2010.01.017>
- El Telégrafo. (2017, June 28). El 95% de las empresas en el país son mipymes Esta noticia ha sido publicada originalmente por. Retrieved from <https://www.eltelegrafo.com.ec/noticias/economia/4/el-95-de-las-empresas-en-el-pais-son-mipymes%0A>
- Ezekwesili, R., Shahzad, M. K., Baboli, A., & Tonadre, R. (2018). Optimizing Bootstrap method to improve forecasting accuracy in business jet spare parts supply chains. *Proceedings of the*

- 2018 *International Conference on Optimization and Applications, ICOA 2018*, 1–6.
<https://doi.org/10.1109/ICOA.2018.8370567>
- Fernández, L. A., Martínez, A. H., & Fernández, J. M. (2013). *Introducción a los modelos de regresión*. Distrito Federal, UNKNOWN: Plaza y Valdés, S.A. de C.V. Retrieved from <http://ebookcentral.proquest.com/lib/utnortesp/detail.action?docID=4722107>
- Fu, W., Chien, C.-F., & Lin, Z.-H. (2018). A Hybrid Forecasting Framework with Neural Network and Time-Series Method for Intermittent Demand in Semiconductor Supply Chain. *IFIP International Conference on Advances in Production Management Systems*, 65–72.
https://doi.org/10.1007/978-3-319-99707-0_9
- Hanke, J. (2010). *Pronósticos en los negocios*. (Person Educación, Ed.) (9a. edición). México.
- Heizer, J., Render, B., & Munson, C. (2017). *Operations Management Sustainability and Supply Chain Management*. (PEARSON, Ed.) (12th ed.).
- Hernández, C. (2004). *Relación entre la distribución y posición genética en las especies del género *tropaeolum*, sección Chilensia*.
- Hu, Y., Sun, S., & Wen, J. (2014). Agricultural Machinery Spare Parts Demand Forecast Based on BP Neural Network. *Applied Mechanics & Materials*, (635–637), 1822–1825. Retrieved from <http://10.0.15.188/www.scientific.net/AMM.635-637.1822>
- Hyndman, R., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). Australia: Texts.
- Kimnewzealand. (2017). Time Series Analysis and Modeling with the Air Passengers Dataset. Retrieved from http://rstudio-pubs-static.s3.amazonaws.com/311446_08b00d63cc794e158b1f4763eb70d43a.html
- Kourentzes, N. (2019). Nikolaos Kourentzes predicción de la investigación. Retrieved from

<http://kourentzes.com/forecasting/2019/01/16/tutorial-for-the-nnfor-r-package/>

- Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario. Retrieved from https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_ano/orientadora1/monograias/matich-redesneuronales.pdf
- Méndez, G., & López, E. (2014). Metodología para el pronóstico de la demanda en ambientes multiproducto y de alta variabilidad, 18. Retrieved from <http://www.scielo.org.co/pdf/tecn/v18n40/v18n40a08.pdf>
- Montemayor, E. (2013). *Métodos de pronósticos para negocios*. (Instituto Tecnológico y de Estudios Superiores & Monterrey, Eds.). México.
- Newbold, P., Carlson, W., & Thorne, B. (2008). *Estadística para administración y economía* (6ta ed.). Madrid.
- Paradis, E. (2003). *R para Principiantes*. France: Universit Montpellier II. Retrieved from https://cran.r-project.org/doc/contrib/rdebut_es.pdf
- PricewaterhouseCoopers. (2009). Administrando efectivamente en tiempos de crisis. Retrieved from <https://www.pwc.com/py/es/publicaciones/assets/admintc.pdf>
- Ramasubramanian, K., & Singh, A. (2019). *Machine Learning Using R* (2da ed.). Delhi, India. Retrieved from <https://doi.org/10.1007/978-1-4842-4215-5>
- Saha, C., Lam, S. S., & Boldrin, W. (2015). Demand Forecasting for Server Manufacturing Using Neural Networks Demand Forecasting for Server Manufacturing Using Neural Networks State University of New York at Binghamton. *Proceedings of the 2014 Industrial and Systems Engineering Research Conference*, (June 2014).
- Salcedo, L. (2018). *Redes Neuronales*. Retrieved from <https://github.com/LuisAlejandroSalcedo/Redes-Neuronales>

- Scenio. (2018). ¿Qué es una Red Neuronal? Parte 2: La Red | DotCSV. Retrieved from <https://www.youtube.com/watch?v=uwbHOpp9xkc>
- Sellers Rubio, R., & Casado Díaz, A. B. (2013). *Introducción al marketing*. Alicante, SPAIN: ECU. Retrieved from <http://ebookcentral.proquest.com/lib/utnortesp/detail.action?docID=3215100>
- SENPLADES. (2017). *Plan Nacional de Desarrollo 2017 2021*. (Secretaría Nacional de Planificación y Desarrollo, Ed.). Quito. Retrieved from http://www.planificacion.gob.ec/wp-content/uploads/downloads/2017/10/PNBV-26-OCT-FINAL_0K.compressed1.pdf
- Slimani, I., El Farissi, I., & Achchab, S. (2016). Artificial neural networks for demand forecasting: Application using Moroccan supermarket data. *International Conference on Intelligent Systems Design and Applications, ISDA, 2016–June*, 266–271. <https://doi.org/10.1109/ISDA.2015.7489236>
- TensorFlow, & RStudio. (2018). Tensorflow. Retrieved from <https://tensorflow.rstudio.com/>
- Valeru, S., & Senabre, C. (2012). *Aplicación de un modelo de red neuronal no supervisado a la clasificación de consumidores eléctricos*.
- Venables, W., Smith, D., & R Core Team. (2018). An Introduction to R. Retrieved from <https://cran.r-project.org/doc/manuals/r-release/R-intro.pdf>
- Vidal, C. J. (2010). *Fundamentos de control y gestión de inventarios* (1st ed.). Colombia: Universidad del Valle.
- Yang, C. L., & Sutrisno, H. (2018). Short-Term Sales Forecast of Perishable Goods for Franchise Business. *2018 10th International Conference on Knowledge and Smart Technology: Cybernetics in the Next Decades, KST 2018*, 101–105. <https://doi.org/10.1109/KST.2018.8426091>

