



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:
MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE LA
EMPRESA DIPAC MANTA S.A. (Sede Ibarra) APLICANDO REDES
NEURONALES ARTIFICIALES**

AUTOR: DELIO RICARDO PATIÑO ALARCÓN

DIRECTOR: ING. LEANDRO LEONARDO LORENTE LEYVA MSC.

IBARRA – ECUADOR

2019



UNIVERSIDAD TÉCNICA DEL NORTE

BIBLIOTECA UNIVERSITARIA

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

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 DE IDENTIDAD:	DE	100253851-8	
APELLIDOS Y NOMBRES:	Y	PATIÑO ALARCÓN DELIO RICARDO	
DIRECCIÓN:	SALINAS 5-82 Y OVIEDO		
EMAIL:	drpatinoa@utn.edu.ec		
TELÉFONO FIJO:	2 955 737	TELÉFONO MÓVIL:	09393193089
DATOS DE LA OBRA			
TÍTULO:	MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE LA EMPRESA DIPAC MANTA S.A. (Sede Ibarra) APLICANDO REDES NEURONALES ARTIFICIALES		
AUTOR (ES):	PATIÑO ALARCÓN DELIO RICARDO		
FECHA: AAAAMMDD	2019/03/12		
SÓLO PARA TRABAJOS DE GRADO			
PROGRAMA:	<input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO		
TITULO POR EL QUE OPTA:	INGENIERO INDUSTRIAL		
ASESOR /DIRECTOR:	ING. LEANDRO LORENTE MSC.		

CARRERA DE INGENIERÍA INDUSTRIAL.

CONSTANCIAS

El autor (es) manifiesta (n) 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 (son) el (los) titular (es) de los derechos patrimoniales, por lo que asume (n) la responsabilidad sobre el contenido de la misma y saldrá (n) en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 13 días del mes de marzo de 2019

EL AUTOR:

(Firma).....

Nombre: Delio Ricardo Patiño Alarcón



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

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

Yo, Delio Ricardo Patiño Alarcón, con cédula de identidad Nro. 100253851-8, 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 (es) de la obra o trabajo de grado denominado: MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE LA EMPRESA DIPAC MANTA S.A. (Sede Ibarra) APLICANDO REDES NEURONALES ARTIFICIALES, 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.

Ibarra, a los 13 días del mes de marzo de 2019

(Firma).....
Nombre: Delio Ricardo Patiño Alarcón
Cédula: 100253851-8



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

CERTIFICACIÓN

Ing. Leandro Lorente MSc., director de la Tesis de Grado desarrollada por el señor estudiante Delio Ricardo Patiño Alarcón.

CERTIFICA

Que, el Proyecto de Tesis de grado titulado “MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE LA EMPRESA DIPAC MANTA S.A. (Sede Ibarra) APLICANDO REDES NEURONALES ARTIFICIALES”, ha sido realizado en su totalidad por el señor estudiante Delio Ricardo Patiño Alarcón 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. Leandro Lorente MSc

DIRECTOR DE TESIS



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

DEDICATORIA

Esta meta profesional se la dedico a las personas más importantes de mi vida.

A Dios, por guiarme e iluminar mis días.

A mi madre, Genoveva Alarcón, por ser única en el planeta tierra, por brindarme sus cuidados y amor que sólo una madre puede dar, te amo con mi vida, gracias por demostrarme lo importante que soy en tu vida a DIARIO. "Eres mi ángel azul, vuela alto y vive tus sueños."

A mi padre, Delio Patiño, por ser mi guía y motivación permanente, por corregir mis errores y celebrar nuestros logros, me has formado como un hombre de bien, estaré eternamente agradecido. "Siempre te llevaré en mi alma porque el alma es eterna."

A mi hermano, Fernando Patiño, por sus enseñanzas y por demostrarme su cariño eterno, gracias por reconocer mis virtudes y corregir mis errores. "enano bello."

A mi enamorada, Sheyla Flores, por demostrarme a diario su apoyo incondicional sin importar las condiciones que existan, gracias por complementarme tan mágicamente y por juntos formar tan maravilloso equipo. "el amor es como el mar."

DELIO RICARDO PATIÑO ALARCÓN



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

AGRADECIMIENTO

A la Universidad Técnica del Norte, a la Facultad de Ingenierías en Ciencias Aplicadas y a la Carrera de Ingeniería Industrial, por permitirme alcanzar esta meta profesional.

Al Dr. Miguel Naranjo Toro, por ser mi guía y apoyo académico a lo largo de mi trayectoria universitaria, además de enseñarme el significado de liderazgo y lealtad.

Al Ing. Leandro Lorente, quien en calidad de tutor es mi guía profesional, además de ser un ser humano lleno de principios y valores que me ayudaron a formarme como un ser humano íntegro. "estamos al tanto gran amigo."

A mis profesores Ing. Yakcleem Montero e Ing. Israel Herrera, por su constante apoyo tanto en este trabajo de titulación como en proyectos de investigación, aconsejándome y guiándome para superarme cada día.

A mis tíos Ernesto Alarcón, María Helena Alarcón y Pedro Alarcón, por su preocupación y apoyo durante mi carrera profesional, además de permanecer pendientes de mi progreso profesional.

DELIO RICARDO PATIÑO ALARCÓN

ÍNDICE

IDENTIFICACIÓN DE LA OBRA.....	ii
AUTORIZACIÓN DE USO A FAVOR DE LA UNIVERSIDAD. ¡Error! Marcador no definido.	
CONSTANCIAS.....	iii
CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE GRADO A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE.....	iv
CERTIFICACIÓN	v
DEDICATORIA	vi
AGRADECIMIENTO	vii
ÍNDICE.....	viii
ÍNDICE TABLAS	xi
ÍNDICE FIGURAS.....	xii
RESUMEN	xiv
ABSTRACT.....	xv
CAPÍTULO I. GENERALIDADES	1
1.1. Introducción	1
1.1.1 Preparación de la planificación para el abastecimiento y distribución.....	3
1.1.2. Programación estocástica:	7
1.1.3. Teoría de conjuntos difusos (<i>Fuzzy Sets</i>):	8
1.1.4. Programación dinámica:	9
1.1.5. Redes Neuronales Artificiales en el pronóstico de la demanda:	9
1.2. Problema.....	11
1.3. Objetivos	13
1.3.1 Objetivo General.....	13
1.3.2. Objetivos Específicos	13
1.4. Alcance.....	13
CAPÍTULO II. ESTADO DEL ARTE DEL PRONÓSTICO DE LA DEMANDA MEDIANTE REDES NEURONALES ARTIFICIALES	14
2.1. Pronóstico (<i>Forecasting</i>).....	14
2.1.1. Planeación y control de la producción.....	14
2.1.2. Pronóstico Tradicional Estadístico Clásico	15
2.1.3. Tipos de Pronóstico	17

2.2. Importancia e impacto de la inteligencia artificial para el pronóstico no tradicional de la demanda.....	19
2.3. Metodologías y técnicas para pronosticar mediante inteligencia artificial (Redes Neuronales Artificiales)	21
2.3.1 Metodología mediante selección de parámetros.....	21
2.3.2 Metodología mediante obtención de datos.	22
2.4. Relevancia de las Redes Neuronales Artificiales.....	23
2.4.1. Fundamentos biológicos de las redes neuronales.	23
2.4.2. Redes Neuronales Artificiales.	25
2.5. Redes Neuronales Artificiales vs. Estadística Clásica Tradicional.....	27
2.5.1. Configuración y aplicación de las Redes Neuronales Artificiales	29
2.6. Nivel de precisión al pronosticar con Redes Neuronales Artificiales.	29
2.7. Soluciones de Ingeniería mediante <i>MATLAB</i> ®.....	30
2.7.1. Metodología para resolución de problemas de ingeniería	30
2.7.2. <i>MATLAB</i> ® y su interfaz	30
2.7.3. Toolbox <i>MATLAB</i> ®	31
2.7.4. Redes Neuronales en <i>MATLAB</i> ®	33
CAPÍTULO III. DIAGNÓSTICO SITUACIONAL DE LA EMPRESA	40
3.1. Descripción empresarial.....	40
3.1.1. Red comercial.....	44
3.1.2. Base legal empresarial	45
3.1.3. Estatus Social.....	46
3.1.4. Ranking Empresarial	46
3.1.5. Composición Accionaria	47
3.2 Situación y entorno empresarial.....	49
3.2.1. Volumen de Operaciones.....	49
3.2.2. Impacto en el entorno	50
3.2.3. Principales competidores de la industria del acero.....	51
3.3 Gama de productos para la comercialización.....	51
3.3.1. Distribución y comercialización.....	51
3.3.2. Proveedores externos.....	52
3.3.3. Proveedor interno	54
3.3.4. Descripción de productos	55
3.4 Productos estrella	55

3.5 Planificación y requerimientos actuales para el pronóstico	57
3.5.1. Capacidad estratégica empresarial.....	57
3.5.2. Cadena de Valor	57
3.5.3. Registro de ventas.....	59
CAPÍTULO IV. DESARROLLO DEL MODELO	62
4.1 Redes Neuronales Artificiales y su propuesta metodológica para el pronóstico	62
4.1.1. Propuesta Metodológica RNA´s	62
4.2 Construcción del modelo.....	64
4.2.1. Horizonte a pronosticar	64
4.2.2. Observación de los hechos	64
4.2.3. Selección de técnica.....	64
4.2.4. Desarrollo del pronóstico.....	64
4.2.5. Arquitectura de la red neuronal	67
4.2.6. Función de transferencia.....	68
4.2.7. Criterios de evaluación	69
4.2.8. Algoritmo general del sistema.....	76
CAPÍTULO V. ANÁLISIS Y COMPARACIÓN DE LOS RESULTADOS	78
5.1. Resultados productos estrella	78
5.1.1. Resultados Accesorios	79
5.1.2. Resultados Perfilería.....	80
5.1.3. Resultados Techos	81
5.2. Comparación de resultados	82
5.2.1. Comparación Accesorios	83
5.2.2. Comparación Perfilería.....	84
5.2.3. Comparación Techos	85
CONCLUSIONES	86
RECOMENDACIONES.....	87
REFERENCIAS BIBLIOGRÁFICAS.....	88
ANEXOS	93
ANEXO 1: Demanda mensual de 5 años del producto estrella Accesorios.....	93
ANEXO 2: Demanda mensual de 5 años del producto estrella Perfilería.	93
ANEXO 3: Demanda mensual de 5 años del producto estrella Techos.....	93
ANEXO 4: Iteraciones óptimas de entrenamiento del producto estrella Accesorios.	94

ANEXO 5: Comportamiento del ajuste de los datos del producto estrella Accesorios.	94
ANEXO 6: Ajuste de los datos en forma de campana al error cero absolutos del producto estrella Accesorios.....	95
ANEXO 7: Regresión por punto de error y el objetivo entrenado óptimo perseguido del producto estrella Accesorios.	95
ANEXO 8: Iteraciones óptimas de entrenamiento del producto estrella Perfilería.	96
ANEXO 9: Comportamiento del ajuste de los datos del producto estrella Perfilería.	96
ANEXO 10: Ajuste de los datos en forma de campana al error cero absolutos del producto estrella Perfilería.	97
ANEXO 11: Regresión por punto de error y el objetivo entrenado óptimo perseguido del producto estrella Perfilería.	97
ANEXO 12: Iteraciones óptimas de entrenamiento del producto estrella Techos.....	98
ANEXO 13: Comportamiento del ajuste de los datos del producto estrella Techos.	98
ANEXO 14: Ajuste de los datos en forma de campana al error cero absolutos del producto estrella Techos.....	99
ANEXO 15: Regresión por punto de error y el objetivo entrenado óptimo perseguido del producto estrella Techos.....	99

ÍNDICE TABLAS

Tabla 1: Equivalencias de nomenclatura entre la Estadística y la Inteligencia Artificial para el problema de predicción por redes neuronales.....	6
Tabla 2 : Funciones de los puestos de trabajo DIPAC MANTA S.A. (Sede Ibarra).....	44
Tabla 3: Composición Accionaria Empresarial.	48
Tabla 4: Colaboradores de la empresa DIPAC MANTA S.A. (Sede Ibarra).	49
Tabla 5: Empresas competidoras en producción y comercialización de acero.....	51
Tabla 6: Proveedores externos de la empresa DIPAC MANTA S.A.	53
Tabla 7: Detalle de la arquitectura de la red neuronal.	67
Tabla 8: Criterios de penalización Bayesiana.....	74
Tabla 9: Predicción de demanda para el Producto Accesorios para el año 2019 con Redes Neuronales Artificiales vs Estadística Tradicional.	79
Tabla 10: Predicción de demanda para el Producto Perfilería para el año 2019 con Redes Neuronales Artificiales vs Estadística Tradicional.	80
Tabla 11: Predicción de demanda para el Producto Techos para el año 2019 con Redes Neuronales Artificiales vs Estadística Tradicional.	81
Tabla 12: Evaluación de indicadores de errores para el Producto Accesorios.	83
Tabla 13: Evaluación de indicadores de errores para el Producto Perfilería.	84
Tabla 14: Evaluación de indicadores de errores para el Producto Techos.	85

ÍNDICE FIGURAS

Figura 1: Planificación de abastecimiento y distribución.....	3
Figura 2: Metodología para la selección parámetros de un modelo de RNA's.....	21
Figura 3: Esquema básico metodológico de la investigación.....	23
Figura 4: Esquema de funcionamiento de una neurona.....	25
Figura 5: Esquema de la arquitectura de una red.....	27
Figura 6: Interfaz gráfica de MATLAB®.....	31
Figura 7: Interfaz gráfica Toolbox para Redes Neuronales Artificiales.....	33
Figura 8: DIPAC MANTA S.A. (Sede Ibarra).....	42
Figura 9: Organigrama DIPAC MANTA S.A. (Sede Ibarra).....	43
Figura 10: Distribución de las sedes a nivel nacional.....	45
Figura 11: Top de empresas del Ecuador.....	47
Figura 12: DIPAC MANTA S.A. Matriz Manta.....	54
Figura 13: Gama de productos ofertados por DIPAC MANTA S.A. (Sede Ibarra).....	55
Figura 14: Productos estrella DIPAC MANTA S.A. (Sede Ibarra).....	56
Figura 15: Capacidad estratégica de la empresa DIPAC MANTA S.A.....	57
Figura 16: Relación de la cadena de suministros con la cadena de valor de la empresa DIPAC MANTA S.A.....	58
Figura 17: Registro de ventas del producto estrella (accesorios).....	59
Figura 18: Registro de ventas del producto estrella (perfiles).....	60
Figura 19: Registro de ventas del producto estrella (techos).....	60
Figura 20: AS-IS empresarial.....	61
Figura 21: Entrenamiento de la red neuronal artificial.....	65
Figura 22: Punto óptimo de iteración.....	66
Figura 23: Construcción de Red Neuronal Artificial.....	68
Figura 24: Función de transferencia de la capa oculta.....	68
Figura 25: Función de transferencia de la capa de salida.....	69
Figura 26: Comportamiento de datos entrenados dentro del nivel de confianza.....	70
Figura 27: Histograma de errores.....	70
Figura 28: Relación del rendimiento entre el entrenamiento, validación y prueba.....	71
Figura 29: Análisis de la data y su ajuste en cada etapa.....	71
Figura 30: Número de iteraciones.....	72
Figura 31: Reentrenamiento Levenberg-Marquardt de la red.....	73
Figura 32: Reentrenamiento Bayesian Regularization de la red.....	74
Figura 33: Relación de respuesta y errores entre la salida y objetivo.....	75
Figura 34: Flujograma del sistema.....	76
Figura 35: Comparación del pronóstico realizado en Redes Neuronales Artificiales vs Estadística Tradicional del producto estrella Accesorios.....	79
Figura 36: Comparación del pronóstico realizado en Redes Neuronales Artificiales vs Estadística Tradicional del producto estrella Perfilería.....	80
Figura 37: Comparación del pronóstico realizado en Redes Neuronales Artificiales vs Estadística Tradicional del producto estrella Techos.....	81
Figura 38: Resultados de errores arrojados del análisis de datos por la Red Neuronal Artificial en el producto estrella Accesorios.....	83

Figura 39: Resultados de errores arrojados del análisis estadístico tradicional en el producto estrella Accesorios.	83
Figura 40: Resultados de errores arrojados del análisis de datos por la Red Neuronal Artificial en el producto estrella Perfilería.....	84
Figura 41: Resultados de errores arrojados del análisis estadístico tradicional en el producto estrella Perfilería.	84
Figura 42: Resultados de errores arrojados del análisis de datos por la Red Neuronal Artificial en el producto estrella Techos.	85
Figura 43: Resultados de errores arrojados del análisis estadístico tradicional en el producto estrella Techos.	85

RESUMEN

Esta investigación presenta una aplicación de redes neuronales artificiales en el pronóstico de demanda, utilizando la herramienta computacional MATLAB ®. Teniendo en cuenta que, en cualquier proceso de planificación, las previsiones desempeñan un papel fundamental, al ser una de las bases para planificar, organizar y controlar la producción, dando prioridad a los nodos más críticos y sus actividades clave, de modo que las decisiones que se tomen sobre ellos generen el mayor impacto positivo posible. La metodología aplicada demuestra la calidad de las soluciones encontradas, las mismas que se comparan con métodos estadísticos tradicionales para demostrar la mejora encontrada mediante la aplicación de las redes neuronales artificiales. Cuando los resultados muestran que se alcanza el error cuadrático mínimo con la aplicación de redes neuronales artificiales, se obtiene un mejor rendimiento, por lo tanto, se establece un horizonte adecuado para la planificación y toma de decisiones en la industria para el uso de inteligencia artificial en los procesos de producción.

ABSTRACT

This research presents an application of artificial neural networks in demand forecasting, using the computational tool MATLAB ®. Keeping in mind that in any planning process forecasts play a fundamental role, being one of the bases for; planning, organizing and controlling production. It gives priority to the most critical nodes and their key activities, so that the decisions made about them will generate the greatest possible positive impact. The methodology applied demonstrates the quality of the solutions found which are compared with traditional statistical methods to demonstrate the value of the proposed solution. When the results show that the minimum quadratic error is reached with the application of artificial neural networks, a better performance is obtained. Therefore, a suitable horizon is established for the planification and decision making in the industry for the use of artificial intelligence in the production processes.

CAPÍTULO I. GENERALIDADES

1.1. Introducción

Con el único propósito de generar una mejora continua y un valor agregado ante el campo laboral, las empresas se dirigen hacia la implementación de nuevas metodologías las cuales generen un impacto positivo en sus resultados, en la mayoría de los casos la incertidumbre resultante de la mala planificación y toma de decisiones erróneas se traduce en errores bastante considerables al momento de generar el reabastecimiento de material, control de inventario, registro de ventas, pronósticos de la demanda, etc. A partir de esto se busca la medida correctiva que abarque todo el conjunto de problemas de una manera inteligente mediante un pronóstico de demanda usando la inteligencia artificial con el empleo de redes neuronales, siendo una herramienta novedosa y de gran impacto, y como resultado se logra una gran ayuda para la posterior planificación y toma de decisiones (PWC, 2011).

Con el uso de esta herramienta se prevén errores futuros y, además, de suma importancia la repercusión en ingresos y en la calidad global del servicio. En si el análisis del pronóstico de la demanda está conjugado con los registros de ventas en un tiempo determinado como la variable más importante, partiendo de este punto se generará la reprogramación del sistema de abastecimiento y su logística (PWC, 2011).