ANEXOS

Anexo A. Modelos de pronósticos

Tabla 18. Modelo de pronósticos

Modelos de pronósticos					
Modelos	Método	Descripción	Aplicaciones	Computadora	
				Costo	¿Necesaria?
Modelos causales de pronósticos	Análisis de regresión	Pronóstico explicativo; supone una relación de causa-efecto entre la información de entrada y la información resultante	Pronóstico de corto y mediano alcance de productos y servicios existentes; estrategias de marketing, producción, contratación de personal y planeación de instalaciones	de bajo a medio	Por lo general
	Regresión múltiple	Pronóstico explicativo: supone una relación de causa-efecto entre la información introducida en el sistema y la información que resulta de éste	Igual que en el caso anterior	de bajo a medio	sí
Modelos de pronóstico de series de tiempo	Método de descomposición	Pronóstico explicativo: supone una relación de causa-efecto entre el tiempo y la información resultante del sistema; el sistema se descompone en sus elementos	Pronóstico de medio alcance para una planta nueva y planeación del equipo, financiamiento, desarrollo del nuevo producto y nuevos métodos de ensamblaje; pronóstico de corto alcance para personal, publicidad, inventario, financiamiento y planeación de la producción	de bajo a medio	sí
	Promedios móviles	Se usan para eliminar la aleatoriedad en una serie de tiempo; el pronóstico se basa en los datos de la serie de tiempo suavizados por un promedio móvil	Pronóstico de corto alcance para operaciones como inventario, programación, control, fijación de precios y calendarización de promociones especiales; se emplea para calcular los componentes cíclico y estacional del método de descomposición de corto plazo	bajo	no
	Suavización exponencial	Similar a los promedios móviles, pero los valores son ponderados exponencialmente, otorgando mayor peso a los datos más recientes	Pronósticos de corto alcance para operaciones como inventario, programación, control, fijación de precios y calendarización de promociones especiales	bajo	si

	Modelos autorregresivos	Se emplean con variables económicas para explicar las relaciones entre observaciones adyacentes en una serie de tiempo	Pronósticos de corto y mediano plazos para datos económicos —incluyendo precio, — inventario, producción, acciones y ventas ordenados en una serie de tiempo	medio	sí
	Técnicas Box-Jenkins	No supone ningún patrón particular en los datos históricos de la serie que va a ser pronosticada; usa un método iterativo de identificación y ajuste de un modelo posiblemente útil tomado de un grupo general de modelos	Igual que en el caso anterior	alto	sí
	Redes neurales	Usa un programa complejo de computadora para asimilar datos relevantes y reconocer patrones mediante “aprendizaje” como lo hacen los humanos	Uso creciente de una gran variedad de aplicaciones de pronóstico; está en la fase de desarrollo	alto	sí

Fuente: (Montemayor,2013)

Elaborado por: Joselyn Chicaiza

Anexo B. Tabla de autocorrelaciones

Tabla 19. Tabla de autocorrelaciones

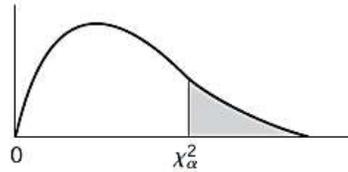
Retardo	Autocorrelació a	Tip. Error ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	.060	.160	.141	1	.707
2	.152	.158	1,070	2	.586
3	.244	.155	3,542	3	.315
4	.001	.153	3,542	4	.471
5	.267	.151	6,684	5	.245
6	.172	.148	8,029	6	.236
7	.023	.146	8,054	7	.328
8	.028	.143	8,092	8	.425
9	-.060	.140	8,277	9	.506
10	-.107	.138	8,878	10	.544
11	.034	.135	8,941	11	.627
12	.172	.132	10,628	12	.561
13	-.124	.130	11,536	13	.566
14	.092	.127	12,065	14	.601
15	-.261	.124	16,505	15	.349
16	.037	.121	16,598	16	.412
17	.191	.118	19,232	17	.315
18	-.099	.115	19,973	18	.334
19	.072	.111	20,385	19	.372
20	-.098	.108	21,210	20	.385
21	-.150	.105	23,257	21	.330
22	.019	.101	23,293	22	.385
23	-.154	.097	25,796	23	.311
24	-.059	.094	26,191	24	.344
25	-.046	.090	26,459	25	.383
26	-.191	.085	31,436	26	.212
27	-.214	.081	38,425	27	.071
28	-.033	.076	38,607	28	.087
29	-.128	.072	41,806	29	.058
30	-.104	.066	44,260	30	.045
31	-.045	.060	44,806	31	.052
32	-.136	.054	51,124	32	.017
33	-.041	.047	51,896	33	.019
34	.023	.038	52,243	34	.024