La globalización del mundo ha generado una fragmentación en las empresas, destruyendo el concepto de integración vertical y/o la concentración del negocio en una sola mano, generando empresas más desintegradas y específicas que dependen de otras empresas productoras y/o comercializadoras. Aumento en los riesgos inherentes de cada negocio, por tener más componentes que no controla ni conoce, por esto la comunicación, visibilidad y colaboración son las claves para disminuir el riesgo de la cadena de abastecimiento y distribución. El tener por si sola una comunicación óptima de la Cadena de Abastecimiento y

Distribución no genera una mejora en los niveles de servicios y procesos, pero aporta en forma importante a:

- Disminuir los riesgos de deterioros o fallas en la cadena de abastecimiento y distribución.
- Aumentar el Nivel de Servicio.
- Optimizar los procesos operacionales.
- Pasar de una logística reactiva a una proactiva.
- Se debe comunicar toda información que condicione, restrinja, modifique e influya en el proceso de abastecimiento y distribución de la empresa.
- Tipo de producto y sus condiciones de almacenaje y manipulación.
- Lotes mínimos y máximos de compra.
- Lead time del proveedor.
- Cantidad recibida (conforme, faltante, rechazada, etc.).
- Fecha, hora, productos y cantidad a recibir o despachar.
- Condiciones de entrega del producto al cliente (horarios, embalaje, orden, etiquetado, etc.).
- Nivel de servicio comprometido con el cliente.
- Atrasos en las compras y/o plan de producción (PWC, 2011).

1.1.1 Preparación de la planificación para el abastecimiento y distribución

Es importante preparar la organización para poder realizar una planificación eficiente y eficaz de la cadena de abastecimiento y distribución, con:

- Una robusta comunicación interna y externa de la empresa.
- Una visibilidad global en la cadena de abastecimiento y distribución.
- Una colaboración sustentable en el tiempo con proveedores y clientes.
- Políticas, normas claras y conocidas por la organización.
- Procesos de trabajos claramente definidos y conocidos por la organización.
- Definición y participación de reuniones periódicas de trabajos de coordinación y planificación.
- Entender que la planificación de la cadena de abastecimiento y distribución es un proceso de la empresa, por lo que la ejecución de éste debe ser colaborativo e integral (PWC, 2011).



Figura 1: Planificación de abastecimiento y distribución.

Fuente: (PWC, 2011).

Todos los datos que ayuden a tener una trazabilidad y seguimiento de los productos desde su origen hasta su destino final. Al definir los datos, debemos tener plena claridad de la dificultad de implementar el proceso de recolección de éstos, tanto a nivel de esfuerzos como calidad y oportunidad de la información. También se deben contemplar procesos de validación de los datos recolectados, de manera de asegurar la calidad de ellos. Todo dato por recolectar debe aportar antecedentes de manera que permita construir y elaborar información útil y valiosa en tiempo, calidad y cantidad para la toma de decisión oportuna (PWC, 2011).

Es importante identificar cuáles son los datos, por tipo de negocio, que se deben ver, pero éstos se pueden clasificar en 4 grupos que son:

- Los productos.
- Proveedores.
- Mis operaciones.
- Cliente o mercado.

Algunos ejemplos de estas dimensiones pueden ser:

- Los productos.
- Fechas de vencimientos.
- Lote productivo.
- Unidad de medida.
- Codificación.
- Condición del producto (disponible o no disponible) (PWC, 2011).

Actualmente el uso de las Redes Neuronales Artificiales como un método novedoso y en virtud de la tendencia variante de la planificación en las empresas se encuentra desplazando a los métodos estadísticos más tradicionales, sobre todo por los resultados tan prometedores que se empiezan a consolidar como un modelo práctico y dinámico para la toma de decisiones que es una opción muy factible para la empresa.

Se puede constatar, sin embargo, que muchos de los problemas abordados en Análisis de datos son comunes con la Inteligencia Artificial. Estas dos disciplinas, como a menudo sucede en el entorno académico, se han desarrollado la una a espaldas de la otra, dando lugar a nomenclaturas totalmente diferentes para problemas iguales. La Tabla 1, elaborada por el profesor L. Lebart, muestra las equivalencias para el problema de la predicción con redes neuronales.

Resumiendo, podemos decir que la Inteligencia Artificial ha estado más preocupada en ofrecer soluciones algorítmicas con un coste computacional aceptable, mientras que la estadística se ha preocupado más del poder de generalización de los resultados obtenidos, esto es, poder inferir los resultados a situaciones más generales que la estudiada (Aluja, 2001).

Tabla 1: *Equivalencias de nomenclatura entre la Estadística y la Inteligencia Artificial para el problema de predicción por redes neuronales.*

Inteligencia Artificial	Estadística
Red(<i>network</i>)	Modelo
Ejemplos (<i>patterns</i>)	Observaciones, individuos
<i>Features, inputs, outputs</i>	Variables
<i>Inputs</i>	Variables explicativas
<i>Outputs, targets</i>	Variables de respuesta
Errores	Residuos
<i>Training, learning</i>	Estimación
Función de error, coste	Criterio de ajuste
Pesos, coef, sinápticos	Parámetros
Aprendizaje supervisado	Regresión, discriminación
Aprendizaje no supervisado	Clasificación

Fuente: (Aluja, 2001).

Todo esto comporta la necesidad de tratar tablas de datos complejos y de tamaño inimaginable hasta ahora. Esta situación es nueva para el estadístico y bastante alejada de la clásica muestra aleatoria de observaciones independientes formada por algunas decenas de variables y unos cuantos millares de individuos. En general, cualquiera que sea el problema por resolver, no existe una única técnica para solucionarlo, sino que puede ser abordado siguiendo aproximaciones distintas. El número de técnicas es muy grande y sólo puede crecer en el futuro.

Redes neuronales. Inspiradas en el modelo biológico, son generalizaciones de modelos estadísticos clásicos. Su novedad radica en el aprendizaje secuencial, el hecho de utilizar transformaciones de las variables originales para la predicción y la no linealidad del modelo.

Es decir, permite aprender en contextos difíciles, sin precisar la formulación de un modelo concreto. Su principal inconveniente es que para el usuario son una caja negra (Aluja, 2001).

La modelación matemática mediante redes neuronales artificiales enfocada al pronóstico implica, su correcto diseño en base a las necesidades, y las variables que busca descifrar. De esta manera obtiene el aporte deseado por el modelo y por ende los resultados que desea la empresa, además genera un aporte considerable a la empresa caso de estudio (*DIPAC MANTA S.A.*).

La toma de decisiones es posiblemente uno de los aspectos más importantes de aplicación de la matemática en diversas esferas de la actividad humana; esto si consideramos que el primer paso para intentar resolver un problema de toma de decisiones consiste en formular un modelo matemático de un sistema o una situación a analizar. Sin embargo, en condiciones reales la toma de decisiones es imprecisa debido, al menos en parte, a la incertidumbre que rodea a tales situaciones. Es así como, si tenemos la intención de hacer modelos matemáticos razonablemente adecuados al mundo real, se debe ser capaz de introducir la incertidumbre en dichos modelos y sugerir medios para el procesamiento de la información imprecisa (Pandian, 2002).

1.1.2. Programación estocástica:

La programación lineal es una herramienta fundamental de planificación, aunque una de sus limitaciones es el requerimiento de que toda la información se conozca con certeza. Los modelos de programación estocástica combinan el paradigma de la programación lineal con la formulación de parámetros aleatorios. La programación estocástica puede usar escenarios o distribuciones de probabilidades para los parámetros inciertos.

Diversos autores han sugerido numerosos modelos de programación estocástica en lo referente a la planificación de la producción cabe destacar:

Eppen y otros (1989) desarrollan un modelo para planificar las capacidades de un importante fabricante de automóviles. El modelo de programación estocástica se basó en escenarios de demandas con ciertas probabilidades. Además, se incorporó un análisis de riesgo (Eppen, 2015 - 1989).

Josefa Mula (2004) presenta un modelo de programación estocástica para el problema del *MRP (Material Requirements Planning)* con incertidumbre en la demanda. Los autores analizan diferentes enfoques para la planificación de la producción y la capacidad utilizando programación estocástica (Josefa Mula Bru1, 2004) .

1.1.3. Teoría de conjuntos difusos (*Fuzzy Sets*):

La teoría de los conjuntos difusos hace una distinción entre aleatoriedad e imprecisión, Bellman y Zadeh (2002) presentan la forma de aplicar la teoría de conjuntos difusos a la toma de decisiones con incertidumbre. Los autores cuestionan el uso del enfoque probabilista ya que, según ellos, la imprecisión que normalmente se encuentra en muchas situaciones no es lo mismo que aleatoriedad (Zadeh, 2002).

Rubio (2017) describe la modelación y simulación mediante conjuntos difusos de una cadena de suministro en serie en un entorno de incertidumbre. El objetivo es determinar los niveles de stock y cantidades a ordenar durante un horizonte de tiempo finito, para un nivel de servicio aceptable y a un costo razonable. Posteriormente, (Rubio, 2017) presenta una herramienta de simulación, SCSIM, desarrollada para analizar el comportamiento y funcionamiento de la cadena de suministro en presencia de incertidumbre utilizando conjuntos difusos.

Los conjuntos difusos se utilizan para describir las imprecisiones de la información, pero cuando el problema progresa con la adquisición de datos reales, se pueden empezar a modelar estos valores con distribuciones de probabilidad y frecuencias relativas. De esta forma, la demanda de los clientes, el nivel de desempeño del proveedor externo, y los tiempos de ciclo de producción se convierten en variables *fuzzy*, que son asociadas con distribuciones de probabilidad de una forma similar a las variables aleatorias (J. de J. Rubio, 2017).

1.1.4. Programación dinámica:

La programación dinámica es un enfoque para la modelación, análisis y solución de problemas de decisión dinámicos tanto en entornos deterministas como estocásticos. La principal diferencia entre programación dinámica y estocástica está en la estructura utilizada para formular ambos modelos. En programación dinámica los conceptos de “estado del proceso” y “función valor” juegan un rol central, mientras que estos conceptos no son utilizados en programación estocástica (Shapiro, 2002).

Josefa Mula (2004) desarrollan un modelo para la planificación y programación dinámica de la producción en un entorno de fabricación de hierro y acero. El modelo de optimización propuesto está basado sobre el concepto de entradas-salidas de (Leontif, 1966). El modelo desarrollado es apropiado para gestionar redes de cadenas de suministro descentralizadas o centralizadas, aunque los beneficios del modelo se aprecian mejor cuando los miembros de la red de fabricación juegan el rol de proveedor y consumidor simultáneamente. (Josefa Mula Bru1, 2004)

1.1.5. Redes Neuronales Artificiales en el pronóstico de la demanda:

La idea de utilizar RNA's en pronóstico de series de tiempo fue aplicada por primera vez en 1964 cuando Hu utilizó una RNA lineal adaptable de Widrow para el pronóstico del clima, debido a la ausencia de un algoritmo de entrenamiento para RNA multicapa en el tiempo, la

investigación quedó limitada. En 1974 Werbos formuló primero la retropropagación, pero no fue conocido por los investigadores en RNA's. A partir de 1986 cuando el algoritmo de retropropagación (del inglés *backpropagation*), el desarrollo de RNA's para pronóstico de series de tiempo ha ido en incremento. Werbos reportó que la RNA entrenada por retropropagación superó el desempeño de los métodos estadísticos tradicionales tales como los procedimientos de regresión y *Box- Jenkins* en varios casos (Cabrera Ríos, 2010).

En años recientes, las RNA's han llegado a ser muy populares en el pronóstico de series de tiempo en un gran número de áreas incluyendo finanzas, generación de energía, medicina, recursos del agua y ciencias ambientales, entre otras (Cabrera Ríos, 2010).

Para hacer un pronóstico es común requerir información cuantitativa del comportamiento de la demanda a través del tiempo, es decir, una serie de tiempo, siendo el Análisis de Series de Tiempo la técnica estadística más utilizada para estimar su comportamiento (Cabrera Ríos, 2010).

Por muchos años, este tipo de análisis ha estado dominado por la utilización de métodos estadísticos lineales que se pueden implementar de manera conveniente, sin embargo, la existencia de relaciones no lineales entre los datos puede limitar la aplicación de estos modelos, en la práctica es muy posible encontrar relaciones no lineales en los datos, tal como sucede en este caso de estudio. Por ello es necesaria la utilización de técnicas capaces de reflejar dicho comportamiento (Cabrera Ríos, 2010).

La utilización de Redes Neuronales Artificiales (RNA's) para pronósticos de series de tiempo es relativamente nueva en la literatura, sin embargo, lo positivo de los resultados en las aplicaciones prácticas la convierten en un área prometedora (Cabrera Ríos, 2010).

Los resultados alcanzados por la modelación matemática mediante redes neuronales artificiales del pronóstico de la demanda también se evidencian en proyectos de trabajo de grado realizados en diferentes universidades del país. Principalmente se logran resultados como:

- Los resultados apoyan la utilización de las RNA's como técnicas confiables de pronóstico y apuntan a la factibilidad de su instauración en la industria.
- Se puede resaltar que la metodología de usar una RNA's, definida y entrenada, para determinar la concentración de determinado elemento de interés, es una idea novedosa que se robustece por los resultados. Las entradas a la red no provienen sólo de datos del espectro detectado, sino que se basan en los antecedentes propios del experimento y se relacionan con sus distintos componentes (Cabrera Ríos, 2010).

Con la realización del presente proyecto se pretende disminuir la incertidumbre en la demanda y así lograr un reabastecimiento óptimo a la sede con el fin de obtener un mejor cumplimiento con la demanda. Otros beneficios que se pretende obtener es la disminución de ventas por falta de stock (Cabrera Ríos, 2010).

1.2. Problema

La empresa DIPAC MANTA S.A. (Sede Ibarra) es una empresa sede que se dedica a la distribución, fabricación y comercialización de productos de hierro y acero o de sus derivados industriales, por cuenta propia o en representación de terceros.

Mediante consulta al gerente, se encontró como problemática principal de la empresa el desconocimiento de la demanda, razón por la cual se han generado inconformidades, conllevando a la empresa a tomar medidas urgentes que permitan mejorar su proceso de aprovisionamiento.

En los problemas de planificación de la producción, las situaciones reales son frecuentemente inciertas. Debido a la defectuosa planificación del estado futuro, ésta puede no ser completamente conocida. Este tipo de incertidumbre (de carácter estocástico) se ha gestionado, tradicionalmente, mediante la teoría de la probabilidad y la estadística, además se denominan a este tipo de variaciones como incertidumbre estocástica en contraste con la poca precisión presente en la descripción del significado semántico de los eventos, fenómenos o sentencias, que denomina incertidumbre (fuzziness). La aleatoriedad o incertidumbre está presente en todas las áreas en los que los criterios humanos, la evaluación y las decisiones son importantes, como es el caso de la planificación de la producción. La planificación de la producción *fuzzy* permite la imprecisión que puede existir en las previsiones de la demanda del mercado y/o los parámetros asociados con la capacidad productiva, el retraso de la demanda o la pérdida de ventas. En un esfuerzo por obtener un mejor entendimiento del uso de las redes neuronales artificiales en problemas de planificación de la producción y para proporcionar una base para investigaciones futuras, se ha realizado un estudio mediante una observación de campo, entrevista al gerente y clientes encontrando como problemática principal el reabastecimiento de la sede e incumplimiento en el despacho del producto. (Josefa Mula Bru1, 2004)

Por los motivos mencionados anteriormente se considera la realización de un Modelo para el pronóstico de la demanda de la empresa DIPAC MANTA S.A. (Sede Ibarra) aplicando redes neuronales artificiales, el mismo que estará sustentado en el estudio del estado del arte y su modelación para generar información útil para las decisiones futuras de la empresa.

1.3. Objetivos

1.3.1 Objetivo General

Desarrollar un modelo para pronosticar la demanda de la empresa DIPAC MANTA S.A. (Sede Ibarra) que garantice la adecuada planificación de la producción mediante la aplicación de Redes Neuronales Artificiales.

1.3.2. Objetivos Específicos

- Revisar las técnicas y algoritmos utilizados para el pronóstico de la demanda y la aplicación de Redes Neuronales Artificiales.
- Diagnosticar la situación actual del abastecimiento de las familias estrellas de productos de perfilería, techos y accesorios, para lograr una mejor planificación.
- Desarrollar un modelo para realizar el pronóstico de la demanda de la empresa.
- Realizar el análisis de los resultados obtenidos en base al desarrollo del pronóstico.

1.4. Alcance

La validación y comprobación del pronóstico de la demanda mediante redes neuronales artificiales y su contribución al desarrollo empresarial, fortaleciendo la planificación de producción y abastecimiento a la empresa y a su vez que garanticen el desarrollo de las capacidades competitivas de la empresa y sus niveles adecuados de abastecimiento.

CAPÍTULO II. ESTADO DEL ARTE DEL PRONÓSTICO DE LA DEMANDA MEDIANTE REDES NEURONALES ARTIFICIALES

2.1. Pronóstico (*Forecasting*)

2.1.1. Planeación y control de la producción

La planeación y control de la producción juegan un papel importante dentro de las empresas de manufactura, ya que permiten satisfacer las necesidades de los clientes, los objetivos empresariales y las restricciones propias del sistema mediante la utilización y coordinación efectiva de los recursos disponibles (Ramírez, Torné, & Cabrera, 2012).

Por lo general, el proceso de toma de decisiones de la planeación y control de la producción tiene una estructura jerárquica que está conformada por tres niveles principales: las decisiones estratégicas o de largo plazo, las decisiones agregadas o de mediano plazo y las decisiones operativas o de corto plazo (Ramírez, Torné, & Cabrera, 2012).

Las decisiones a largo plazo se enfocan en las necesidades globales y los objetivos estratégicos de la empresa, tales como la ubicación de las instalaciones, las previsiones de la demanda y el diseño de los productos. Las decisiones de mediano plazo a menudo implican el establecimiento del programa maestro de producción, *Master Production Schedule (MPS)* y la planeación de los requerimientos de materiales, *Material Requirements Planning (MRP)*. Finalmente, las decisiones a corto plazo implican el día a día de la programación de

operaciones, la asignación de los recursos, la secuencia del trabajo y el control de los talleres (Ramírez, Torné, & Cabrera, 2012).

2.1.2. Pronóstico Tradicional Estadístico Clásico

- **Historia y necesidad de los pronósticos**

Muchas de las técnicas de pronóstico utilizadas actualmente se desarrollaron en el siglo XIX, un ejemplo de ellas son los procedimientos de análisis de regresión. Los procedimientos de descomposición, suavizamiento y *Box-Jenkins* entran en esta categoría (Hanke & Wichern, 2006).

Con el desarrollo de técnicas de pronóstico más sofisticadas, más el advenimiento de las computadoras, en especial la proliferación de la computadora personal y su *software* asociado, la realización de pronósticos ha recibido cada vez más atención. Ahora, todo administrador tiene la capacidad de utilizar técnicas muy sofisticadas de análisis de datos para fines de pronóstico en consecuencia, es esencial entenderlas. Por esta razón, los agentes que necesitan de los pronósticos deben estar alerta ante el uso inadecuado de las técnicas de pronósticos, ya que cuando éstos son imprecisos pueden llevar a malas decisiones (Hanke & Wichern, 2006).