Elaborado por: Joselyn Chicaiza-SPSS

Anexo C. Tabla de Distribución Chi Cuadrado

Tabla 20. Valores críticos de la distribución Chi-cuadrado. °

TABLA B-4 Valores críticos de chi cuadrada



<i>df</i>	$X^2_{.995}$	$X^2_{.990}$	$X^2_{.975}$	$X^2_{.950}$	$X^2_{.900}$
1	0.0000393	0.0001571	0.0009821	0.0039321	0.0157908
2	0.0100251	0.0201007	0.0506356	0.102587	0.210720
3	0.0717212	0.114832	0.215795	0.351846	0.584375
4	0.206990	0.297110	0.484419	0.710721	1.063623
5	0.411740	0.554300	0.831211	1.145476	1.61031
6	0.675727	0.872085	1.237347	1.63539	2.20413
7	0.989265	1.239043	1.68987	2.16735	2.83311
8	1.344419	1.646482	2.17973	2.73264	3.48954
9	1.734926	2.087912	2.70039	3.32511	4.168216
10	2.15585	2.55821	3.24697	3.94030	4.86518
11	2.60321	3.05347	3.81575	4.57481	5.57779
12	3.07382	3.57056	4.40379	5.22603	6.30380
13	3.56503	4.10691	5.00874	5.89186	7.04150
14	4.07468	4.66043	5.62872	6.57063	7.78953
15	4.60094	5.22935	6.26214	7.26094	8.54675
16	5.14224	5.81221	6.90766	7.96164	9.31223
17	5.69724	6.40776	7.56418	8.67176	10.0852
18	6.26481	7.01491	8.23075	9.39046	10.8649
19	6.84398	7.63273	8.90655	10.1170	11.6509
20	7.43386	8.26040	9.59083	10.8508	12.4426
21	8.03366	8.89720	10.28293	11.5913	13.2396
22	8.64272	9.54249	10.9823	12.3380	14.0415
23	9.26042	10.19567	11.6885	13.0905	14.8479
24	9.88623	10.8564	12.4011	13.8484	15.6587
25	10.5197	11.5240	13.1197	14.6114	16.4734
26	11.1603	12.1981	13.8439	15.3791	17.2919
27	11.8076	12.8786	14.5733	16.1513	18.1138
28	12.4613	13.5648	15.3079	16.9279	18.9302
29	13.1211	14.2565	16.0471	17.7083	19.7677
30	13.7867	14.9535	16.7908	18.4926	20.5992
40	20.7065	22.1643	24.4331	26.5093	29.0505
50	27.9907	29.7067	32.3574	34.7642	37.6886
60	35.5347	37.4848	40.4817	43.1879	46.4589
70	43.2752	45.4418	48.7576	51.7393	55.3290
80	51.1720	53.5400	57.1532	60.3915	64.2778
90	59.1963	61.7541	65.6466	69.1260	73.2912
100	67.3276	70.0648	74.2219	77.9295	82.3581

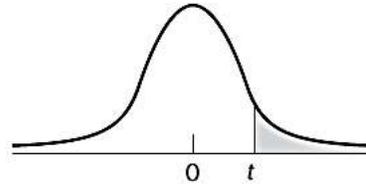
TABLA B-4 (Continuación)

<i>df</i>	$\chi^2_{.100}$	$\chi^2_{.050}$	$\chi^2_{.025}$	$\chi^2_{.010}$	$\chi^2_{.005}$
1	2.70554	3.84146	5.02389	6.63490	7.87944
2	4.60517	5.99147	7.37776	9.21034	10.5966
3	6.25139	7.81473	9.34840	11.3449	12.8381
4	7.77944	9.48773	11.1433	13.2767	14.8602
5	9.23635	11.0705	12.8325	15.0863	16.7496
6	10.6446	12.5916	14.4494	16.8119	18.5476
7	12.0170	14.0671	16.0128	18.4753	20.2777
8	13.3616	15.5073	17.5346	20.0902	21.9550
9	14.6837	16.9190	19.0228	21.6660	23.5893
10	15.9871	18.3070	20.4831	23.2093	25.1882
11	17.2750	19.6751	21.9200	24.7250	26.7569
12	18.5494	21.0261	23.3367	26.2170	28.2995
13	19.8119	22.3621	24.7356	27.6883	29.8194
14	21.0642	23.6848	26.1190	29.1413	31.3193
15	22.3072	24.9958	27.4884	30.5779	32.8013
16	23.5418	26.2962	28.8454	31.9999	34.2672
17	24.7690	27.5871	30.1910	33.4087	35.7185
18	25.9894	28.8693	31.5264	34.8053	37.1564
19	27.2036	30.1435	32.8523	36.1908	38.5822
20	28.4120	31.4104	34.1696	37.5662	39.9968
21	29.6151	32.6705	35.4789	38.9321	41.4010
22	30.8133	33.9244	36.7807	40.2894	42.7956
23	32.0069	35.1725	38.0757	41.6384	44.1813
24	33.1963	36.4151	39.3641	42.9798	45.5585
25	34.3816	37.6525	40.6465	44.3141	46.9278
26	35.5631	38.8852	41.9232	45.6417	48.2899
27	36.7412	40.1133	43.1944	46.9630	49.6449
28	37.9159	41.3372	44.4607	48.2782	50.9933
29	39.0875	42.5569	45.7222	49.5879	52.3356
30	40.2560	43.7729	46.9792	50.8922	53.6720
40	51.8050	55.7585	59.3417	63.6907	66.7659
50	63.1671	67.5048	71.4202	76.1539	79.4900
60	74.3970	79.0819	83.2976	88.3794	91.9517
70	85.5271	90.5312	95.0231	100.425	104.215
80	96.5782	101.879	106.629	112.329	116.321
90	107.565	113.145	118.136	124.116	128.299
100	118.498	124.342	129.561	135.807	140.169

Fuente: Hanke (2010)