A medida que crece la preocupación por el proceso del pronóstico, el desarrollo de nuevas técnicas para pronósticos continúa. Un foco de atención particular al respecto se encuentra en los errores que son inherentes a cualquier procedimiento de pronóstico. Las predicciones de los resultados rara vez son precisas, y quienes pronostican sólo pueden intentar que los

errores que se comenten de manera inevitable se minimicen tanto como sea posible (Hanke & Wichern, 2006).

En vista de que las imprecisiones no se pueden separar del proceso, ¿por qué son necesarios los pronósticos? La respuesta es que todas las organizaciones operan en una atmósfera de incertidumbre; pero hoy deben tomarse decisiones que afectarán su futuro.

Para los administradores de una empresa, las conjeturas sobre el futuro, con base en cierta información, son más valiosas que las presunciones sin bases. Además, podemos ver varias maneras de pronosticar que se basan en métodos lógicos de manipulación de datos, los cuales han sido generados por acontecimientos históricos (Hanke & Wichern, 2006).

Esto no quiere decir que los pronósticos intuitivos sean malos. Al contrario, es frecuente que “las corazonadas” de quienes dirigen las organizaciones proporcionen los únicos pronósticos disponibles. Nuestro punto de vista es que quienes toman las decisiones se encuentran en una mejor posición si entienden las técnicas de pronósticos, tanto cuantitativas como cualitativas, y las utilizan con prudencia; en cambio, obtendrán resultados inferiores si se ven forzados a planear sin tener el beneficio de buenos pronósticos (Hanke & Wichern, 2006).

La función de los pronósticos por juicio personal ha cambiado en años recientes. Antes de la llegada de las técnicas modernas de pronósticos y el poder de la computadora, el juicio del administrador era la única herramienta de pronóstico posible. No obstante, de acuerdo con Makridakis (1986), los pronósticos generados al utilizar sólo el juicio personal no son tan precisos como aquellos que combinan los juicios personales con las técnicas cuantitativas (Hanke & Wichern, 2006).

(Los humanos poseen conocimientos únicos e información interna que no se encuentran en los métodos cuantitativos. Sin embargo, los estudios empíricos y los experimentos de laboratorio han demostrado sorprendentemente que esos pronósticos no tienen mayor precisión que aquellos generados por métodos cuantitativos. Los humanos tienden a ser optimistas y subestiman la incertidumbre futura. Además, el costo de los pronósticos con métodos de juicio personal comúnmente es más alto que cuando se utilizan métodos cuantitativos.)

(Hanke & Wichern, 2006).

Se cree que es más eficiente el pronosticador capaz de formular una mezcla habilidosa de técnicas cuantitativas de pronósticos con un buen juicio personal y que evita los extremos donde se depende completamente de cualquiera de las dos. En un extremo se encuentra el ejecutivo que, debido a su ignorancia y miedo a las técnicas cuantitativas y a las computadoras, depende únicamente de su intuición y sentimientos. En el otro extremo está un pronosticador experto en las últimas técnicas de manipulación de datos, pero es incapaz o no está dispuesto a relacionar el proceso de pronósticos con las necesidades de la organización y de quienes toman las decisiones dentro de ella (Hanke & Wichern, 2006).

2.1.3. Tipos de Pronóstico

Cuando los administradores se enfrentan a la necesidad de tomar decisiones en una atmósfera de incertidumbre, ¿qué tipos de pronósticos están disponibles para ellos? Primero, los procedimientos de pronóstico podrían clasificarse como de largo o corto plazos. Los pronósticos de largo plazo son necesarios para establecer el curso general de una organización y son el enfoque exclusivo de la alta dirección. Los pronósticos de corto plazo se usan para diseñar estrategias inmediatas, y los mandos medios y las gerencias de primera línea los usan para cubrir las necesidades del futuro inmediato (Hanke & Wichern, 2006).

También se podrían clasificar los pronósticos en términos de su posición dentro de un continuo micro y macro; es decir, en la medida que involucren pequeños detalles en comparación con una gran escala. Por ejemplo, a un gerente de planta le podría interesar el pronóstico del número de trabajadores necesarios durante los próximos meses (es decir un micro pronóstico), mientras que el gobierno pronostica la cantidad total de personas empleadas en el país entero (es decir un macro pronóstico). Una vez más, los diferentes niveles administrativos dentro de una organización tienden a centrarse en diferentes niveles del continuo micro y macro, Por ejemplo, a la alta dirección le interesaría pronosticar las ventas para toda la compañía, mientras que a los vendedores individuales les sería de más interés pronosticar sus volúmenes individuales de ventas (Hanke & Wichern, 2006).

Los procedimientos de pronósticos también pueden clasificarse según sean más cuantitativos o cualitativos. En un extremo, una técnica totalmente cualitativa no requiere manipulación abierta de datos. Solamente se utiliza el juicio de quien pronostica. Incluso aquí, en realidad, el juicio de esta persona es el resultado de la manipulación mental de datos históricos. En el otro extremo, las técnicas puramente cuantitativas no necesitan elementos de juicio; son procedimientos mecánicos que producen resultados cuantitativos. Por supuesto, algunos procedimientos cuantitativos requieren una manipulación mucho más sofisticada de los datos que otros. Estos procedimientos enfatizan las técnicas cuantitativas de pronóstico debido a que se requiere un entendimiento más amplio de estos procesos, los cuales son muy útiles en la dirección eficaz de las organizaciones modernas. Sin embargo, se pone de relieve, una vez más, que deben utilizarse el sentido común y la apreciación junto con los procedimientos mecánicos y de manipulación de datos. Sólo de esta manera puede obtenerse un pronóstico inteligente (Hanke & Wichern, 2006).

2.2. Importancia e impacto de la inteligencia artificial para el pronóstico no tradicional de la demanda

En toda industria, la planeación es una necesidad. Un objetivo importante de la planeación es tratar de prever lo que puede suceder en el futuro. En este trabajo, se colaboró con una empresa de distribución de productos siderúrgicos con necesidad de planear a nivel operacional, estratégico y táctico para mantenerse competitiva ante las fluctuaciones de mercado y cursos de acción de sus competidores. Esta empresa, como la gran mayoría, tiene como objetivo principal generar utilidades y brindar un alto nivel de servicio a sus clientes (Aguilar & Ríos, 2007).

Para cumplir con el alto nivel de servicio y maximizar las utilidades, la red de transmisión debe tener capacidad suficiente para satisfacer la demanda de los clientes. Por ello, le corresponde al tomador de decisiones determinar la capacidad de la red (Aguilar & Ríos, 2007).

A partir de un pronóstico, el tomador de decisiones puede determinar la capacidad que se requiere en la red de transmisión para satisfacer la demanda, así como determinar con anticipación si es necesaria una expansión de capacidad. Un buen trabajo de pronóstico deberá resultar en una mejor planeación del presupuesto anual, así como un mejor aprovechamiento de los recursos económicos de la empresa (Aguilar & Ríos, 2007).

Para hacer un pronóstico es común requerir información cuantitativa del comportamiento de la demanda a través del tiempo, es decir, una serie de tiempo, siendo el Análisis de Series de Tiempo la técnica estadística más utilizada para estimar su comportamiento (Aguilar & Ríos, 2007).

Por muchos años, este tipo de análisis ha estado dominado por la utilización de métodos estadísticos lineales que se pueden implementar de manera conveniente, sin embargo, la existencia de relaciones no lineales entre los datos puede limitar la aplicación de estos modelos. En la práctica es muy posible encontrar relaciones no lineales en los datos. Por ello es necesario la utilización de técnicas capaces de reflejar dicho comportamiento (Aguilar & Ríos, 2007).

La utilización de Redes Neuronales Artificiales (RNA's) por sus siglas en inglés (*Artificial Neural Networks*) para pronósticos de series de tiempo es relativamente nueva en la literatura de pronóstico con el uso de redes neuronales artificiales como es (Aguilar & Ríos, 2007), sin embargo, lo positivo de los resultados en las aplicaciones prácticas la convierten en un área prometedora.

Para este trabajo, la empresa brindó información histórica de registros mensuales acerca del sistema de aprovisionamiento de materia prima de los productos estrella a estudiar y analizar de los últimos 3 años. Con esta información, se realizará el pronóstico de la demanda para períodos posteriores mediante el uso de RNA's (Aguilar & Ríos, 2007).

Como resultado de otras investigaciones se obtuvo como ejemplo que al intentar desarrollar el modelo de RNA's para esta aplicación de pronóstico de series de tiempo, se experimentó y se identificó que la exactitud del pronóstico de la RNA's depende de varias decisiones críticas en cuanto a la definición de los parámetros que intervienen en el modelo, así como de la arquitectura de RNA que se esté utilizando. Algunas de estas decisiones pueden ser tomadas en el proceso de construcción del modelo, mientras que otras requieren ser especificadas antes de que comience la modelación. Sin embargo, no existe una regla establecida que permita tomar varias de estas decisiones de manera adecuada (Aguilar & Ríos, 2007).

2.3. Metodologías y técnicas para pronosticar mediante inteligencia artificial (Redes Neuronales Artificiales)

2.3.1 Metodología mediante selección de parámetros

Para esta metodología se toman como prueba todos los parámetros controlados introducidos o a su vez las variables, de esta manera podemos tener un control de las variaciones en la medida que se desempeña este experimento.

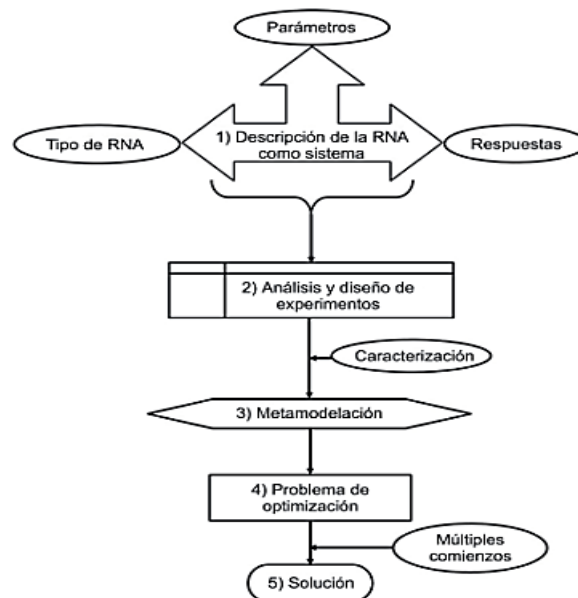


Figura 2: Metodología para la selección parámetros de un modelo de RNA's.

Fuente: (Aguilar & Ríos, 2007).

La descripción de la metodología es la siguiente:

- Descripción de la RNA como sistema:

- a) Determinar el tipo de RNA que se utilizará para el análisis.
 - b) Identificar los parámetros controlables.
- Definir las respuestas de interés (medidas de desempeño del modelo de RNA's).
- Análisis y diseño de experimentos:
 - a) Planear, ejecutar e interpretar un diseño estadístico de experimentos.
- Metamodelación:
 - a) Describir la superficie de cada respuesta mediante un modelo de regresión apropiado.
- Problema de optimización:
 - a) Considerar los metamodelos como funciones objetivo de un problema de optimización.
- Solución:
 - a) Resolver los problemas de optimización definidos en el paso anterior. Utilizar múltiples comienzos para escapar de optimalidad local (Aguilar & Ríos, 2007).

2.3.2 Metodología mediante obtención de datos.

Para definir la metodología a emplearse se debe considerar que una serie de datos describe su propio comportamiento, por lo que es importante entender que con esta metodología se obtendrá la mejor vía para pronosticar la demanda dentro de la empresa donde se llevó el caso de estudio, se debe estar consciente de que el modelo no será único para todas las situaciones dentro de la misma rama industrial, ya que el tratamiento de los datos se debe realizar bajo diferentes factores (Santoyo & Laguna, 2013).

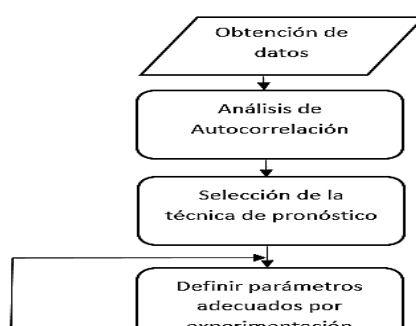


Figura 3: Esquema básico metodológico de la investigación.

Fuente: (Santoyo & Laguna, 2013).

La primera etapa para realizar pronósticos es la recolección de datos válidos y confiables. Un pronóstico no puede ser más preciso que los datos en que se basa. Cuando se mide una variable a lo largo del tiempo, las observaciones en diferentes periodos con frecuencia están relacionadas o correlacionadas. Esta correlación se mide mediante el uso del coeficiente de autocorrelación. Posteriormente se selecciona el método de pronóstico adecuado en función del patrón que presenten los datos, el tipo de serie y la facilidad de aplicación (Makradakis, 1986). Además, se deben de establecer los parámetros adecuados para el tipo de pronóstico, este paso fuere suelto mediante experimentación exhaustiva tomando como variable de respuesta un error cuadrático medio mínimo (Santoyo & Laguna, 2013).

2.4. Relevancia de las Redes Neuronales Artificiales

2.4.1. Fundamentos biológicos de las redes neuronales.

Las redes neuronales artificiales se basan en el funcionamiento del sistema neuronal del cuerpo humano. En el cuerpo humano encontramos 3 elementos fundamentales: los órganos receptores que recogen información del exterior; el sistema nervioso que transmite la

información, la analiza y en parte almacena, y envía la información elaborada y, los órganos efectores que reciben la información de parte del sistema nervioso y la convierte en una cierta acción (Rodríguez, 2015).

La unidad fundamental del sistema nervioso es la neurona. Las neuronas se unen unas con otras formando redes. Se componen de un cuerpo o núcleo, del axón, que es una ramificación de salida de la neurona, y de un gran número de ramificaciones de entrada llamadas dendritas. Su funcionamiento es el siguiente. Las señales de entrada llegan a la neurona a través de la sinapsis, que es la zona de contacto entre neuronas (u otro tipo de células, como las receptoras). La sinapsis recoge información electroquímica procedente de las células adyacentes que están conectadas a la neurona en cuestión. Esta información llega al núcleo de la neurona, a través de las dendritas, que la procesa hasta generar una respuesta, la cual es posteriormente propagada por el axón (Rodríguez, 2015).

La sinapsis está compuesta de un espacio líquido donde existe una cierta concentración de iones. Este espacio tiene unas determinadas características eléctricas que permiten inhibir o potenciar la señal eléctrica a conveniencia (Rodríguez, 2015).

Por ello, se puede ver que el sistema neuronal es un conjunto de neuronas conectadas entre sí, que reciben, elaboran y transmiten información a otras neuronas, y que dicha información se ve potenciada o inhibida en la siguiente neurona a conveniencia, gracias a las propiedades del espacio intersináptico (Rodríguez, 2015).

De hecho, esta propiedad de poder alterar el peso de cada información en la red neuronal nos otorga en cierta medida la capacidad de aprender (Rodríguez, 2015).

2.4.2. Redes Neuronales Artificiales.

Las redes neuronales artificiales tratan de emular las características y propiedades de las redes neuronales biológicas. En general, consisten en una serie de unidades denominadas neuronas, conectadas entre sí (Rodríguez, 2015).

Cada neurona recibe un valor de entrada, el cual transforma según una función específica denominada función de activación. Dicha señal transformada pasa a ser la salida de la neurona (Rodríguez, 2015).

Las neuronas se conectan entre sí según una determinada arquitectura. Cada conexión tiene un determinado peso que pondera cada entrada a la neurona. De esta manera la entrada de cada neurona es la suma de las salidas de la neurona conectadas ella, multiplicada por el peso de la respectiva conexión. *La figura 4* ilustra dicho concepto (Ghiassi, Zimbra, & Saidane, 2008):

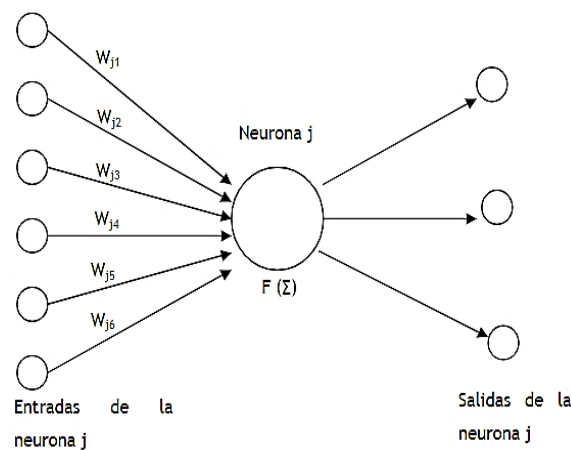


Figura 4: Esquema de funcionamiento de una neurona.

Fuente: (Rodríguez, 2015).

Este modelo, la neurona j recibe una serie de entradas X_1, X_2, \dots, X_n . Cada señal se multiplica por el peso asociado a su conexión W_1, W_2, \dots, W_n . Luego, se suman estas entradas ponderadas y se les aplica la función de activación $F[\sum (W)]$ para generar la señal de salida

de la neurona j . Los valores de los pesos son ajustados durante la fase de aprendizaje (Rodríguez, 2015).

Como se ha comentado anteriormente, estas neuronas están conectadas entre sí de acuerdo con una determinada arquitectura. Es decir, las neuronas se agrupan en distintas capas: una capa de entrada, otra de salida, y en el caso de existir, una o varias capas ocultas como se muestra en el *esquema de la arquitectura de una red* figura 5. La salida de cada neurona se propaga por igual por estas conexiones hasta las neuronas de destino. Cada conexión tiene un peso asociado que pondera el valor numérico de la señal que viaja por ésta. Así pues, una red de neuronas artificial puede verse como un grafo cuyos nodos tienen funcionamiento similar, los cuales propagan la información a través de las distintas conexiones (Rodríguez, 2015).

Para entender el funcionamiento de una red debemos visualizar el esquema de arquitectura de una red. Las entradas a la red son introducidas en las neuronas de la capa de entrada, que normalmente genera una salida tal cual o las escala para que las señales se encuentren en un determinado rango. Estas entradas son propagadas a las neuronas de la siguiente capa. De acuerdo con el esquema de funcionamiento de una neurona, cada neurona j de la segunda capa generará una salida de valor como se muestra en la siguiente ecuación:

$$S_{2j} = F_{2j}(X_1 W_{1j}) \quad (1)$$

X_1 es el vector de entradas de la capa 1 y W_{1j} el vector de pesos correspondientes a las conexiones que van de todas las neuronas de la primera capa a la neurona j de la segunda capa. La función F_{2j} es la función de activación de la neurona j de la segunda capa. Así con todas las neuronas de la segunda capa. Estas salidas son propagadas a las neuronas de la capa de salida, estas neuronas generan las salidas de la red. Cada neurona i de la capa de salida generará una salida de valor como podemos ver en la siguiente ecuación:

$$S_{si} = F_{si}(W_{2i}S_2) \quad (2)$$

Donde W_{2i} es el vector de pesos correspondientes a las conexiones que van de las neuronas de la segunda capa a la neurona i de la capa de salida, y S_2 el vector de salidas de las neuronas de la capa dos, que a su vez son entradas de las neuronas de la capa de salida (Rodríguez, 2015) (Neto & Fiorelli, 2008).




Figura 5: Esquema de la arquitectura de una red.

Fuente: (Rodríguez, 2015).