Anexo D. Tabla de Distribución de t de Student

Tabla 21. Valores críticos de la distribución t de Student



<i>df</i>	$t_{.100}$	$t_{.050}$	$t_{.025}$	$t_{.010}$	$t_{.005}$
1	3.078	6.314	12.706	31.821	63.657
2	1.886	2.920	4.303	6.965	9.925
3	1.638	2.353	3.182	4.541	5.841
4	1.533	2.132	2.776	3.747	4.604
5	1.476	2.015	2.571	3.365	4.032
6	1.440	1.943	2.447	3.143	3.707
7	1.415	1.895	2.365	2.998	3.499
8	1.397	1.860	2.306	2.896	3.355
9	1.383	1.833	2.262	2.821	3.250
10	1.372	1.812	2.228	2.764	3.169
11	1.363	1.796	2.201	2.718	3.106
12	1.356	1.782	2.179	2.681	3.055
13	1.350	1.771	2.160	2.650	3.012
14	1.345	1.761	2.145	2.624	2.977
15	1.341	1.753	2.131	2.602	2.947
16	1.337	1.746	2.120	2.583	2.921
17	1.333	1.740	2.110	2.567	2.898
18	1.330	1.734	2.101	2.552	2.878
19	1.328	1.729	2.093	2.529	2.861
20	1.325	1.725	2.086	2.528	2.845
21	1.323	1.721	2.080	2.518	2.831
22	1.321	1.717	2.074	2.508	2.819
23	1.319	1.714	2.069	2.500	2.807
24	1.318	1.711	2.064	2.492	2.797
25	1.316	1.708	2.060	2.485	2.787
26	1.315	1.706	2.056	2.479	2.779
27	1.314	1.703	2.052	2.473	2.771
28	1.313	1.701	2.048	2.467	2.763
29	1.311	1.699	2.045	2.462	2.756
inf.	1.282	1.645	1.960	2.326	2.576

Fuente: Hanke (2010)

Anexo E. Autocorrelaciones

Tabla 22. Valores de autocorrelaciones con la primera diferenciación

Serie: Pedidos mensual

Retardo	Autocorrelación	Típ. Error ^a	Estadístico de Box-Ljung		
			Valor	gl	Sig. ^b
1	-.538	,182	10,958	1	,001
2	,000	,180	10,958	2	,004
3	,137	,157	11,721	3	,008
4	-.274	,155	14,883	4	,005
5	,201	,152	18,801	5	,005
6	,026	,150	18,832	6	,011
7	-.027	,147	18,865	7	,020
8	,030	,144	18,707	8	,033
9	-.048	,142	18,813	9	,052
10	-.112	,139	17,483	10	,065
11	,051	,138	17,805	11	,091
12	,201	,133	19,883	12	,069
13	-.232	,130	23,043	13	,041
14	,292	,127	28,299	14	,013
15	-.346	,124	38,088	15	,002
16	,058	,121	38,298	16	,003
17	,177	,118	38,543	17	,002
18	-.153	,115	40,334	18	,002
19	,187	,111	42,803	19	,001
20	-.117	,108	43,778	20	,002
21	-.075	,104	44,294	21	,002
22	,122	,100	45,789	22	,002
23	-.080	,096	48,457	23	,003
24	,018	,092	48,487	24	,004
25	,117	,088	48,281	25	,003
26	-.070	,083	48,983	26	,004
27	-.117	,079	51,187	27	,003
28	,105	,074	53,224	28	,003
29	-.029	,078	53,409	29	,004
30	,004	,082	53,413	30	,005
31	,078	,058	55,389	31	,005
32	-.082	,048	58,297	32	,003
33	-.008	,039	58,323	33	,004

Fuente: Joselyn Chicaiza- SPSS

Anexo F. Código de Análisis de Datos

```
library(ggfortify)
library(tseries)
library(forecast)
library(ggplot2)
###Análisis de datos

##Construcción de la serie temporal

##Cargando los Datos
setwd("~/Doc_R")
Botellones<-read.csv("C:/Users/Joselyn/Documents/Doc_R/Pedidos11.csv",header=T,sep=",")
Botellones

##vamos a convertir la base de datos de botellones en serie temporal(ts)
Botellonests=ts(Botellones$Pedidos,freq=12,start=c(2016,1))
Botellonests
y <- Botellonests

##Graficando la serie temporal
grap1<-plot(y, ylab="Botellones(unidades)", type="o", pch =20,xlab="Años" )
grap1
grap2<-(autoplot(y) + labs(x="Date", y = "Botellones (unidades)",
                        title="Botellones desde el 2016 al 2018 "))
grap2

###Valorizaciones iniciales

## Verificar valores faltantes
sum(is.na(y))

##Verificar la frecuencia
frequency(y)
#Verificar los ciclos

##Analizando el ciclo
cycle(y)

##Resumen
summary(y)

###Análisis de estacionalidad
DiagC<-boxplot(y~cycle(y),xlab="Años", ylab = "Botellones(unidades)" ,
              main ="Pedidos de botellones mensuales desde el 2016 hasta el 2018")
DiagC
###Descomposición de la serie de tiempo
###tendencia, estacionalidad y aleatoriedad

AP.decompM <- decompose(y, type = "multiplicative")
plot(AP.decompM)

###Probar si la serie de tiempo es estacionaria
adf.test(y)
```

Elaborado por: Joselyn Chicaiza- Rproject

Anexo G. Tabla de toma de decisiones

Tabla 23. Requisitos para selección del método de pronóstico

Método	Patrón de series de tiempo	Horizonte de tiempo	Tipo de modelo	Requisitos mínimos de datos	
				No estacionales	Estacionales
Informal	ST,T,S	S	TS	1	
Promedios simples	ST	S	TS	30	
Promedios móviles	ST	S	TS	de 4 a 20	
Suavizamiento exponencial	ST	S	TS	2	
Suavizamiento exponencial lineal	T	S	TS	3	
Suavizamiento exponencial cuadrático	T	S	TS	4	
Suavizamiento exponencial estacional	S	S	TS		2xs
Filtración adaptiva	S	S	TS		5xs
Regresión simple	T	I	C	10	
Regresión múltiple	C,S	I	C	10x V	
Descomposición elástica	S	S	TS		5xs
Modelos de tendencia exponencial	T	I,L	TS	10	
Ajuste la curva s	T	I,L	TS	10	
Modelos de Gompertz	T	I,L	TS	10	
Curvas de crecimiento	T	I,L	TS	10	
Censo X-12	S	S	TS		6xs
Box-Jenkins	ST,T,C,S	S	TS	24	3xs
Indicadores principales	C	S	C	24	
Modelos econométricos	C	S	C	30	
Regresión múltiple con series de tiempo	T,S	I,L	C		6xs
Patrones de datos: estacionarios (ST), tendencia (T), estacional (S), cíclico (C) Horizonte de tiempo: Costo plazo-menos de 3 meses (S),intermedio (I),Largo plazo (L) Tipo de modelo: serie de tiempo (TS), causal (C) Estacionalidad: longitud de estacionalidad (s) Variable: número de variables (v)					

Fuente: Hanke (2010)

Anexo H. Métodos de pronóstico en el software POM

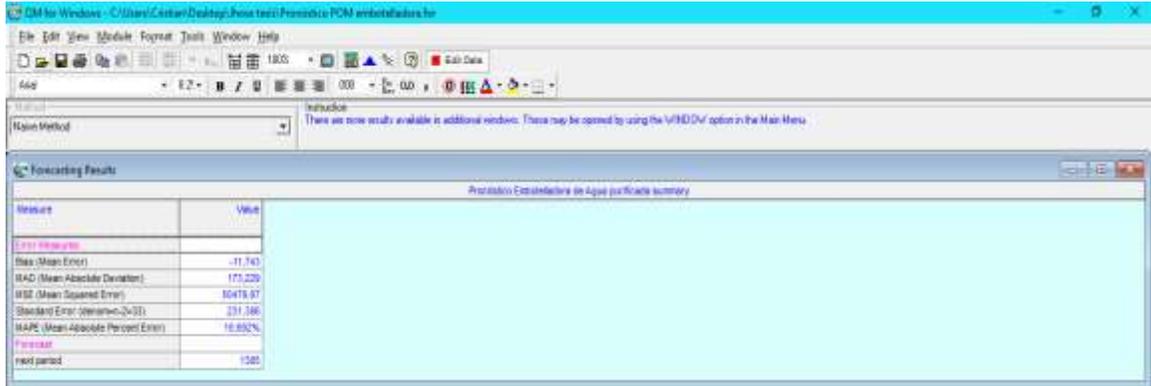


Figura 41. Pronóstico de la embotelladora en POM usando el método ingenuo



Figura 42. Pronóstico de la embotelladora en POM usando el método suavización.



Figura 43. Pronóstico de la embotelladora en POM usando el método suavización exponencial con tendencia exponencial.

Anexo I. Reporte de resultados de pronósticos con SPSS V.22

```
PREDICT THRU YEAR 2019 MONTH 12.
* Modelizador de series temporales.
TSMODEL
  /MODELSUMMARY PRINT=[MODELFIT]
  /MODELSTATISTICS DISPLAY=YES MODELFIT=[ SRSQUARE RMSE]
  /SERIESPLOT OBSERVED FORECAST FORECASTCI FITCI
  /OUTPUTFILTER DISPLAY=ALLMODELS
  /SAVE PREDICTED(Pronosticado) LCL(LCI) UCL(LCS) NRESIDUAL(ResiduoN)
  /AUXILIARY CILEVEL=95 MAXACFLAGS=24
  /MISSING USERMISSING=EXCLUDE
  /MODEL DEPENDENT=Pedidos INDEPENDENT=MONTH_
    PREFIX='Modelo'
  /EXPERTMODELER TYPE=[ARIMA EXSMOOTH] TRYSEASONAL=YES
  /AUTOOUTLIER DETECT=OFF.
```

Modelizador de series temporales

Descripción del modelo

			Tipo de modelo
ID de modelo	Pedidos	Modelo_1	Aditivo de Winters

Resumen del modelo

Ajuste del modelo

Estadístico de ajuste	Media	SE	Mínimo	Máximo	Percentil	
					5	10
R cuadrado estacionaria	,855	.	,855	,855	,855	,855
R cuadrado	,620	.	,620	,620	,620	,620
RMSE	106,800	.	106,800	106,800	106,800	106,800
MAPE	5,470	.	5,470	5,470	5,470	5,470
MaxAPE	14,941	.	14,941	14,941	14,941	14,941
MAE	88,260	.	88,260	88,260	88,260	88,260
MaxAE	206,329	.	206,329	206,329	206,329	206,329
BIC normalizado	9,641	.	9,641	9,641	9,641	9,641