Por último, hablar del aspecto más importante y delicado de redes neuronales, el aprendizaje. Las RNA son sistemas de aprendizaje basadas en datos que son utilizados como patrones. Por ello la capacidad de una red de resolver un problema está muy ligada a los patrones utilizados durante su fase de aprendizaje (Rodríguez, 2015) (Adamowski & Karapataki, 2010).

2.5. Redes Neuronales Artificiales vs. Estadística Clásica Tradicional

Los pronósticos de demanda son indicadores de realidades económico-empresariales, básicamente en la situación de la industria en el mercado y en la participación de la empresa en ese mercado. El pronóstico determina qué puede venderse con base en la realidad, y el plan de ventas permite que esa realidad hipotética se materialice, guiando al resto de los

planes operativos de la empresa. La elección e implementación de un método adecuado de pronósticos siempre ha sido un tema de gran importancia para las empresas. Se utilizan los pronósticos en el área de compras, marketing, ventas, etc. Un error significativo en el pronóstico de ventas podría dejar a una empresa sin la materia prima o insumos necesarios para su producción, o podría generarle un inventario demasiado grande. En ambos casos, el pronóstico erróneo disminuye las utilidades de la empresa (Zapata & Garrido, 1996).

El uso óptimo de los recursos y la creciente demanda de una mayor variedad de productos, entre otros, obliga a los fabricantes a realizar programas de producción más estrictos y flexibles para poder maximizar el uso de los costosos equipos de producción, mano de obra, inversiones en materias primas, de forma que se cumplan las fechas de entrega a los clientes finales minimizando los costos (Santoyo & Laguna, 2013).

El objetivo principal de los pronósticos se transforma entonces en convertirse en la entrada para el resto de los planes operativos. Para realizar eficientes programas de producción que atiendan la demanda sin incurrir en excesivos costos de capital, es deseable un adecuado manejo de la información de ventas con el fin de realizar pronósticos con buen nivel de confianza para todos los departamentos de la empresa (Santoyo & Laguna, 2013).

Debido al comportamiento no lineal que presenta un pronóstico de demanda, las redes neuronales artificiales, RNA's, son un excelente candidato para la predicción de esta estimación. Las RNA's son usadas en modelos y sistemas altamente no lineales (Azadeh, 2008). En general las RNA's son técnicas matemáticas simples diseñadas para cumplir una gran variedad de tareas. Hoy en día las RNA's pueden ser configuradas en varios arreglos para desarrollar diversas tareas, tales como, el reconocimiento de patrones, minería de datos, clasificación y predicción, entre otras (Vahidinasab, 2008). Las RNA's están compuestas de atributos que aprenden soluciones en aplicaciones donde se necesita un mapeo lineal o no

lineal. Algunos de estos atributos son: capacidad de aprender, generalización y procesamiento en paralelo, estos atributos hacen que las RNA's puedan resolver problemas complejos haciendo de esta técnica un método preciso y flexible(Santoyo & Laguna, 2013).

2.5.1. Configuración y aplicación de las Redes Neuronales Artificiales

- Topologías o tipos de conexiones.
- Número de capas.
- Número de neuronas por capa.
- Mecanismo de aprendizaje.
- Tipo de información de entrada y salida.
- Entrenamiento de la red neuronal.
- Experimentación final (Nojek, Britos, Rossi, & R., 2003).

2.6. Nivel de precisión al pronosticar con Redes Neuronales Artificiales.

Investigaciones proponen el uso de redes neuronales artificiales como herramienta eficiente de pronósticos, ya que no presentan un análisis lineal. Otra parte importante de la investigación que se ha realizado es la caracterización de los métodos para pronósticos ya que la estimación del comportamiento futuro de algunas variables puede realizarse utilizando diversos métodos de proyección de carácter especial que hace de su selección un problema de decisión influido por diversos factores, como son, la validez y disponibilidad de los datos históricos, la precisión deseada del pronóstico, y el tiempo disponible para hacer el estudio entre otros. Dentro de los métodos de pronósticos se pueden clasificar en función de su carácter, esto es, aplicando métodos de carácter cualitativo, modelos causales y modelos de series de tiempo (Nojek, Britos, Rossi, & R., 2003) (Santoyo & Laguna, 2013).

2.7. Soluciones de Ingeniería mediante *MATLAB*®.

2.7.1. Metodología para resolución de problemas de ingeniería

La resolución de problemas es una parte clave, también de los de ciencias computacionales, matemáticas, física y química. Por tanto, es importante tener una estrategia consistente para resolver los problemas. También es conveniente que la estrategia sea lo bastante general como para funcionar en todas las áreas . La técnica de resolución de problemas que presentaremos funciona para problemas de ingeniería y puede adaptarse para resolver también problemas de otras áreas; sin embargo, da por hecho que vamos a usar una computadora para ayudarnos a resolver el problema.

La metodología para resolver problemas que se usará tiene cinco pasos:

- Plantear el problema claramente (recolección de datos).
- Describir la información de entrada y de salida.
- Resolver el problema manualmente para una prueba con un conjunto de datos sencillos.
- Crear una solución *MATLAB*® (*Toolbox*).
- Probar la solución con diversos datos (Etter, 1997).

2.7.2. *MATLAB*® y su interfaz

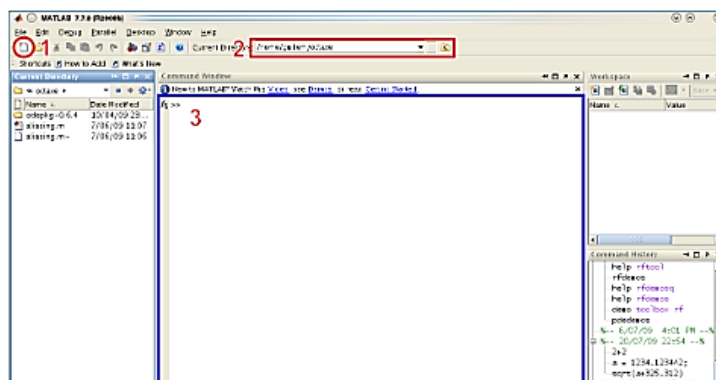


Figura 6: Interfaz gráfica de *MATLAB*®.

Fuente: (Borrell & al, 2013).

La interfaz gráfica de *MATLAB*® es prácticamente idéntica en cualquiera de sus versiones independientemente del sistema operativo.

En *la figura 6* se muestra que está dividida en apartados con una función específica. Cada uno de estos apartados, a excepción del menú, es una ventana que puede moverse dentro de la propia aplicación. Esto permite que ordenemos *MATLAB*® para ajustarlo mejor a nuestras necesidades. Las tres únicas zonas que de momento nos interesan están marcadas con un número en la imagen. El icono señalado con el número 1 significa nuevo archivo y sirve para abrir el editor de *MATLAB*®. Será nuestra herramienta de trabajo y pronto le dedicaremos una sección. El recuadro señalado con el número 2 es el diálogo para seleccionar el directorio de trabajo. A medida que vayamos escribiendo código lo guardaremos en algún lugar del ordenador. Para poder utilizarlos en un futuro es importante que *MATLAB*® sepa dónde lo hemos dejado. *MATLAB*® ya sabe, porque así viene configurado de fábrica, dónde tiene guardadas las funciones propias de la aplicación y de los distintos *toolkits* pero no sabe dónde están las que hemos escrito (Borrell & al, 2013).

2.7.3. Toolbox *MATLAB*®

MATLAB® es un paquete de software orientado hacia el *cálculo numérico e ingenieril*. Integra cálculo numérico, computación de matrices y gráficos en un entorno de trabajo cómodo para el usuario. Su nombre significa Laboratorios de Matrices y fue escrito

inicialmente en base a los ya existentes paquetes de cálculo matricial *LINPACK* y *EISPACK*. Posteriormente se han añadido librerías, denominadas *Tool boxes*, especializadas en diferentes áreas científicas. De entre ellas podemos destacar (Durana, 2004).

- *Simulink Toolbox*.
- *Control System Toolbox*.
- *System Identification Toolbox*.
- *Robust Control Toolbox*.
- *Signal Processing Toolbox*.
- *Filter Design Toolbox*.
- *Symbolic Math Toolbox*.

Por su particular interés para nuestra área de conocimiento. La última de la lista, *Symbolic Math Toolbox*, está basada en el programa de cálculo simbólico *Maple* y utiliza una sintaxis diferente (Durana, 2004).

Matlab ha evolucionado y crecido con las aportaciones de muchos usuarios. En entornos universitarios se ha convertido, junto con *Mathematica* y *Maple*, en una herramienta instructora básica para cursos de matemáticas aplicada, así como para cursos avanzados en otras áreas. En entornos industriales se utiliza para investigar y resolver problemas prácticos y cálculos de ingeniería. Son aplicaciones típicas el cálculo numérico, la realización de algoritmos, la resolución de problemas con formulación matricial, la estadística, la optimización, etc. Es de destacar la aplicación en el estudio, simulación y diseño de los sistemas dinámicos y de control (Durana, 2004).

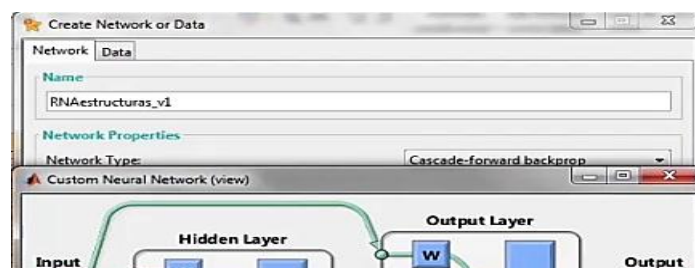


Figura 7: Interfaz gráfica *Toolbox* para Redes Neuronales Artificiales.

Fuente: (Borrell & al, 2013).

2.7.4. Redes Neuronales en *MATLAB*®

- **Redes Neuronales de base radial**

Redes neuronales de base radial podrían requerir más neuronas que las redes neuronales estándar de retropropagación. Pero su entrenamiento es similar a éstas. Trabajan mejor cuando hay muchos datos de entrenamiento disponibles.

Para la creación de la red, las redes neuronales de base radial pueden ser implementadas con cualquiera de estas dos funciones, *newrbe* y *newrb* (Rodríguez, 2015).

- **Función *newrbe***

Esta función coge una matriz de vectores de entrada y sus correspondientes salidas patrón y una constante *SPREAD*, que señala el campo de actuación de cada neurona, y devuelve una red cuyos pesos y valores umbrales son tal, que devuelve exactamente las salidas esperadas *P* para las entradas *A*. Su sintaxis en *MATLAB*® es la siguiente:

```
net = newrbe (A, P, SPREAD);
```


Esta función crea una red cuya capa de neuronas de base radial tiene un número de neuronas igual al número de entradas diferentes que se le proporciona a la red durante su entrenamiento. De esta manera cada neurona de esta capa actúa como un detector de un tipo de entrada en concreto. Se debe recalcar que la red tiene un error cero para los valores de entrada (Rodríguez, 2015).

La constante *SPREAD* es muy importante porque definirá el campo de actuación de cada neurona. Por ejemplo, si dicha constante tiene un valor cuatro, la neurona responderá con un valor 0.5 a cualquier entrada que se encuentre a una distancia euclídea de cuatro con respecto a su centro de actuación. Debe ser lo suficientemente grande para que las neuronas actúen correctamente en regiones de solapamiento. Ello provoca que la respuesta de la red sea muy suave y que tenga buena capacidad de generalización. El problema estriba, en que, si se necesitan demasiados vectores de entrada para caracterizar correctamente la red, ésta tendrá en su capa oculta demasiadas neuronas (Rodríguez, 2015)

- **Función *newrb***

Esta función se puede emplear de otra forma para generar una red más eficiente. En este método, la función crea la red de forma iterativa, creando una neurona más en cada iteración, las neuronas son añadidas hasta que el error medio cuadrático caiga por debajo del parámetro *GOAL*, o se haya alcanzado un determinado número de neuronas máximo. La sintaxis de dicha función en *Matlab* es:

```
net = newrb(P, T, GOAL, SPREAD);
```

- **Entrenamiento**

Como se ha comentado anteriormente, el entrenamiento de la red consiste en presentarle unas entradas y sus correspondientes salidas, para que la red vaya reajustando su salida

mediante la modificación de sus pesos y valores umbrales, de manera que el error de actuación de la red se minimice. Dicho valor *MATLAB*® lo almacena en la variable *net.performFcn*. La medida del error por defecto en *MATLAB*® es el error medio cuadrático, que viene dado por la ecuación:

$$E(n) = \frac{1}{N} \sum_{k=1}^N \sum_{n=1}^r (S_k(n) - Y_k(n))^2 \quad (3)$$

Para indicar que se quiere utilizar esta definición del error en *MATLAB*®, la variable *net.performFcn* debe igualarse a *mse* (en cualquier caso, este valor lo toma por defecto) (Rodríguez, 2015).

Para entrenar una red en *MATLAB*® se utiliza la función *train*. Dicha función utiliza como argumentos el nombre de la red que se quiere entrenar (y que anteriormente ha debido ser creada) y los patrones, compuestos por unos vectores de entradas (unidos en una matriz “a”) y sus correspondientes salidas (todas ellas en una matriz “p”). De esta manera la línea de código que se debería escribir es:

```
[net, pr] = train (net,a,p);
```

La variable *pr* contiene información sobre el proceso de entrenamiento y la variable *net* contiene a la red ya entrenada, es decir con sus pesos y valores umbrales ajustados (Rodríguez, 2015).

- **Método de aprendizaje totalmente supervisado**

En el aprendizaje totalmente supervisado se determinan los centros, amplitudes y pesos de tal manera que se minimice el error cometido por la red, por lo que no es de esperar que se

conservar el comportamiento local de la misma, ya que no se restringe el solapamiento de las regiones de activación de las neuronas (Rodríguez, 2015).

Para ello hay que tener en cuenta que la dependencia de la salida de la red en relación con los centros y amplitudes de las distintas neuronas de la capa oculta es no lineal, por lo que hay que emplear técnicas de optimización no lineales. A continuación, se explicará el método del descenso por el gradiente. Mediante este método obtenemos la actualización de los parámetros (centros, amplitudes y pesos) se lleva a cabo mediante las siguientes ecuaciones (Rodríguez, 2015).

$$W_{ik}(n) = W_{ik}(n - 1) - \alpha_1 \frac{\partial e(n)}{\partial w_{ik}} \quad (4)$$

$$U_k(n) = U_k(n - 1) - \alpha_2 \frac{\partial e(n)}{\partial u_k} \quad (5)$$

$$C_{ij}(n) = C_{ij}(n - 1) - \alpha_3 \frac{\partial e(n)}{\partial c_{ij}} \quad (6)$$

$$d_i(n) = d_i(n - 1) - \alpha_4 \frac{\partial e(n)}{\partial d_i} \quad (7)$$

Donde $j = 1, 2, p$, $i = 1, 2, \dots, m$, y $k = 1, 2, \dots, r$, siendo p el número de neuronas en la capa de entrada, n el número de neuronas en la capa oculta y r el número de neuronas de salida, además ∂e hace referencia a la variabilidad y cambio de la variable que opera debido al retroajuste o reentrenamiento. (Rodríguez, 2015).

- **Errores en el Pronóstico**

De acuerdo con (Zabala, 2015), para evaluar el desempeño del pronóstico (\hat{X}), se utilizarán medidas que comparan la predicción con el valor real. Estas medidas también pueden ser utilizadas para la calibración de los datos.

Para una serie $(X_n)_{t=1}^n$ de media \bar{X} , se tienen las siguientes medidas de error:

- a) Error Absoluto Medio (MAE): Indicador que entrega el promedio del error absoluto del pronóstico en toda la serie.

$$MAE = \frac{1}{n} \sum_{t=1}^T |X_t - \hat{X}| \quad (8)$$

- b) Error porcentual absoluto medio (MAPE): Indicador que entrega en promedio el error absoluto en el pronóstico de toda la serie, como porcentaje de la serie original.

$$MAPE = \frac{1}{n} \sum_{t=1}^T \left| \frac{X_t - \hat{X}}{X_t} \right| \quad (9)$$

- c) Error Porcentual Absoluto Medio Ponderado (*Weighted MAPE*): Equivalente a calcular un error MAPE, ponderado por el tamaño del error relativo al valor original.

El MAPE pondera cada error en el pronóstico por igual, independiente del nivel de los valores de la serie que se está pronosticando. WMAPE pondera cada error dependiendo del nivel de valores de la serie. WMAPE compensa el tamaño del error relativo al porcentaje del valor original.

$$WMAPE = \frac{\sum_{t=1}^T |X_t - \hat{X}| * X_t * 100}{\sum_{t=1}^T X_t} \quad (10)$$

Según (Hyndman, 2006), el indicador más recomendado para comparar modelos para una misma serie es el MAE, porque es de fácil cálculo e interpretación, además de ser una medida

objetiva para medir el desempeño de los modelos. Sin embargo, al ser escala-dependiente, hace que pierda el sentido si se quiere comparar modelos para diferentes series.

El MAPE tiene la ventaja de ser independiente de la escala, de manera que es útil para comparar modelos entre series. Sin embargo, cuando se quieren pronosticar valores pequeños, se producen errores pequeños que arrojan un gran MAPE, ya que significan un gran porcentaje del valor real. Para corregir este problema, se utiliza el WMAPE, que pondera el error por el porcentaje que representa el valor de la serie en un punto versus el valor real. Así, grandes valores del MAPE tienen poco peso si es que el nivel del valor real es bajo.

Dado lo anterior, se utilizará el WMAPE como métrica para comparar el desempeño de los modelos (Chen, Lai, & Yeh, 2012).

- **Errores Bayesianos**

Una diferencia fundamental de la inferencia Bayesiana respecto a la clásica es el carácter subjetivo (y no frecuencial) de las probabilidades, ya que no se plantea el problema de muestreo repetido ni requiere del concepto de distribución muestral. Las probabilidades subjetivas pueden definirse para cualquier proposición, mientras que la probabilidad frecuencial se define sólo para sucesos en un espacio muestral (O' Hagan & Forster, 2004).

De tal manera, el método bayesiano utiliza la información previa disponible mientras que los métodos clásicos no toman en cuenta esta información.

También existe la posibilidad de cambiar los modelos e interpretaciones a lo largo del análisis, mientras que en inferencia clásica se supone que las hipótesis y modelos se establecen antes de recoger los datos y no se cambian. Esto es poco razonable, pues dejar a

los datos “hablar por sí mismos” es una idea básica en la modelización matemática, donde asumimos que los modelos son útiles para describir los datos, pero no son exactamente iguales a los datos y por tanto sería posible cambiar de modelo a lo largo del análisis (Pruzek., 1997).

- **Ponderación BIC**

Con posterioridad a la definición del AIC, y motivado por el problema de sobrestimación que éste presenta, Akaike (1978b, 1979) elabora un nuevo criterio de especificación que denomina BIC, “Bayesian Information Criteria”. Este estadístico se obtiene al introducir en el AIC una modificación de tipo bayesiano. Se obtiene la siguiente expresión:

$$BIC(k) = \{-2 \ln(\text{máxima verosimilitud}) + \ln(N)K\} \quad (11)$$

donde N es el número total de observaciones de la muestra. Si comparamos el AIC y el BIC vemos que la diferencia básica entre ambos criterios radica en que este último penaliza más los modelos con un número mayor de parámetros estimados (debido a la sustitución del 2 por $\ln(N)$), obteniéndose así modelos de orden inferior a los obtenidos a partir del AIC y corrigiendo, por tanto, la tendencia a la sobrestimación observada (Studylib, 2019).