Figura 44. Resultado de pronósticos con SPSS primera parte

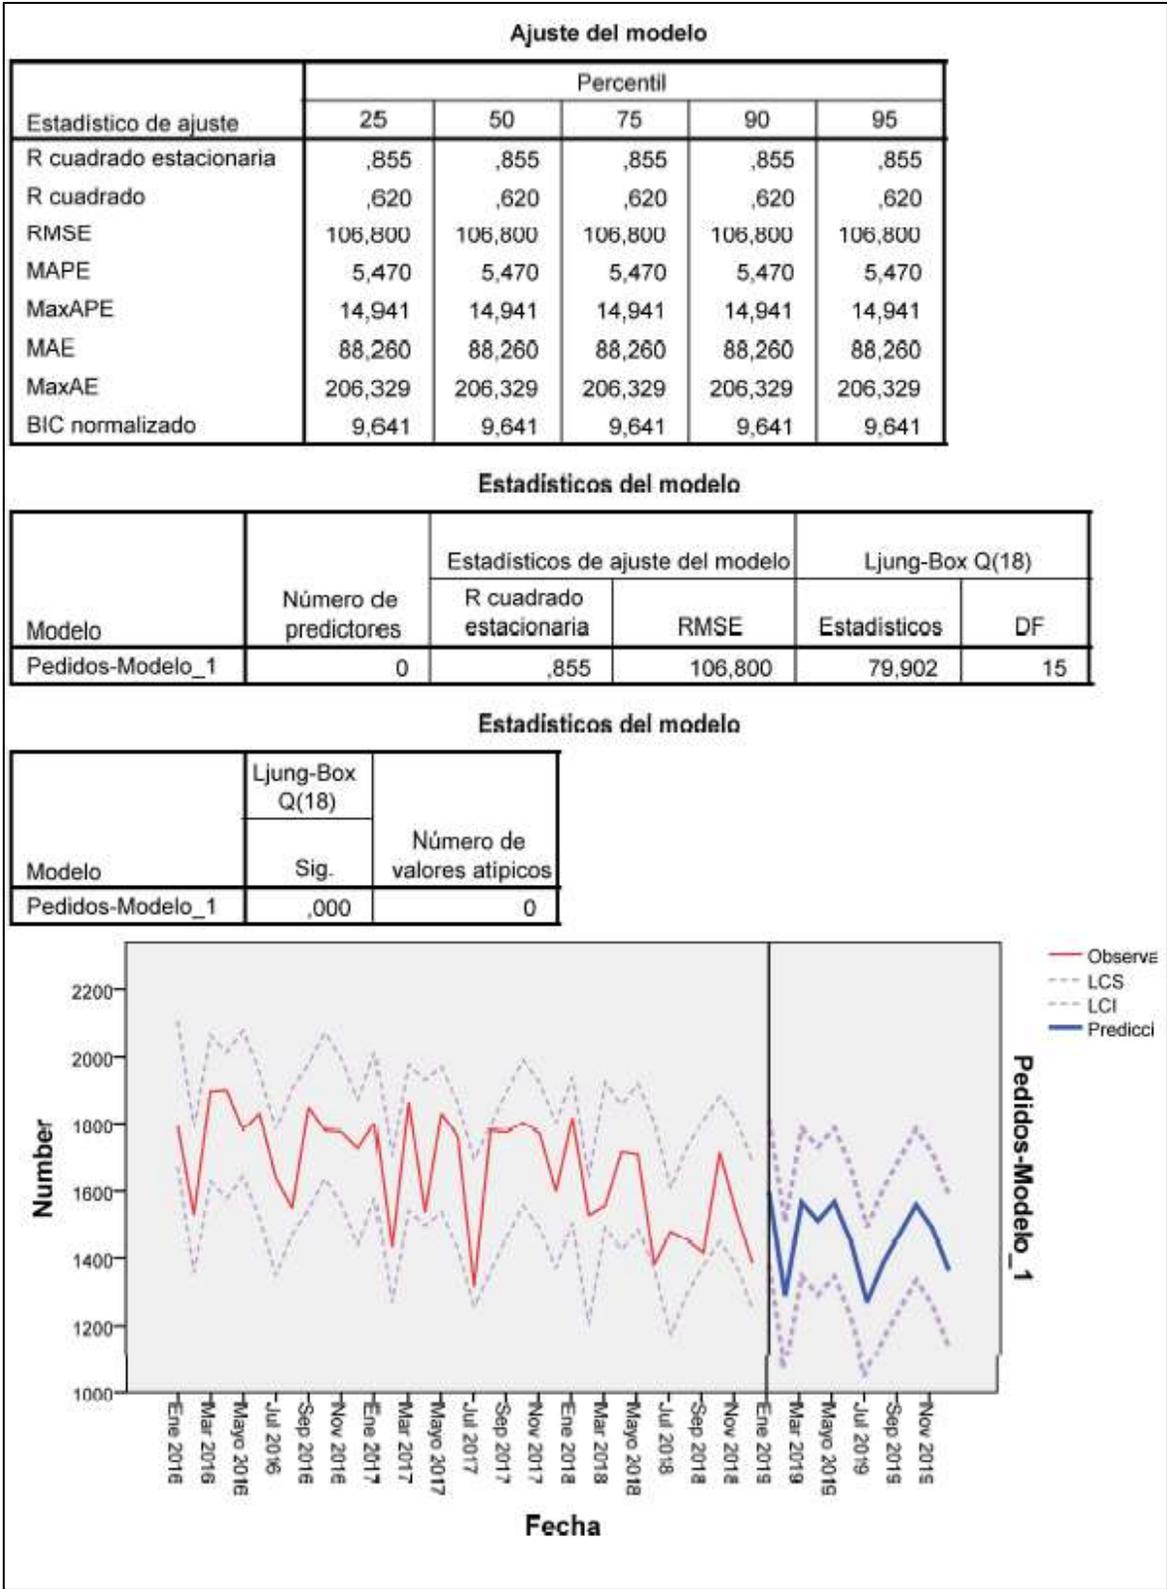
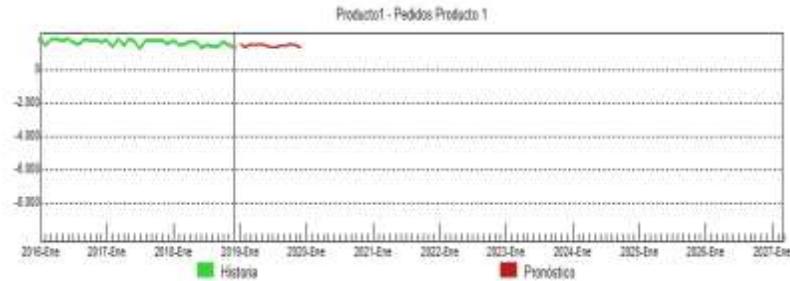


Figura 45. Figura 46. Resultado de pronósticos con SPSS segunda parte

Anexo J. Reporte de Forecast Pro V.05

Tabla 24. Reporte de Resultados de pronósticos para el año 2019 de Forecast Pro V.05



Reporte de pronósticos para Producto1

Pedidos Producto 1

Producto1

Análisis Experto

Utilizando una lógica basada en reglas de FPRO he limitado la selección entre Suavización exponencial y Box-Jenkins.

Realicé una prueba a una muestra para seleccionar entre estas dos familias de modelos.