- **Ponderación AIC (Akaike)**

Tradicionalmente el proceso de construcción de un modelo para una serie temporal se basa en la utilización de un conjunto de pruebas de hipótesis que van a permitir ir definiendo paso a paso el modelo que mejor se ajusta. Pero los contrastes estadísticos formales pierden su significado cuando no conocemos exactamente el mecanismo que ha generado los datos, ni la forma funcional con que intervienen las variables en el modelo, ni tampoco los desfases temporales que pueden existir, además no debemos olvidar que la elección del nivel de

significación es puramente subjetiva en base a las ponderaciones, el AIC pondera (Studylib, 2019):

- a) Análisis de varianza.
- b) Regresión múltiple.

CAPÍTULO III. DIAGNÓSTICO SITUACIONAL DE LA EMPRESA

3.1. Descripción empresarial

Desde 1978 la empresa DIPAC MANTA S.A. se dedica a la importación, transformación, distribución y comercialización de productos de acero de alta calidad, lo que le ha permitido a la organización ser líder en el Ecuador, siendo una de las principales preocupaciones el servicio a las personas que se dedican a la construcción y fabricación de máquinas-herramientas. Durante más de 40 años en DIPAC MANTA S.A. se ha satisfecho la necesidad creciente del mercado de productos de acero (Naranjo, 2018).

DIPAC MANTA S.A. ha venido creciendo e implementando nuevos centros de venta a nivel nacional, iniciando su primer local en la ciudad de Manta. Actualmente cuenta con 18 locales en diferentes localidades del país de la Costa, Sierra y Oriente (Intriago Gómez, 2013).

La empresa comercializa un extenso portafolio de productos como: Perfiles, laminados en frío y caliente, galvanizados, galvalume, zinc, tubos, vigas planchas navales, calientes y frías, techos, ejes, soldadura, productos de ferretería relacionados. Adicional, DIPAC MANTA S.A brinda servicios de corte, doblado, trabajos en oxicorte, trabajos en plasma, etc (Intriago Gómez, 2013).

El tipo de negocio que DIPAC MANTA S.A. actualmente tiene en ventas, se clasifica en: 80% de artículos fabricados internamente en sus dos plantas de producción y un 20% de sus ventas en distribución, es decir, se reaprovisiona por compras, sean locales o del exterior (Intriago Gómez, 2013).

La empresa tiene una importante lista de proveedores de inventarios para stock y demás, otros que ofertan sus bienes y servicios que ayudan al complemento de las diferentes actividades que engloban el negocio de la comercialización del acero (Intriago Gómez, 2013).




Figura 8: DIPAC MANTA S.A. (Sede Ibarra).

Fuente: El autor.

En *la figura 8* podemos observar que en la parte derecha está ubicada la sala de exhibición, seguido del mesón de ventas y administración, en el lado izquierdo está ubicada la bodega donde se almacena el material para la venta, en la parte central la sede tiene un área especial para realizar los servicios de cortes, rolados y doblados en planchas de acero.

Para facilitar la labor de sus colaboradores cuenta además con centros de servicios para realizar: cortes, doblado, trabajos en oxicorte, trabajos en plasma, cortadora de ejes, etc.

La compañía se encuentra ubicada en la ciudad de Ibarra en la Av. Cristóbal de Troya y Mejía (frente a Piscina Olímpica), debido a los constantes fallos en cuanto al abastecimiento de los productos más demandados (productos estrella), las ventas se han visto afectadas considerablemente, por lo cual la sede se encuentra en un proceso de renovación estratégica para la planificación del abastecimiento.

Por otra parte, en *la figura 9* podemos ver el organigrama actual que posee la empresa.

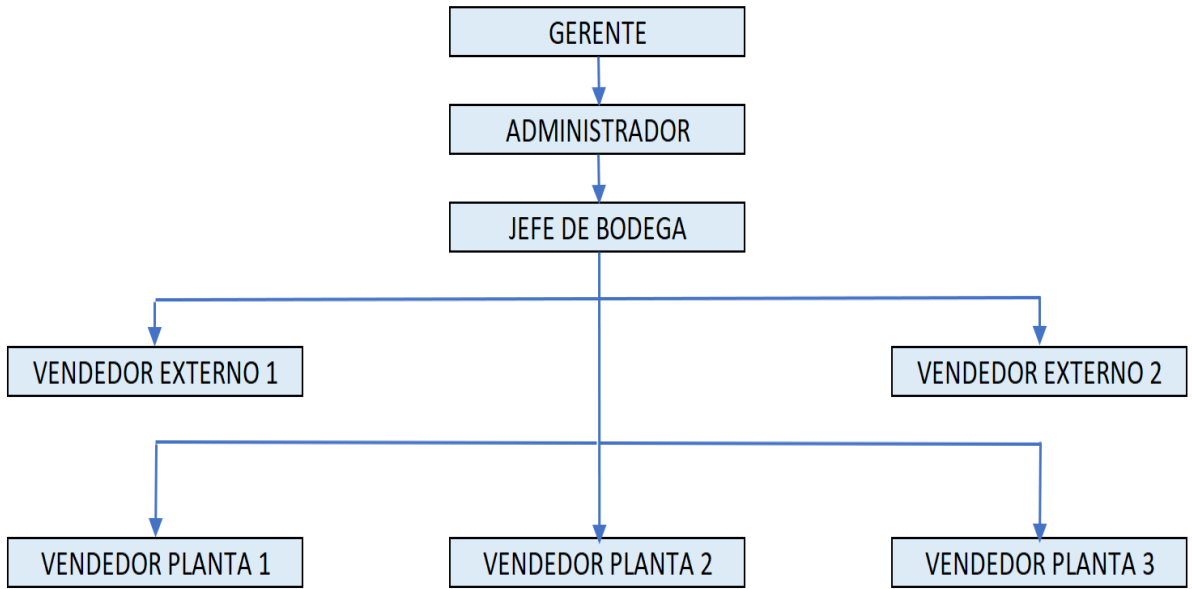


Figura 9: Organigrama DIPAC MANTA S.A. (Sede Ibarra).

Fuente: (Naranjo, 2018).

Tabla 2 : *Funciones de los puestos de trabajo DIPAC MANTA S.A. (Sede Ibarra).*

Puesto de Trabajo	Funciones
Gerente	<ul style="list-style-type: none">*Planificar, organizar, dirigir y controlar la empresa.*Enviar pedidos a planta.*Coordinar con el jefe de bodega los despachos.*Determinar y revisar el presupuesto mensual.*Cálculos elementales y digitación.
Encargada Administrativa	<ul style="list-style-type: none">*Recepción de documentos.*Atender llamadas telefónicas.*Archivos de documentos.*Cálculos elementales y digitación.* Recepción y despacho de dinero.
Vendedor Externo 1	<ul style="list-style-type: none">*Realizar labor de prospección.*Realizar visitas.*Realizar proformas y facturación.*Cálculos elementales y digitación.
Jefe de Bodega	<ul style="list-style-type: none">*Entrega y recepción de pedidos.*Cálculos elementales.*Digitación.*Atender llamadas telefónicas.

Fuente: (Naranjo, 2018).

3.1.1. Red comercial

DIPAC MANTA S.A cuenta con 18 sucursales a nivel nacional las cuales se detallan a continuación:

Manta, Portoviejo, Machala, Quevedo, Milagro, Santo Domingo, Ibarra, Loja, Cuenca, Ambato, Riobamba, Quito Norte y Sur, Guayaquil Norte y Sur, Lago Agrio y el Coca.




Figura 10: Distribución de las sedes a nivel nacional.

Fuente: (Intriago Gómez, 2013).

3.1.2. Base legal empresarial

Debido a su nivel de importancia relativa el auditor empresarial deberá abarcar las leyes, reglamentos y normas que le son aplicables a la empresa tales como:

- Ley de Compañías.
- Estatutos de la Compañía.
- Ley Orgánica del Régimen Tributario Interno.
- Reglamento de Seguridad e Higiene del trabajo.
- Normas, Políticas y procedimientos internos de la compañía.
- Normas Internacionales de Información Financiera (Intriago Gómez, 2013).

3.1.3. Estatus Social

DIPAC MANTA S.A. a través de sus 18 locales ubicados estratégicamente a nivel nacional, permite que el usuario final satisfaga sus necesidades, actualmente la empresa está dentro de las 1000 empresas más grandes del país según datos proporcionados por la revista Ekos, basados datos estadísticos proporcionados por Sistema de Rentas Internas, Superintendencia de Bancos y Seguros (Intriago Gómez, 2013).

3.1.4. Ranking Empresarial

La economía nacional muestra índices de mayor crecimiento y estabilidad en el 2018 con respecto al año anterior, las 1000 empresas más grandes del país son un ejemplo del comportamiento de la economía (Ekos, 2018).

Para el Ranking Empresarial 2018, la Revista Ekos contó con la información del Servicio de Rentas Internas (SRI), así como el de la Superintendencia de Bancos y Seguros (SBS), por lo que la información presentada garantiza consistencia con la realidad de cada una de las compañías (Ekos, 2018).

A continuación, se presenta una gráfica donde se visualiza el lugar que ocupa la empresa DIPAC MANTA S.A. con referencia a las empresas más importantes del país (Ekos, 2018).

Pos. (ventas)	Empresa	Ingresos	Utilidad	Utilidad / Ingresos
233	NETLIFE	74.043.664	3.847.084	5,00 %
234	INDUSTRIA NACIONAL DE ENSAMBLAJES S.A. INNACENSA	73.309.121	5.504.981	8,00 %
235	MIRASOL SA	73.031.569	2.695.518	4,00 %
236	FERRERO DEL ECUADOR S.A.	72.797.252	8.606.018	12,00 %
237	TERMINAL PORTUARIO DE GUAYAQUIL	72.374.814	10.259.106	14,00 %
238	PALMERAS DEL ECUADOR S.A.	72.231.401	2.723.108	4,00 %
239	COMPAÑIA FERREMUNDO S. A.	71.634.545	3.583.644	5,00 %
241	PALMERAS DE LOS ANDES S.A.	71.374.139	1.013.534	1,00 %
242	AGZULASA CIA. LTDA.	71.029.245	1.509.279	2,00 %
243	INDUSTRIAL MOLINERA C.A.	70.990.521	1.289.870	2,00 %
244	TECNOVA S.A.	70.899.823	6.450.942	9,00 %
245	Automotores de La Sierra	70.843.222	3.018.031	4,00 %
246	GUAYATUNA S.A.	70.761.078	10.507.917	15,00 %
247	CHINA INTERNATIONAL WATER & ELECTRIC CORP-CWE	70.543.623		
248	DIPAC MANTA S.A.	70.424.921	13.610.278	19,00 %
249	Devies	70.392.693	1.616.188	2,00 %
250	MEGAPROFER S. A.	70.257.440	3.937.026	6,00 %
251	TETRA PAK CIA. LTDA.	70.212.274	1.744.292	2,00 %
252	CONSTRUCTORA HERDOIZA GUERRERO S.A.	70.071.877	62.883.379	90,00 %
253	PROAUTO C.A. Grupo MEPA	69.875.728	1.063.945	2,00 %
254	CEDAL	69.774.454	226.869	0,00 %
255	SERTECPET S. A.	69.511.134	15.139.669	22,00 %

Figura 11: Top de empresas del Ecuador.

Fuente: (Ekos, 2018).

Las compañías fueron ordenadas en función a los ingresos del 2018 y en la tabla se compara con los ingresos del año 2017, se establece la variación porcentual de crecimiento, el monto pagado por impuestos y la relación entre el pago del impuesto sobre las ganancias (Ekos, 2018).

3.1.5. Composición Accionaria

La empresa DIPAC MANTA S.A. tiene como capital suscrito, pagado y autorizado.

- Capital Suscrito y Pagado \$580,800.00.
- Capital Autorizado \$580,800.00.
- Número de acciones, Valor Nominal de cada una, clase y series.
- Número de acciones: 580,800.

Valor nominal de las acciones: \$ 1.00 (UN DÓLAR DE LOS ESTADOS UNIDOS DE AMÉRICA) por cada acción.

Composición de los principales accionistas propietarios de más de diez mil por ciento de las acciones representativas del capital suscrito de la compañía, con indicación del porcentaje de su respectiva participación (Intriago Gómez, 2013).

Tabla 3: *Composición Accionaria Empresarial.*

Accionistas	%
Comercial del Norte CODENOR Internacional Limitada	99.998%
Acenor Aceros del Norte S.A.	0.002%
TOTAL	100%

Fuente: (Intriago Gómez, 2013).

Por privacidad se omite los nombres de los funcionarios de la empresa, a continuación, detallamos las jerarquías de cómo está conformada la entidad (Intriago Gómez, 2013).

Representantes Legales

- Vicepresidente.
- Gerente General.
- Gerente Comercial.
- Controlador Ecuador.
- Jefe de Planta.
- Jefe de Sistemas.

Entre otras obligaciones tributarias la compañía es contribuyente especial, por lo tanto, está obligada a llevar contabilidad y cumplir con todas las disposiciones legales que demanda el Servicio de Rentas Internas, entre las más importantes: Declaración y pago de IVA,

Impuesto a la Renta, realizar anexos transaccionales, pago anticipado de impuesto a la renta anual, etc. Además, entre las obligaciones de la compañía se encuentra también presentar anualmente los Estados Financieros en la Superintendencia de Compañías (Intriago Gómez, 2013).

3.2 Situación y entorno empresarial

3.2.1. Volumen de Operaciones

A nivel general la empresa durante el año 2018 obtuvo ventas que aumentaron en un 6.2% con respecto al año anterior, en tanto a la utilidad respecto al 2017 fue de \$9'012,204, mientras que para el 2018 es de \$13'610,278 hasta donde se registra el año contable, marcando un incremento en utilidades de \$4'598,074. Según el plan comercial de la empresa DIPAC MANTA S.A perteneciente al año 2018, el local sede Ibarra representa el 5% de participación en ventas a nivel nacional. De similar forma el promedio de clientes mensuales es de 198, como se puede observar en *la tabla 4* a continuación.

- **Población total de la empresa Sede Ibarra.**

Tabla 4: *Colaboradores de la empresa DIPAC MANTA S.A. (Sede Ibarra).*

Detalle	N°
Jefe de la Sucursal	1
Administración	1
Personal Operativo	7
Total	9

Fuente: El autor.

3.2.2. Impacto en el entorno





El mercado del acero en el Ecuador se inicia con la primera industria del acero fundada en 1969 con la compañía Andec (Acerías Nacionales del Ecuador). En la actualidad el mercado del acero en el Ecuador es manejado por varias empresas grandes y de origen extranjero como: Novacero, Ideal Alambrec, Ferrotorres, Multimetales, Ipac, Centro Acero, entre otros, las mismas que están enfocadas a satisfacer necesidades de clientes en las siguientes actividades: Constructores inmobiliarios, distribuidores ferreteros, empresas dedicadas a las estructuras metálicas, talleres metalúrgicos, cerrajeros, metal mecánicas, y en general transformadores del acero.

Las actividades de estas empresas están enfocadas a la importación, transformación y comercialización de productos derivados del acero tales como: Bobinas, Flejes, Planchas, Tubos, Rollos, Perfiles, Ángulos, Platinas. Actualmente empresas como Novacero, Adelca, Andec funde el hierro forjado de la chatarra y lo convierte en materia prima (Intriago Gómez, 2013).

Debido a que la participación en el mercado es alta y la demanda fluctúa constantemente en escala mundial, DIPAC MANTA S.A. (Sede Ibarra) ofrece a sus clientes servicios de entrega a domicilio, precios razonables, calidad en el producto, logrando con esta estrategia quitar a sus competidores los intermediarios, llegando directamente al cliente dando un servicio de calidad (Intriago Gómez, 2013).

3.2.3. Principales competidores de la industria del acero

Tabla 5: Empresas competidoras en producción y comercialización de acero.

Compañía	Ingresos de Actividades 2018
	260'551,729
	176'960,808
	70'424, 921
	98'477.729

Fuente: El autor.

3.3 Gama de productos para la comercialización

3.3.1. Distribución y comercialización

(Gallardo Hernández, 2012), señala. “La plaza o distribución, consiste en la selección de los lugares o puntos de venta en donde se venderán u ofrecerán el producto a los consumidores, así como en determinar la forma en que será trasladado hacia esos lugares”.

La distribución son actividades donde se tiene por objeto determinar los lugares o nichos de mercados, para ofertar los productos a los clientes o consumidores, además de establecer la forma de establecer los medios a utilizarse para llevar el producto en óptimas condiciones y justo a tiempo (Erazo Suárez, 2015).

(Manene, 2012), manifiesta. “La actividad de comercialización, de intercambio, es una de las primeras que llevo a cabo el ser humano. Esta actividad con el tiempo y con el aumento del número de intercambios y con su complejidad, ha ido evolucionando, tanto en la forma de entenderla, como de practicarla”.

Toda empresa compite con otras para conseguir los pedidos de los clientes. Así pues, la organización debe fundamentar su estrategia en el conocimiento del proceso que sigue el cliente para comprar. Derivado de esto se pueden considerar dos estrategias principales (Erazo Suárez, 2015):

- **Estrategias de comercialización**

Según (Gallardo Hernández, 2012), dice. “la estrategia de comercialización se refiere a la definición del conjunto de actividades relacionadas con la transferencia de bienes y servicios; desde los productos hasta el consumidor final.”

a) Estrategia pasiva:

Consiste en “esperar” que los clientes se acerquen a la organización para poder implementar con éxito debe gozar de un nombre y una reputación que le permita ser reconocida por todo el mercado (Erazo Suárez, 2015).

b) Estrategia activa:

Busca mecanismos de comercialización que va desde la creación de equipos de ejecutivos venta directa y telemarketing, hasta el uso de redes de distribución y ofrece una mayor atención al cliente más dedicada y principalmente una mayor facilidad para ofrecer productos (Erazo Suárez, 2015).

3.3.2. Proveedores externos

Son las compañías, personas naturales o jurídicas que proporcionan los recursos que necesita la empresa para su funcionamiento.

La empresa se abastece de muchos proveedores para el funcionamiento de su negocio, tanto en la producción como en la comercialización, nacional e internacional.

DIPAC MANTA S.A. (Sede Ibarra) tiene una importante lista de proveedores nacionales e internacionales a los cuales compra recurrentemente, estos proveedores son previamente calificados y autorizados por la gerencia, los cuales se enmarcan de acuerdo con los estándares establecidos, servicios y precios que requiere la compañía, a continuación, detallamos los más importantes (Intriago Gómez, 2013).

Tabla 6: *Proveedores externos de la empresa DIPAC MANTA S.A.*

Proveedores	Material que proveen
Ferrotorres	Tuberías
Novacero	Laminados
Adelca	Laminados
Ideal Alambrec	Laminados – Mallas
Ipac	Tuberías
Ferremundo	Artículos de ferretería
Promesa	Artículos de ferretería
Pinturas Unidas	Pinturas
Neirasolven	Pinturas
SIEA	Discos Abrasivos
Linde	Soldadura
Acerimallas	Mallas de cerramiento
Andipuerto Guayaquil	Servicios portuarios
Agencia Naviera Zanders	Servicios portuarios
Electrodos S.A.	Soldadura
Acero Trading Antwerp NV	Bobinas
Acerinox	Acero inoxidable
Corus	Acero, aluminio
Industria Italiana Arteferro	Cerrajerías

Fuente: (Intriago Gómez, 2013).

3.3.3. Proveedor interno

La empresa DIPAC MANTA S.A. a nivel nacional tiene como proveedor interno la matriz ubicada en la ciudad de Manta como podemos ver en *la figura 12*, la cual funciona como centro de distribución para todas las sedes o sucursales, de esta manera abastece o brinda el servicio de provisionamiento de material terminado para su posterior comercialización.



Figura 12: DIPAC MANTA S.A. Matriz Manta.

Fuente: El autor.

3.3.4. Descripción de productos

DIPAC MANTA S.A. (Sede Ibarra) posee una extensa gama de productos para abastecer la exigente demanda del mercado constructor y clientes en general, a continuación, en la *figura 13*, se puede observar la variedad de productos ofertados:

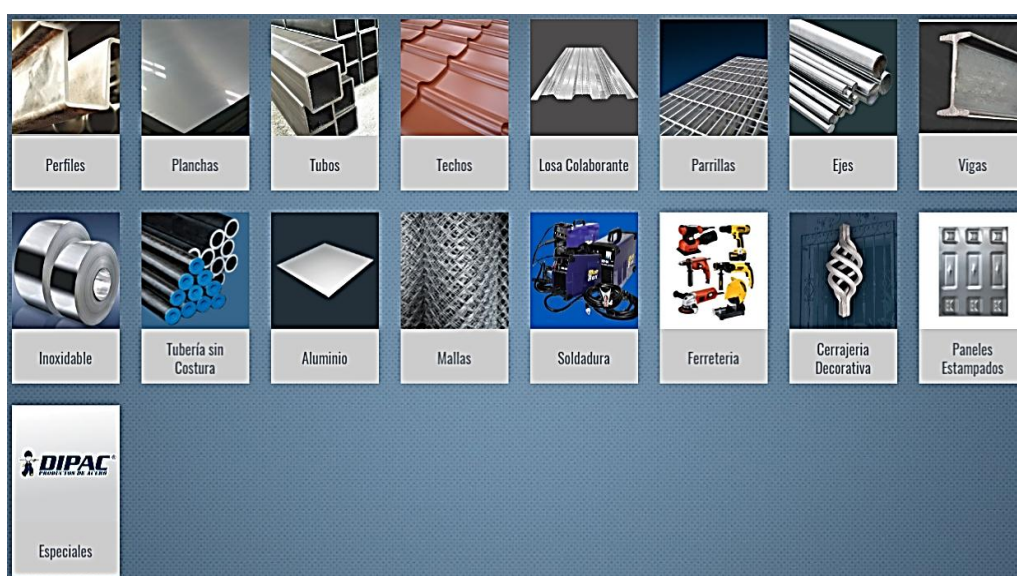


Figura 13: Gama de productos ofertados por DIPAC MANTA S.A. (Sede Ibarra).

Fuente: (DIPAC, 2018).

3.4 Productos estrella

Estos tipos de productos comienzan a mandar en su demanda el precio, ya que es lógico pensar que la capacidad instalada supera a la demandada. La capacidad ociosa baja los precios hasta que los más eficientes encuentran una nueva estabilidad, ya que nadie invierte para mejorar la eficiencia en un producto cuyo mercado está en extinción. Al quedar los más eficientes, se reacomoda el mercado y pueden llegar a concretarse acuerdos oligopólicos (Audisio, 2006) (Giraldo & Santana, 2013).

Lo fundamental en estas situaciones será vigilar continuamente las ventas y la rentabilidad, ya que ésta última será la que nos dirá cuándo salirnos del mercado. Por supuesto que en forma paralela la empresa deberá desarrollar los productos que sustituyan al que está saliendo y puede ser inteligente aprovechar la rentabilidad remanente de la salida, para posicionar lo que se denominan “*productos estrella*” (Audisio, 2006).

Los productos estrella seleccionados por su mayor peso ponderado en ventas y que gracias a ellos la sede Ibarra se ha sostenido en el tiempo son los que podemos observar en *la figura 14*:



Figura 14: Productos estrella DIPAC MANTA S.A. (Sede Ibarra).

Fuente: El autor.

3.5 Planificación y requerimientos actuales para el pronóstico

3.5.1. Capacidad estratégica empresarial

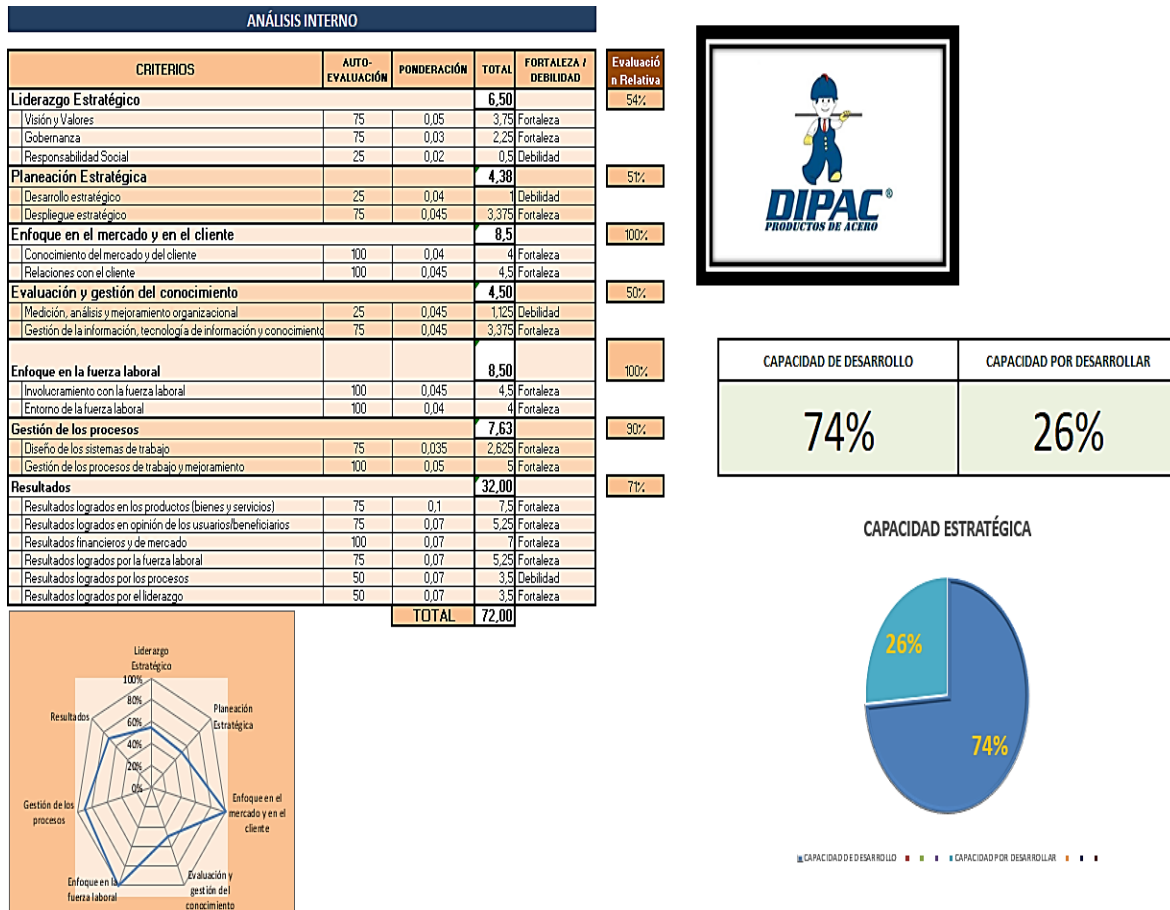


Figura 15: Capacidad estratégica de la empresa DIPAC MANTA S.A.

Fuente: El autor.

3.5.2. Cadena de Valor

En la cadena de valor de una entidad se describen las acciones y actividades que se realizan en un proceso, es decir, se analiza cada paso de las actividades específicas de cada uno de los departamentos, además es una herramienta que permite optimizar el proceso productivo, ya que en ella puede apreciarse detalladamente el funcionamiento de la compañía.

Según Ronald Ballou (2004), manifiesta que la cadena de valor se relaciona directamente al momento que agrega valor en el retorno de información del cliente hasta la materia prima o insumo inicial, como se muestra en la *figura 16* (Ballou, 2004).

Se denomina cadena de valor a las diferentes actividades que realiza el personal que conforma la entidad con el fin de producir algo, como todo proceso tiene un inicio y un final, dentro del mismo se requiere de insumos necesarios para llevar a cabo la producción y entrega al consumidor final.

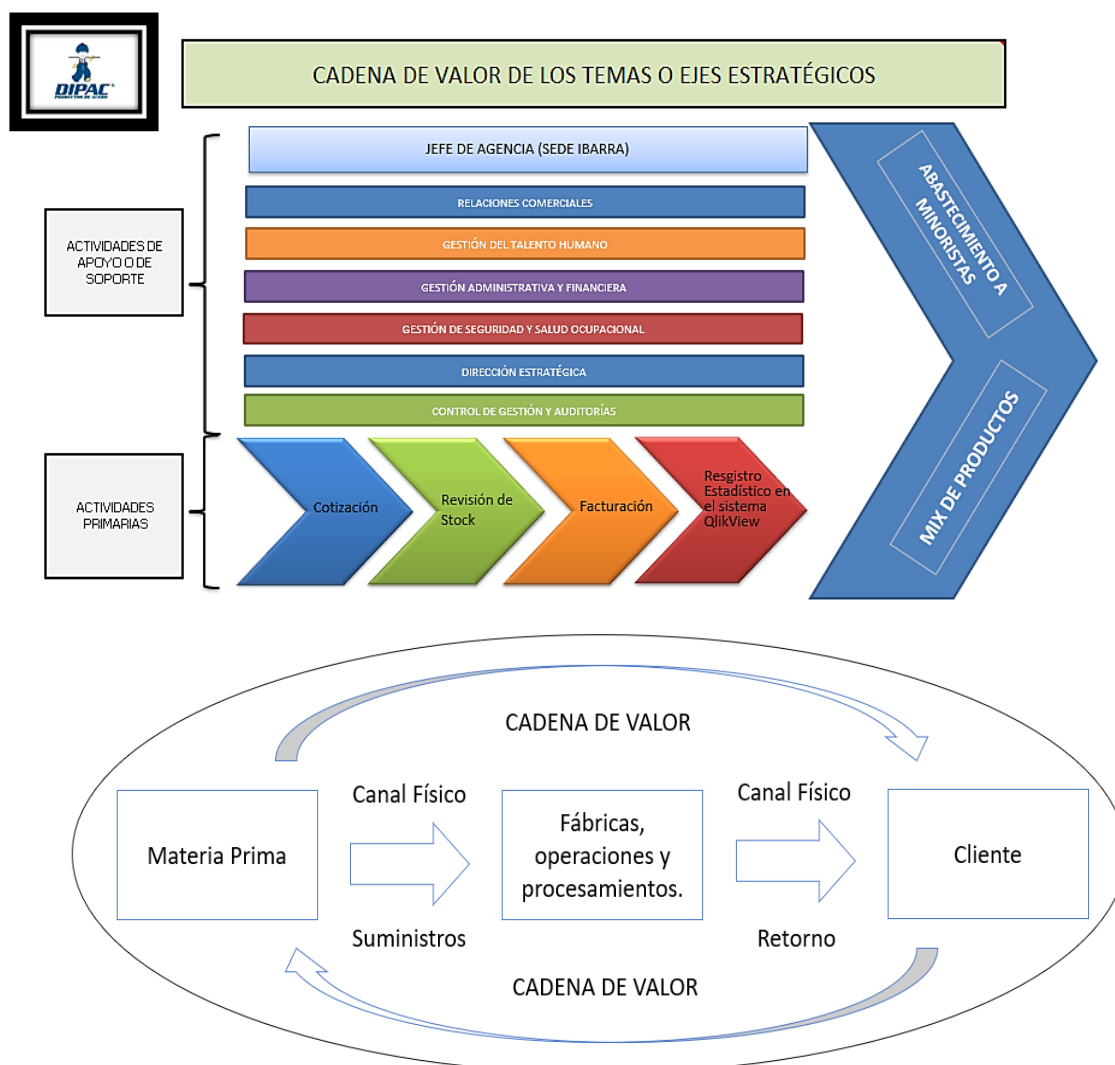


Figura 16: Relación de la cadena de suministros con la cadena de valor de la empresa DIPAC MANTA S.A.

Fuente: El autor; (Ballou, 2004).

3.5.3. Registro de ventas

A modo de ejemplo se detallará el historial de ventas del año 2018 hasta donde se valida el ciclo contable otorgado por la empresa y su departamento de ventas, a continuación, se puede observar el historial de ventas de los 3 productos estrella de la empresa:

- **Registro de ventas PRODUCTO ESTRELLA (ACCESORIOS).**

Se muestra en *la figura 17* un ejemplo de clientes de la empresa.

Nom.Vendedor	Familia Articulos	Cod. Articulo	Cant. Entregada	Kilos	Cliente
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	BBCTIP08	3	0	CABASCANGO PINEIDA ANGEL
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	BBMASC FOTO	1	1	MOSQUERA CHIMARRO LUIS FABIAN
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	BBMASC FOTO	1	1	COYAGO QUISHPE MARIA ISABEL
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	BISAGRAET10	6	1	CUAJIBOY CORTEZ EIVER IVAN
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	BISAGRAET12	5	0	BENAVIDES USIÑA CARMEN AMELIA
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	BISAGRAET58D	2	0	CARRERA MORALES OLGA
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	BISAGRAET78D	6	2	CARRERA MORALES OLGA
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	1	0	PEREZ MERO JOSE
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	1	0	CAGUA MORALES ROMAN
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	1	0	SALAS EDUARDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	2	0	SALAS LUIS
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	1	0	QUIMBIULCO ANTAMBA RICAR GERMANICO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	2	0	BENAVIDES USIÑA CARMEN AMELIA
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	2	0	QUIRANZA OSCAR ALFREDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	1	0	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR14DD	-1	-0	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR4116DD	2	0	FUERES ANRANGO JORGE EDUARDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR4116DD	4	0	QUIRANZA OSCAR ALFREDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR4116DD	20	2	FUERES ANRANGO JORGE EDUARDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR4116N	4	0	QUIRANZA OSCAR ALFREDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR4124DD	6	1	QUIRANZA OSCAR ALFREDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR4124DD	5	1	MOSQUERA CHIMARRO LUIS FABIAN
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR4124DD	3	0	SALAS EDUARDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR7116DD	5	1	HIDALGO AMAGUAÑA EDUARDO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR7116DD	1	0	CARRERA MORALES OLGA
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR7116DD	100	10	COYAGO QUISHPE MARIA ISABEL
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR7116DD	10	1	CUAJIBOY CORTEZ EIVER IVAN
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR7116DD	8	1	MORALES ZAMBRANO JOSE MARCELO
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR7116DD	1	0	COLLAGUAZO TORRES WILSON GEOVANY
ARAUJO MOSQUERA ALEJANDRO	ACCESORIOS	DISCOR7116DD	1	0	CALLIGUANGO CUASCOTA JAIME OSWALDO

Figura 17: Registro de ventas del producto estrella (accesorios).

Fuente: El autor.

- **Registro de ventas PRODUCTO ESTRELLA (PERFILERÍA).**

Se muestra en *la figura 18* un ejemplo de clientes de la empresa.

Vendedor	Familia Artículos	Cod. Artículo	Cant. Entregada	Kilos	Cliente
ARAUJO MOSQUERA ALEJANDRO	PERFILES	PEG06003018(10)	3	32	PAUCAR GAVILANEZ JONATHAN ALEXANDE
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG06003018(10)	1	11	HERFERIA GALINDO GABRIEL
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG06003018(10)	10	107	HERFERIA GALINDO GABRIEL
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG06003018(10)	8	85	EICONS CIA LTDA
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG06003018(10)	30	320	ACOSTA LOPEZ GUIDO FERNANDO
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG06003018(10)	14	150	MONJE OVIEDO ARNALDO RAUL
ERAZO CHAMORRO CARLOS XAVIER	PERFILES	PEG06003018(10)	1	11	SALTOS FERNANDEZ JUAN
ERAZO CHAMORRO CARLOS XAVIER	PERFILES	PEG06003018(10)	2	21	AYALA CABASCANGO SANDRA
ERAZO CHAMORRO CARLOS XAVIER	PERFILES	PEG06003018(10)	3	32	VASQUEZ GRAMAL LUIS HERNAN
ERAZO CHAMORRO CARLOS XAVIER	PERFILES	PEG06003018(10)	8	85	JOSE VILCA
ERAZO CHAMORRO CARLOS XAVIER	PERFILES	PEG06003018(10)	1	11	ANDRADE PUMA JUAN
ERAZO CHAMORRO CARLOS XAVIER	PERFILES	PEG06003018(10)	17	182	HERFERIA GALINDO GABRIEL
RUBIO CASTRO FABRICIO GONZALO	PERFILES	PEG06003018(10)	12	128	CONSTRUCCIONES CRANBEGAL CIA. LTDA.
ARAUJO MOSQUERA ALEJANDRO	PERFILES	PEG0600302(10)	8	96	CHASQUIZA CHUQUIN LUIS OLMEDO
ARAUJO MOSQUERA ALEJANDRO	PERFILES	PEG0600302(10)	20	239	CABASCANGO FERNANDEZ MARIA ADELA
ARAUJO MOSQUERA ALEJANDRO	PERFILES	PEG0600302(10)	20	239	CABASCANGO FERNANDEZ MARIA ADELA
ARAUJO MOSQUERA ALEJANDRO	PERFILES	PEG0600302(10)	8	96	OÑA CHICO GLORIA PATRICIA
ARAUJO MOSQUERA ALEJANDRO	PERFILES	PEG0600302(10)	5	60	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	PERFILES	PEG0600302(10)	30	358	CABASCANGO FERNANDEZ MARIA ADELA
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	1	12	MALDONADO QUINATA MILTON ROMULO
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	1	12	HERNANDEZ CASTILLO JORGE HUMBERTO
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	11	131	PAEZ JACOME MARCELO
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	14	167	HERFERIA GALINDO GABRIEL
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	3	36	ENRIQUEZ CHAVEZ JOSE
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	11	131	GUTIERREZ GUACHUN SONIA LEONDR
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	33	394	TAPIA EGAS MARGOTH DEL CONSUELO
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	7	84	TAPIA EGAS MARGOTH DEL CONSUELO
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	4	48	TORRES ANDRADE WILSON OSWALDO
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	1	12	CISNEROS TAPIA NANCY
CADENA RUJALES NADYA ESTEFANIA	PERFILES	PEG0600302(10)	4	48	SALGADO ROSERO MANUEL

Figura 18: Registro de ventas del producto estrella (perfiles).

Fuente: El autor.

- **Registro de ventas PRODUCTO ESTRELLA (TECHOS).**

Se muestra en *la figura 19* un ejemplo de clientes de la empresa.