El MAD acumulado en la muestra para Suavización exponencial fue 141 y para Box-Jenkins fue 207.

La prueba rolada sobre la muestra usó un horizonte máximo de 6 y generó para cada método 21 pronósticos.

Basado en el MAD acumulado más bajo, utilicé suavización exponencial.

Detalles del modelo

Selección Experta

Winters multiplicativo: tendencia lineal, estacionalidad multiplicativa

LM(0,045; 0,060; 0,282)

Límites de confianza proporcionales a índices

Componente	Peso parámetro de suavización		Valor final
Nivel	0.0451		1523
Tendencia	0.05956		-7.997
Estacional	0.282		
Índices estacionales			
Ene - Mar	1.057	0.902	1.035
Abr - Jun	1.019	1.054	0.9848
Jul - Sep	0.9076	0.971	1.01
Oct - Dic	1.074	1.034	0.9692

Estadísticas de la muestra

Tamaño muestra	36	No. parámetros	3
Media	1666.72	Desv. estándar	168.26
R-Cuadrada Aj.	0.45	Durbin-Watson	2.5

Ljung-Box(18)	60,3 P=1,00	Error de pronóstico	125.34
BIC	139.32	MAPE	0.064
RMSE	120	MAD	102.6

Datos de pronósticos

Fecha	2,5 Inf.	Pronóstico	Trimestral	Anual	97,5 Sup.
2019-Ene	1309	1601			1894
2019-Feb	1109	1359			1609
2019-Mar	1265	1552	4512		1839
2019-Abr	1236	1519			1802
2019-May	1270	1563			1855
2019-Jun	1179	1453	4535		1727
2019-Jul	1078	1332			1585
2019-Ago	1146	1417			1688
2019-Sep	1184	1466	4215		1748
2019-Oct	1250	1550			1850
2019-Nov	1195	1484			1773
2019-Dic	1111	1383	4418	17679	1655
Total		17679			
Promedio		1473			
Mínimo		1332			
Máximo		1601			

Existencias de Seguridad

T. Anticipación	DDTA	97,5 E.S.	Valor a Re-ordenar
1	1601	292	1894
2	2961	395	3356
3	4512	494	5006
4	6031	576	6607
5	7594	652	8246
6	9047	712	9759
7	10378	760	11138
8	11795	810	12605
9	13261	861	14122
10	14812	915	15726
11	16296	963	17259
12	17679	1004	18683

DDTA = Demanda Durante Tiempo Anticipación (pronósticos acumulados)

E. de Seg = Límites de confianza acumulados para el T. Anticipación

Valor a Re-ordenar = DDTA + E. de Seg

Ajustes

No existen ajustes para este ítem

Anexo K. Fase 2 de programación

The screenshot displays the RStudio environment. The main editor window contains R code for training and plotting neural networks. The code is organized into sections for different models (Fit01_2, Fit01_3, Fit01_4) and includes commands for fitting, printing, forecasting, and plotting. A comment at the top of the code reads "REDES NEURONALES FASE 2".

```
28 GR01<-plot(Fit01)
29 GR01
30 GP01<-plot(P01)
31 GP01
32
33 #####REDES NEURONALES FASE 2#####
34 ### P02_2
35 Fit01_2 <- mlp(y, hd = c(1))
36 IF01_2 <-print(Fit01_2 )
37 P01_2 <-forecast(Fit01_2 )
38 P01_2
39 GR01_2 <-plot(Fit01_2 )
40 GR01_2
41 GP01_2 <-plot(P01_2 )
42 GP01_2
43 ### P02_2
44 Fit01_3 <- mlp(y, hd = c(2))
45 IF01_3 <-print(Fit01_3 )
46 P01_3 <-forecast(Fit01_3 )
47 P01_3
48 GR01_3 <-plot(Fit01_3 )
49 GR01_3
50 GP01_3 <-plot(P01_3 )
51 GP01_3
52 ### P02_2
53 Fit01_4 <- mlp(y, hd = c(1))
54 IF01_4 <-print(Fit01_4 )
55 P01_4 <-forecast(Fit01_4 )
56 P01_4
57 GR01_4 <-plot(Fit01_4 )
58 GR01_4
59 GP01_4 <-plot(P01_4 )
60 GP01_4
61 ### P02_2
62 Fit0 <- mlp(y, hd = c(20,8,4),reps=60)
63 print(Fit0 )
64 plot(Fit0)
65 plot(Forecast(Fit0))
66
```

The Environment pane on the right shows the following objects:

Object	Type
Fit01_2	List of 15
Fit1	Large mlp (15 elements, 694.1 kb)
Fit2	Large mlp (15 elements, 694.1 kb)
P01_2	List of 6
p2	List of 6
BoteItonests	Time-Series [1:36, 1] from 2016 to 2019: 1796 1526 1897 190.
GP01_2	NULL (empty)

The diagram in the bottom right corner, titled "MLP", illustrates a neural network architecture with three layers: "Inputs (7)", "Hidden (1)", and "Output". Arrows indicate the flow of information from the input layer to the hidden layer, and then to the output layer.

Figura 47. Interfaz de fase 2 de programación.

Anexo L. Resultado de Fase 2

Tabla 25. Resultados de pruebas con multicapas.