Nom Vendedor	Familia Artículos	Cod. Artículo	Cant. Entregada	Kilos	Cliente
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	CABGUMC030	4	6	REMACHE SALAZAR JUAN CARLOS
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	CABGUML040	2	10	POZO TARUPI MARCELO JAVIER
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM3000030	1	9	PAUCAR GAVILANEZ JONATHAN ALEXANDE
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM3000030	6	52	PAUCAR GAVILANEZ JONATHAN ALEXANDE
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM3000040	1	11	ANDRADE JIMENEZ FRANKLIN ANDRES
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM3600040	15	207	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM3600040	2	28	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4000030	1	11	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4000035	12	161	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4000035	1	13	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4000040	13	199	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4000040	1	15	BAUTISTA INLAGO LUIS EDWIN
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4000040	1	15	BAUTISTA INLAGO LUIS EDWIN
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4200030	7	84	PAUCAR GAVILANEZ JONATHAN ALEXANDE
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4200040	7	113	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500035	15	226	CHICAIZA GRANDA EDGAR IVAN
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500035	5	75	CHICAIZA GRANDA EDGAR IVAN
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	3	52	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	2	34	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	4	69	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	30	517	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	40	690	FLORES AGUAS JOHN OLEGARIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	7	121	CHICAIZA GRANDA EDGAR IVAN
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	4	69	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM4500040	8	138	MUÑOZ VELASCO VICTOR ALBERTO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM5000030	5	72	CABASCANGO FERNANDEZ MARIA ADELA
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM5000040	4	77	MUÑOZ VELASCO VICTOR ALBERTO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM5000040	2	38	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM5000040	6	115	AYALA FLORES AIDA ROCIO
ARAUJO MOSQUERA ALEJANDRO	GALVALUM	DP5GUM6000025	30	431	SWINTA IZA SEGUNDO FAUSTO

Figura 19: Registro de ventas del producto estrella (techos).

Fuente: El autor.

- **AS-IS empresarial**

Mediante un análisis de diagnóstico situacional se puede analizar el comportamiento en cada una de las áreas involucradas en el pronóstico actual de la empresa, como se muestra en la figura 20.

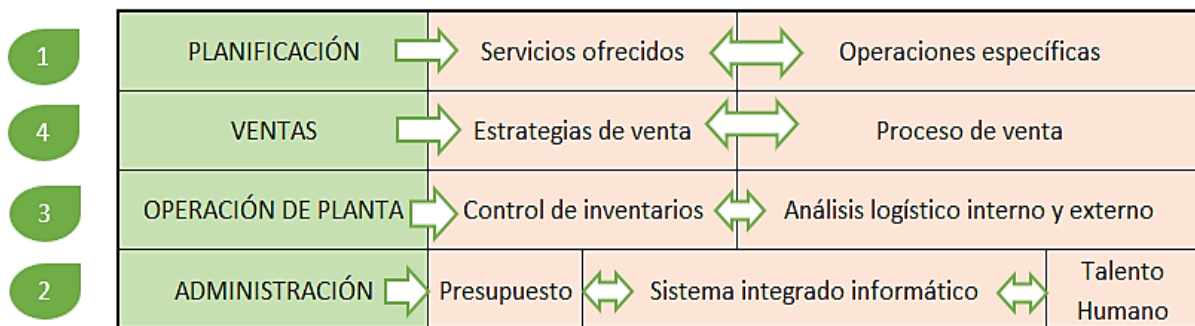


Figura 20: AS-IS empresarial.

Fuente: El autor.

CAPÍTULO IV. DESARROLLO DEL MODELO

4.1 Redes Neuronales Artificiales y su propuesta metodológica para el pronóstico

Las empresas en general se han visto inducidas a sostener un sistema muy común de provisionamiento tanto de materia prima como de artículos terminados para su posterior comercialización, hacemos referencia a un *MRP (Material Requirements Planning)*, sistema bastante común pero que en su mayoría no genera la precisión que se requiere, por lo tanto, esto obliga a los empresarios a buscar alternativas confiables o a su vez probar con nuevas herramientas que contradigan la estadística o metodologías tradicionales.

DIPAC MANTA S.A. (Sede Ibarra) se mantiene en constantes mermas en cuanto a ganancias ya que retiene mucho material para comercializar sobrepasando el tiempo que debería estar en bodega, los mismos que generan costos de almacenamiento que exceden lo presupuestado, esto ha puesto en duda la metodología tradicional usada, por ende la empresa seleccionó los productos que sobresalen sobre los otros, es decir, los productos estrellas como se mencionó anteriormente, productos elegidos en base al mayor nivel de ventas destacándose sobre los otros, mediante las Redes Neuronales Artificiales pretendemos mediante la data proporcionada por la empresa pronosticar y saber la cantidad de esos productos que debemos tener en stock para cubrir la exigente demanda de los clientes.

4.1.1. Propuesta Metodológica RNA's

La modelación será propuesta mediante el esquema mostrado en este trabajo de investigación, el cual nos plantea variables de entrada que ya han sido proporcionadas por la empresa, además de las condicionantes que son las indicadas para ponderar en cada ecuación matemática, y la red en su autonomía optará por usarla o no, seguidas de las capas ocultas y la capa que genera el resultado (Claveria & Torra, 2014).

Debido al tamaño de data a procesar es adecuado y recomendable el uso de la inteligencia artificial, ya que la retroalimentación y dependencia al procesar que genera la red neuronal no lo puede realizar la estadística tradicional o a su vez el nivel de confianza de los resultados se vería afectado, es por esto por lo que sin poner en duda se procede con el uso de esta novedosa y bastante confiable metodología para estos casos de data bastante extensa.

Como apoyo para esta investigación tenemos el *Toolbox* de *MATLAB* ®, software indicado para este tipo de investigaciones.

La principal cualidad de estos sistemas la constituye su adaptabilidad dinámica, esto es, su capacidad para variar de comportamiento en situaciones cambiantes. Para llegar a esto, utilizan técnicas como el aprendizaje, generalización o autoorganización. Están inspirados en el modelo de neurona biológica, usando unidades elementales de procesamiento que mimetizan algunas de las características de las neuronas biológicas (Raúl Pino Díez, 2001).

El comportamiento global de una red determina su capacidad para ensayar hipótesis, detectar patrones estadísticos y regularidades o ajustar dinámicamente un modelo implícito implementado en la misma arquitectura. Este comportamiento va más allá de la suma de las potencialidades de las neuronas que la componen. El resultado es la emergencia de propiedades nuevas que pertenecen al sistema como un todo (Raúl Pino Díez, 2001).

Entonces, encontramos adecuado el uso de la inteligencia artificial para brindar soluciones a la problemática empresarial ya que: *Las redes neuronales artificiales son un grupo de neuronas simuladas, que están muy interconectadas, al igual que las neuronas del cerebro humano, y que son capaces de aprender de la misma forma que lo hacen las personas* (Raúl Pino Díez, 2001).

4.2 Construcción del modelo

4.2.1. Horizonte a pronosticar

Se determina un horizonte a pronosticar de 3 años en base al nivel de entrenamiento que satisface y cumple un nivel de confianza del 95%, ya que, si se sobreentrena la red, ésta procede a sobreajustar datos mermando el nivel de confianza del pronóstico.

4.2.2. Observación de los hechos

La predicción y visualización del comportamiento de los datos, es decir, las unidades a vender y las unidades vendidas de cada producto estrella y cómo incide la predicción futura en cada uno de estos casos.

4.2.3. Selección de técnica

La mejor técnica en base a la incertidumbre tan elevada obtenida de los datos iniciales y su aleatoriedad es la herramienta alojada en el *Toolbox* de *MATLAB*®, juntamente con su algoritmo retropropagable *Levenberg Marquardt*, que mediante iteraciones y entrenamiento logra la respuesta más cercana al óptimo elegido como objetivo.

4.2.4. Desarrollo del pronóstico

Se selecciona las unidades vendidas basadas en los registros reales con los que cuenta la empresa y éstos nos permiten realizar el pronóstico, además de generar una oportuna validación mediante la comparación de los datos de las variables seleccionadas.

- **Selección de Variables**

- a) Mes.
- b) Año.
- c) Unidades Vendidas.

- **Recolección de datos:**
 - a) Unidades vendidas de ACCESORIOS (2014, 2015, 2016, 2017, 2018).
 - b) Unidades vendidas de PERFILERÍA (2014, 2015, 2016, 2017, 2018).
 - c) Unidades vendidas de TECHOS (2014, 2015, 2016, 2017, 2018).

- **Preprocesamiento de datos:**
 - a) Entradas (mes, años).
 - b) Objetivo (Unidades vendidas).

- **Definición del conjunto de entrenamiento, validación y prueba:**
 - a) Entrenamiento (70%):

El entrenamiento mediante el algoritmo de retropropagación *Levenberg Marquardt*, en base a su gran ajuste a la aleatoriedad de los datos y sobre todo a la incertidumbre encontrada en los datos, tiene como objetivo minimizar el error medio cuadrático (MSE), por sus siglas en inglés *Mean Squared Error*.

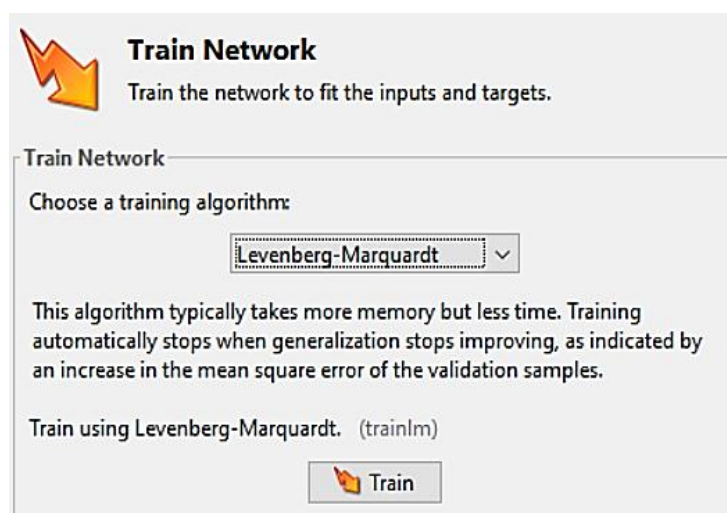


Figura 21: Entrenamiento de la red neuronal artificial.

Fuente: (MATHWORKS & MATLAB, 2015).

Además, se asigna un 70% por *default* el cual es el estándar de entrenamiento sugerido por el proceso de entrenamiento de la red neuronal, de esta manera evita la red un sobreajuste de los datos.

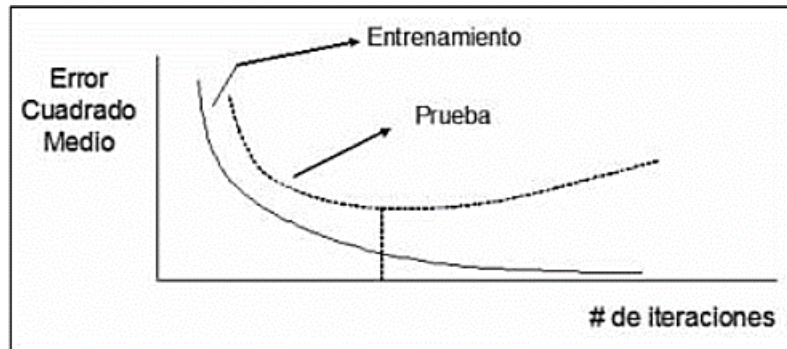


Figura 22: Punto óptimo de iteración.

Fuente: (Torres & Rivera, 2007).

- Validación (15%):

La validación se utiliza para medir la generalización de la red y para detener el entrenamiento cuando ésta considera que la generalización ha dejado de mejorar.

- Prueba (15%):

Ésta sólo se encarga de proporcionar una medida independiente del rendimiento de la red durante y después del entrenamiento.

El procesamiento de los resultados se inicia con el uso de redes neuronales. Las redes neuronales artificiales son estructuras matemáticas basadas en cerebros biológicos, que son capaces de extraer conocimiento de un conjunto de ejemplos. Se componen de una serie de elementos interconectados llamados neuronas y el conocimiento se establece en las conexiones entre las neuronas. Estas neuronas están organizadas en una serie de capas.

La capa de entrada recibe los valores de las variables que pueden condicionar el comportamiento de la demanda, la capa interna realiza las operaciones matemáticas para obtener la respuesta apropiada que muestra la capa de salida que es el comportamiento mismo. En este modelo, la salida neuronal viene dada por:

$$Y = f\left(\sum_{i=1}^n W_i X_i\right) \quad (12)$$

donde X_i es el conjunto de entradas, W_i es el peso sináptico correspondiente a cada entrada, f es la función de activación, \sum es la función de agregación, Y es la salida neuronal.

4.2.5. Arquitectura de la red neuronal

Nota: La cantidad a considerar de neuronas ocultas se logra mediante un *default mínimo* elegido como óptimo inicial por el *software*, eligiendo éste 10 neuronas que a su vez se traducen en 10 iteraciones con 10 diferentes combinaciones de ponderaciones sin sobreajustar datos ni obviar retroalimentaciones tanto lineales como no lineales.

Tabla 7: Detalle de la arquitectura de la red neuronal.

Arquitectura	Datos
Neuronas de entrada	2
Capas ocultas	1
Neuronas ocultas	10
Neuronas de salida	1

Fuente: Autor .

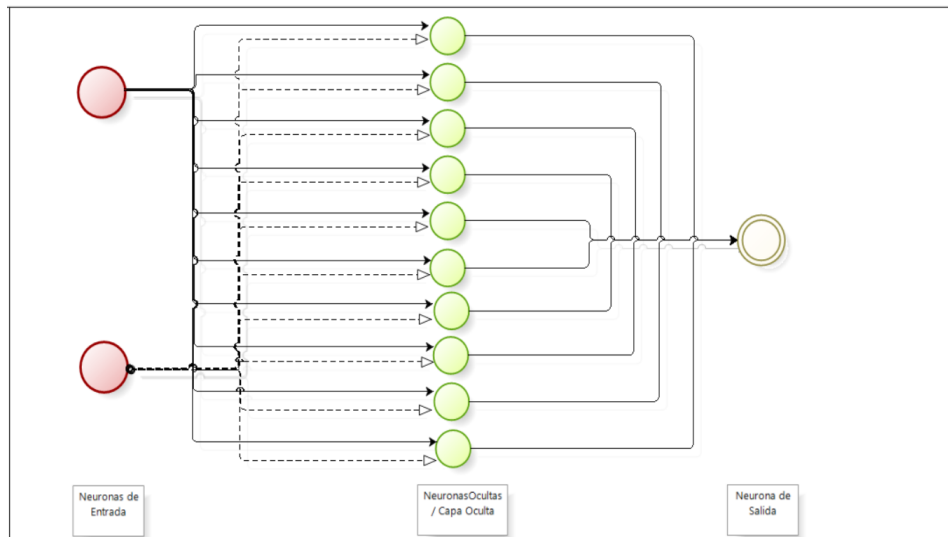


Figura 23: Construcción de Red Neuronal Artificial.

Fuente: Autor.

4.2.6. Función de transferencia

- **Capa oculta**

La capa oculta posee una función de transferencia no lineal hacia la capa de salida, así como se muestra en *la figura 24*.




Figura 24: Función de transferencia de la capa oculta.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

- **Capa de salida**

La capa de salida aplica una función de transferencia lineal hacia la salida de datos una vez que éstos han sido entrenados., así como se muestra en *la figura 25*.




Figura 25: Función de transferencia de la capa de salida.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

4.2.7. Criterios de evaluación

- **Error MSE de entrenamiento:**

Este error hace referencia a la diferencia cuadrada promedio entre salidas y objetivos, en la cual mientras más tienda hacia 0, significará que el error es más bajo y un 0 significa que no existe error entre las salidas y el objetivo buscado.

- **Error R de entrenamiento:**

Este error hace referencia a la correlación de datos entre salidas y objetivos, en la misma podemos identificar que mientras más cerca de 1 o de 100% se encuentre, ésta será una relación cercana ya que por lo contrario definiremos ésta como una relación aleatoria.

- **Error comparativo de rangos de nivel de confianza (*plotfit*):**

Es de suma importancia el análisis final del comportamiento visual de los datos para verificar que se encuentren dentro de los parámetros de confianza, como muestra *la figura 26*.




Figura 26: Comportamiento de datos entrenados dentro del nivel de confianza.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

- **Histograma de error (*ploterrhist*):**

Éste nos muestra cuales son los datos que tienen mayor afinidad o cercanía al error 0, como se muestra en *la figura 27*.




Figura 27: Histograma de errores.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

- **Rendimiento (*plotperform*):**

El rendimiento arroja la iteración en la cual se encuentra la mejor validación de rendimiento entre todas las iteraciones que se realizaron, así como se muestra en *la figura 28*.

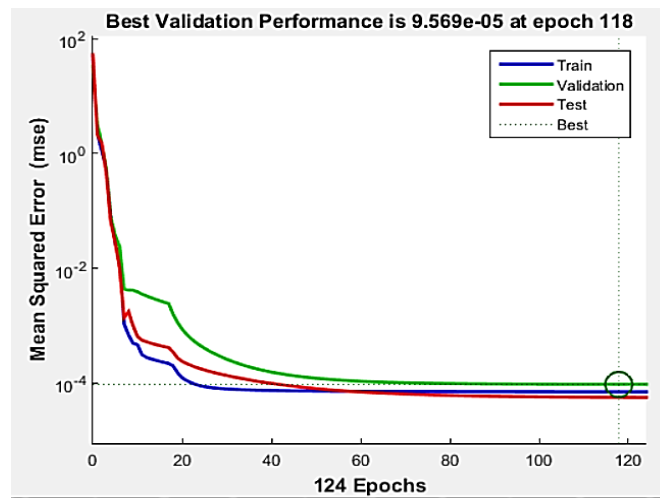
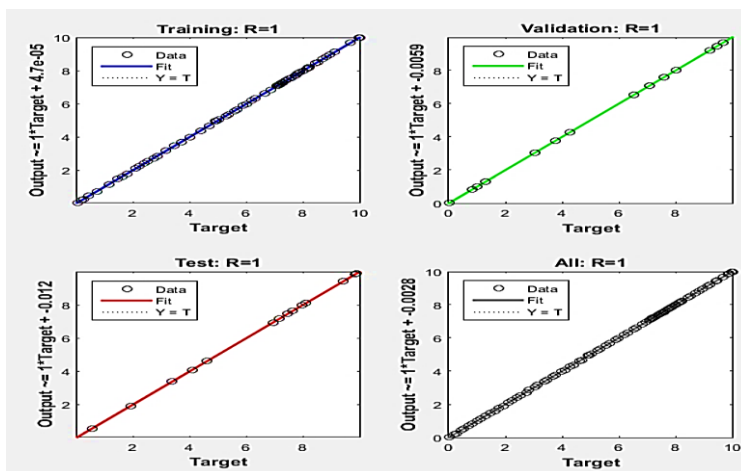


Figura 28: Relación del rendimiento entre el entrenamiento, validación y prueba.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

- **Regresión (*plotregression*):**

La característica principal de este análisis es que nos permite visualizar el comportamiento del indicador R, tanto del entrenamiento, validación, prueba y un análisis general, así como se muestra en *la figura 29*.



***Training:** Entrenamiento de la data.

***Validation:** Validación del ajuste de la data.

***Test:** Pruebas de ajuste de la data.

***All:** Ajuste general del entrenamiento, validación y pruebas.

Figura 29: Análisis de la data y su ajuste en cada etapa.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

- **Entrenamiento de las Redes Neuronales Artificiales:**

a) Número de Iteraciones.

Debido a la inteligencia artificial, autonomía, información lineal y no lineal que se autogenera dentro de la red, la cantidad de iteraciones nunca es constante, puede que, para arrojar el mejor resultado según el entrenamiento y sus retroponderaciones, las iteraciones aumenten o disminuyan.