<i>Hidden layer 1</i>			<i>Hidden layer 3</i>			<i>Hidden layer 3</i>		
Cod_ Training	No. of neurons	MSE	Cod_ Trainin	No. of neurons	MSE	Cod_ Training	No. of neurons	MSE
Fit01_1	1	7473,1526	Fit02_1	1	27,7026	Fit03_1	1	26,4072
Fit01_2	2	358,9923	Fit02_2	2	1,925	Fit03_2	2	1,9768
Fit01_3	3	7,1273	Fit02_3	3	0,4471	Fit03_3	3	0,2493
Fit01_4	4	6,6356	Fit02_4	4	1,2394	Fit03_4	4	1,5051
Fit01_5	5	10,9866	Fit02_5	5	0,8438	Fit03_5	5	1,1218
Fit01_6	6	6,2128	Fit02_6	6	1,003	Fit03_6	6	0,857
Fit01_7	7	11,4028	Fit02_7	7	1,0711	Fit03_7	7	1,2636
Fit01_8	8	6,0657	Fit02_8	8	2,2526	Fit03_8	8	0,8863
Fit01_9	9	6,1877	Fit02_9	9	1,2272	Fit03_9	9	0,5974
Fit01_10	10	6,9134	Fit02_10	10	1,6062	Fit03_10	10	0,8436
Fit01_11	11	6,4843	Fit02_11	11	1,2014	Fit03_11	11	0,7247
Fit01_12	12	8,1482	Fit02_12	12	1,977	Fit03_12	12	0,1308
Fit01_13	13	3,7179	Fit02_13	13	1,5808	Fit03_13	13	0,6739
Fit01_14	14	6,9588	Fit02_14	14	1,6385	Fit03_14	14	1,0501
Fit01_15	15	6,5303	Fit02_15	15	1,4847	Fit03_15	15	0,9084
Fit01_16	16	4,7449	Fit02_16	16	1,7129	Fit03_16	16	0,8644
Fit01_17	17	9,4189	Fit02_17	17	1,259	Fit03_17	17	0,919
Fit01_18	18	6,3269	Fit02_18	18	1,1878	Fit03_18	18	0,9717
Fit01_19	19	5,4223	Fit02_19	19	0,8654	Fit03_19	19	1,9782
Fit01_20	20	6,2488	Fit02_20	20	1,1673	Fit03_20	20	0,5384
Fit01_21	21	6,1694	Fit02_21	21	1,1019	Fit03_21	21	0,727
Fit01_22	22	2,7186	Fit02_22	22	1,1713	Fit03_22	22	0,5656
Fit01_23	23	4,9955	Fit02_23	23	1,3699	Fit03_23	23	0,6858
Fit01_24	24	5,8453	Fit02_24	24	1,1355	Fit03_24	24	0,4766
Fit01_25	25	5,478	Fit02_25	25	0,8681	Fit03_25	25	0,9476
Fit01_26	26	6,3718	Fit02_26	26	0,6289	Fit03_26	26	1,4615
Fit01_27	27	5,3842	Fit02_27	27	0,9987	Fit03_27	27	0,786
Fit01_28	28	6,8759	Fit02_28	28	0,9353	Fit03_28	28	0,6704
Fit01_29	29	5,5447	Fit02_29	29	1,0452	Fit03_29	29	1,0116
Fit01_30	30	4,5565	Fit02_30	30	0,6056	Fit03_30	30	0,6855
Fit01_31	31	3,8494	Fit02_31	31	1,1907	Fit03_31	31	0,9266
Fit01_32	32	2,5282	Fit02_32	32	1,3318	Fit03_32	32	0,8135

Anexo M. Código de programación última fase

```
library(nnfor)

library(ggplot2)
###cargando la base de datos
setwd("~/Doc_R")
Botellones<-read.csv("C:/Users/Joselyn/Documents/Doc_R/Pedidos11.csv",header=T,sep=",")
##Análisis de datos
##Diagra de autocorrelacion
#vamos a convertir la base de datos de botellones en serie temporal(ts)
Botellonests=ts(Botellones,freq=12,start=c(2016,1))
Botellonests
plot(Botellonests)
#calculando la estacionalidad
#library(TSstudio)
#ts_seasonal(Botellonests,type="all")

#El objetivo es pronosticar la serie de Botellones
y <- Botellonests
y
#las variables de entrada son 12 años desde 2015 hasta 2018 en forma mensual
h <- 1*frequency(y)
frequency(y)
#####RED NEURONAL ÓPTIMA
# 1
fit1 <- mlp(y, reps=200, hd = c(22,28,12), sel.lag=FALSE, lags = 1:12, difforder = c(3,10))
#difforder= c(3,10) significa, el 3 permite quitar la tendencia del año 2016, ya que
#en el primer año del 2016 no existe una tendencia marcada y el 12
#para una frecuencia mensual
#sel.lag=false significa que anula la selección automática de los retrasos, entonces
#los retrasos serán de forma manual del 1 hasta el 12:lags= 1:12, son los regresores
#del modelo autoregresivo (AR)
#hd= c(20,8,4), significa configurar 3 capas ocultas con sus respectivos números de nodos
#reps=número de redes a entrenar; si aumenta el número de reps mejora el mse
#si reps= 4 ,mse=0,5, si reps=40,mse=0,1, reps= 100=0,07, reps=200,mse=0,05
print(fit1)
p2<-forecast(fit1)
plot(p2)
plot(fit1)
##Mejora de entrenamiento
##
fit2<-mlp(y, model=fit1, retrain=20)
print(fit2)
plot(fit2)
plot(forecast(fit2,h=h))
forecast(fit2,h=h)
##
```

```
fit3<-mlp(y, model=fit2, retrain=TRUE)
print(fit3)
##
fit4<-mlp(y, model=fit3, retrain=TRUE)
print(fit4)
##
fit5<-mlp(y, model=fit4, retrain=TRUE)
print(fit5)
py<-forecast(fit5)
plot(py)
plot(fit5)
#
fit6<-mlp(y, model=fit5, retrain=TRUE)
print(fit6)
py<-forecast(fit6)
plot(py)
plot(fit6)
#
fit7<-mlp(y, model=fit6, retrain=TRUE)
print(fit7)
py<-forecast(fit7)
plot(py)

plot(fit7)
#
fit8<-mlp(y, model=fit7, retrain=TRUE)
print(fit8)
py<-forecast(fit8)
plot(py)
plot(fit8)
```