La respuesta más acertada dependerá del indicador MSE y R^2 , en especial de la valoración más importante que viene a ser la del especialista técnico del área al considerar, si se encuentra dentro del rango aceptable el MSE y por otra parte el indicador R^2 mientras más cerca de 1 mucho mejor, ya que, de ser así podríamos decir que existe mayor relación entre la salida y el objetivo.

Es necesario mencionar que en cada iteración (*epoch*) se auto pondera cada relación que la red neuronal artificial genera, pudiendo ser estas relaciones lineales y no lineales como se ha mencionado en este capítulo. Estas relaciones arrojarán siempre diferentes resultados en diferentes instancias de iteraciones.




Figura 30: Número de iteraciones.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

b) Reentrenamiento o autoaprendizaje.

También conocido como *Deep learning/machine learning* trabaja mediante la retroponderación en cada iteración generando conexiones neuronales para encontrar los mejores resultados.

La eficiencia y precisión del aprendizaje radica únicamente en la cantidad y calidad de data y variables condicionadas que se introduzca, además de la metodología con la que se trabaje, ésta debe ser la adecuada para el caso en particular a estudiar.

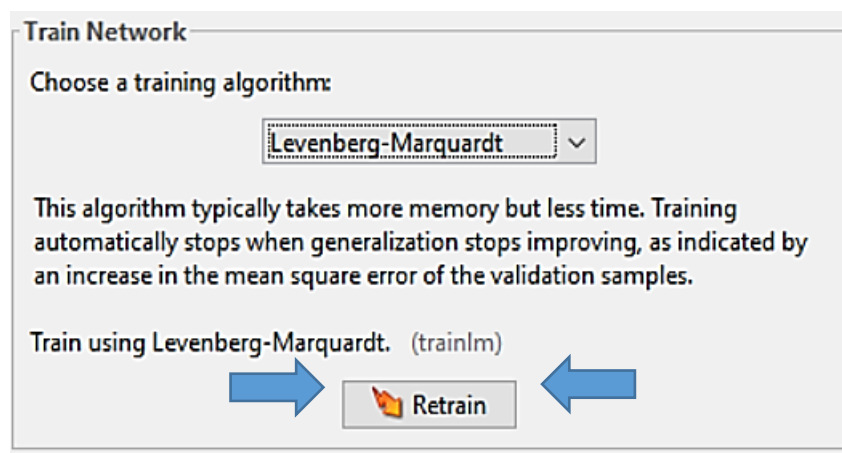


Figura 31: Reentrenamiento *Levenberg-Marquardt* de la red.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

c) Comparaciones y análisis de regularización Bayesiana (*trainbr*).

Este algoritmo generalmente toma más tiempo, pero puede resultar en una buena generalización para conjuntos de datos difíciles, pequeños o ruidosos. El entrenamiento se detiene de acuerdo con la minimización del peso adaptativo (regularización).

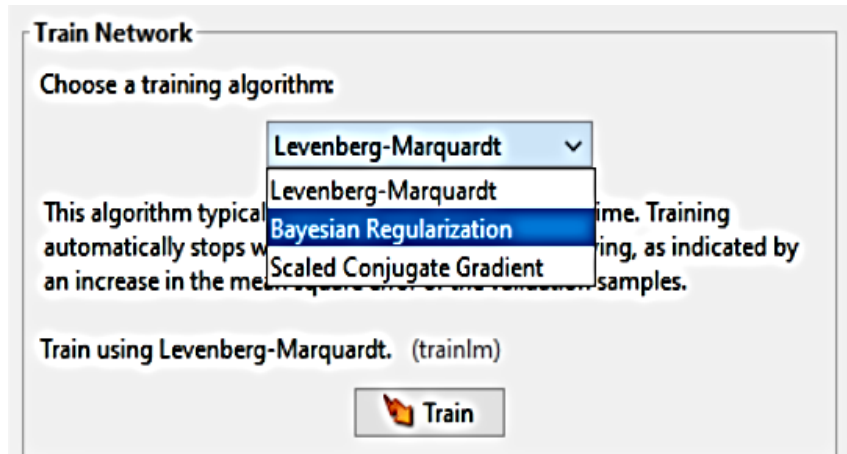


Figura 32: Reentrenamiento *Bayesian Regularization* de la red.

Fuente: (MATHWORKS & MATLAB, 2015); Autor.

- **Criterio de Información Bayesiana para modelos estadísticos exactos (BIC):**

Tanto el BIC y AIC resuelven este problema mediante la introducción de un término de penalización para el número de parámetros en el modelo, el término de penalización es mayor en el BIC que en el AIC.

La herramienta de análisis de ajuste estadístico que existe entre las variables es de suma importancia ya que nos permite conocer la relación positiva o negativa en base a las variables analizadas y su comportamiento, el criterio final se basa en las siguientes evidencias como podemos ver en *la tabla 8*:

Tabla 8: *Criterios de penalización Bayesiana.*

Evidencia para H_1	$2\log B_{10}$ (Aproximación (21))
Positivo	0 – 6
Fuerte	6 – 10
Decisivo	> 10

Fuente: (Kass & Raftery, 1995).

- **Criterio de errores Bayesianos mediante inteligencia artificial (*plotresponse*):**

Este sistema de análisis por punto nos genera información como: objetivo de entrenamiento y prueba, salida de entrenamiento y prueba, respuestas y márgenes de errores, permitiéndonos interpretar y analizar visualmente todos los resultados de errores por cada uno de los puntos de las variables asignadas al estudio de esta serie de tiempo entre las salidas y el objetivo que persigue el modelo neuronal.

Como una ayuda a la precisión del análisis y entrenamiento de la red, el *plotresponse* se apoya en el *MU reached* que es el máximo de aprendizaje posible de la red, antes de que el mismo comience a degradar y mermar la confianza del ajuste de la serie de datos.

En la *figura 33* podemos observar el análisis gráfico:




Figura 33: Relación de respuesta y errores entre la salida y objetivo.

Fuente: (MATHWORKS & MATLAB, 2015).

4.2.8. Algoritmo general del sistema

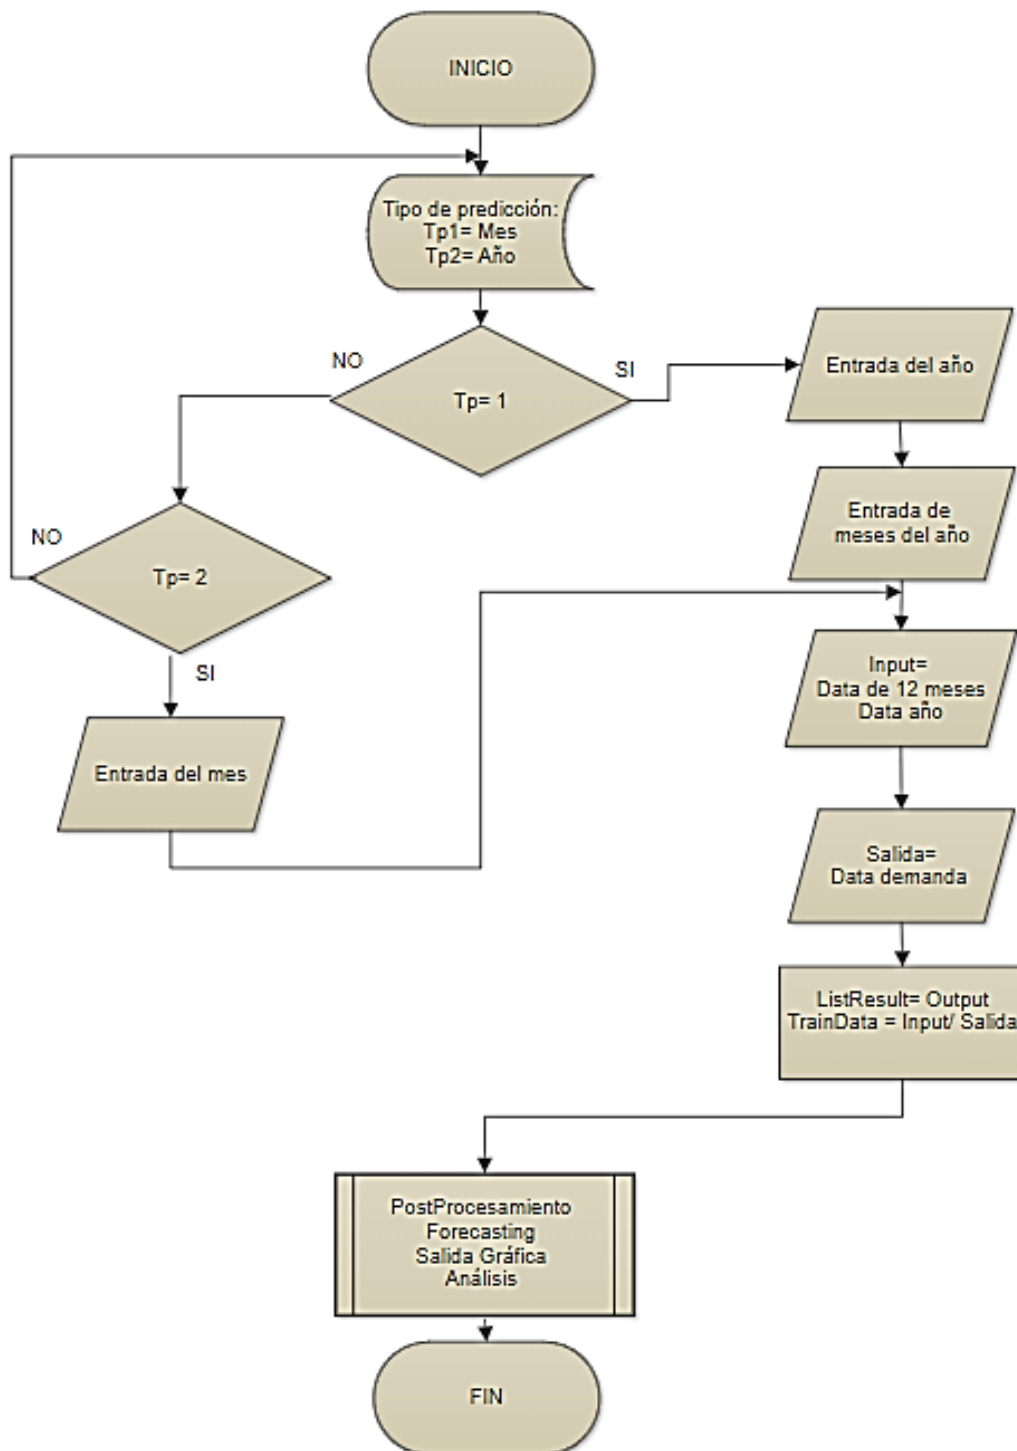


Figura 34: Flujograma del sistema.

Fuente: Autor.

Como se muestra en la *figura 34* toda la modelación mediante la secuencia del flujograma del sistema parte desde la delimitación de las variables, agregando si se desea predecir por año o por mes, posteriormente se añade la variable cuantitativa independiente demanda para el entrenamiento y su predicción, tomando en cuenta siempre el tipo de predicción (Tp) a trabajar.

CAPÍTULO V. ANÁLISIS Y COMPARACIÓN DE LOS RESULTADOS

En este apartado se interpreta y analiza todos los resultados arrojados por el modelo, proporcionando la información final, la cual es útil para la implementación y toma de decisiones de la empresa, y así obtener la mejora esperada, generando una solución al problema identificado, además de concluir la presente investigación.

Todo el análisis y evaluación se realiza en base a la data proporcionada por la empresa, es decir la demanda del año 2014 hasta 2018 de los productos estrellas: accesorios, perfilería y techos, ver anexos 1,2 y 3.

5.1. Resultados productos estrella

Mediante comparación gráfica como se observa en *las figuras 35, 36 y 37*, se representa la serie de tiempo pronosticada mediante estadística tradicional con respecto al comportamiento representado por el pronóstico mediante Redes Neuronales Artificiales.

5.1.1. Resultados Accesorios

En la tabla 9 podemos visualizar los resultados del pronóstico, tanto por redes neuronales artificiales como por estadística tradicional de los 12 periodos analizados del producto estrella *Accesorios*.

Tabla 9: Predicción de demanda para el Producto Accesorios para el año 2019 con Redes Neuronales Artificiales vs Estadística Tradicional.

Pronóstico Accesorios		
Red Neuronal Artificial	Estadística Tradicional ARIMA (1,0,12)	
enero	684	714
febrero	85	1012
marzo	537	2265
abril	1908	946
mayo	1457	946
junio	127	822
julio	161	651
agosto	1305	944
septiembre	232	837
octubre	305	1216
noviembre	550	1944
diciembre	517	1331

Fuente: Autor .

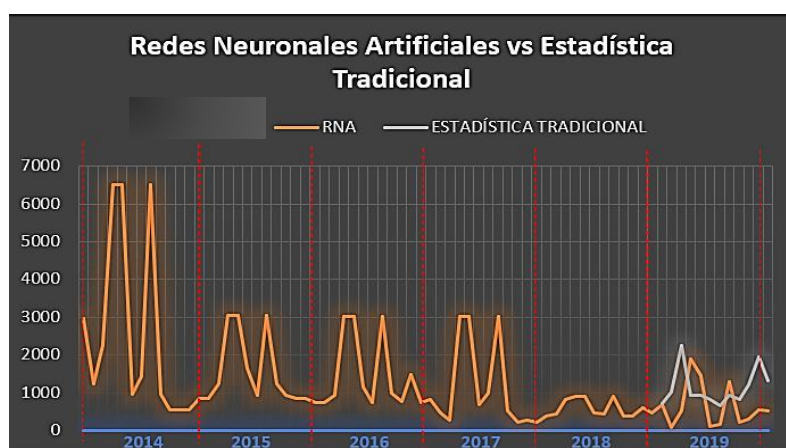


Figura 35: Comparación del pronóstico realizado en *Redes Neuronales Artificiales vs Estadística Tradicional* del producto estrella *Accesorios*.

Fuente: Autor.

5.1.2. Resultados Perfilería

En la tabla 10 podemos visualizar los resultados del pronóstico, tanto por redes neuronales artificiales como por estadística tradicional de los 12 periodos analizados del producto estrella *Perfilería*.

Tabla 10: Predicción de demanda para el Producto *Perfilería* para el año 2019 con Redes Neuronales Artificiales vs Estadística Tradicional.

Pronóstico Perfilería		
	Red Neuronal Artificial	Estadística Tradicional ARIMA (1,0,12)
enero	546	440
febrero	520	520
marzo	531	470
abril	559	479
mayo	564	410
junio	553	464
julio	542	481
agosto	540	498
septiembre	551	436
octubre	566	502
noviembre	498	523
diciembre	446	546

Fuente: Autor.




Figura 36: Comparación del pronóstico realizado en *Redes Neuronales Artificiales vs Estadística Tradicional* del producto estrella *Perfilería*.

Fuente: Autor.

5.1.3. Resultados Techos

En la tabla 11 podemos visualizar los resultados del pronóstico, tanto por redes neuronales artificiales como por estadística tradicional de los 12 periodos analizados del producto estrella *Perfilería*.

Tabla 11: Predicción de demanda para el Producto Techos para el año 2019 con Redes Neuronales Artificiales vs Estadística Tradicional.

Pronóstico Techos		
	Red Neuronal Artificial	Estadística Tradicional ARIMA (1,0,12)
enero	831	258
febrero	733	152
marzo	691	238
abril	722	232
mayo	696	361
junio	607	227
julio	507	241
agosto	465	262
septiembre	511	276
octubre	551	245
noviembre	459	183
diciembre	362	137

Fuente: Autor.




Figura 37: Comparación del pronóstico realizado en *Redes Neuronales Artificiales vs Estadística Tradicional* del producto estrella Techos.

Fuente: Autor.

5.2. Comparación de resultados

El modelo a usar para el método estadístico exacto es ARIMA (1, 0, 12), el cual significa que se está describiendo alguna variable de respuesta (Y) al combinar un modelo de regresión automática de primer orden y un modelo de media móvil de orden 12, debido a que se trabaja mensualmente. Una buena manera de pensarlo es (AR, I, MA) (Tiwari & Adamowsk, 2013).

El 0 entre el 1 y el 12 representa la parte 'I' del modelo (la parte Integrativa) y significa un modelo en el que se tomó la diferencia entre los datos de la variable de respuesta. Esto se puede hacer con datos no estacionarios.

La prueba de análisis estadístico es *Ljung-Box*, ya que se ajusta a estos modelos de serie de tiempo y a su aleatoriedad, por otra parte no podemos usar la prueba de *Durbin-Watson* ya que se recomienda para modelos con más de 1 retraso y no se ajustaría al modelo actual ya que el análisis de *Ljung-Box* lo hace en base a 1 sólo retraso, la prueba de *Wald-Wolfowitz* tampoco se recomienda ya que no cumple con 2 parámetros característicos de esta prueba, los cuales hacen mención a la comparación de 2 variables y en este modelo se analiza 1 sola variable, el segundo parámetro es la comprobación de su independencia, lo cual no se puede comprobar ya que el modelo sólo cuenta con 1 variable.

Se comparó los 2 tipos de errores principales donde tenemos el Error Cuadrático Medio (MSE) y el error R^2 , el MSE se delimitó en un rango de 0% a ∞ , es decir que mientras más pequeño es el MSE más se ajusta el estimador a los datos reales, por otra parte, el R^2 se delimitó en un rango de 0 a 1, siendo 1 el óptimo (Correa & Figueroa, 2016).

5.2.1. Comparación Accesorios

Results			
	Target Values	MSE	R
Training:	54	25794.51143e-0	9.94259e-1
Validation:	3	0.00000e-0	0.00000e-0
Testing:	3	830699.51712e-0	9.99921e-1

Figura 38: Resultados de errores arrojados del análisis de datos por la Red Neuronal Artificial en el producto estrella Accesorios.

Fuente: Autor.

Modelo	Número de predictores	Estadísticos de ajuste del modelo					Ljung-Box Q(18)			Número de valores atípicos	
		R cuadrado	RMSE	MAPE	MAE	MaxAPE	BIC normalizado	Estadísticos	DF		Sig.
UNIDADES VENDIDAS-Modelo_1	0	,268	1283,346	66,848	775,227	253,575	14,519	12,220	16	,729	0

Figura 39: Resultados de errores arrojados del análisis estadístico tradicional en el producto estrella Accesorios.

Fuente: Autor.

Tabla 12: Evaluación de indicadores de errores para el Producto Accesorios.

Evaluación de errores		
	M.S.E. (0% - ∞)	R ² (0 - 1)
Estadística Tradicional	16,5%	0,27
Red Neuronal Artificial	0,3%	0,99

Fuente: Autor .

A partir de la evaluación de los errores se puede evidenciar la valía de las Redes Neuronales Artificiales al mostrar ventaja en el resultado de los errores probados, teniendo una ventaja notoria con una diferencia de 16,2% en el *M.S.E.* y 0,72 en el *R²*.

5.2.2. Comparación Perfilería

Results			
	Target Values	MSE	R
Training:	54	5030.38537e-0	9.94431e-1
Validation:	3	0.00000e-0	0.00000e-0
Testing:	3	215673.31393e-0	9.95832e-1

Figura 40: Resultados de errores arrojados del análisis de datos por la Red Neuronal Artificial en el producto estrella Perfilería.

Fuente: Autor.

Modelo	Número de predictores	Estadísticos de ajuste del modelo					Ljung-Box Q(18)			Número de valores atípicos	
		R cuadrado	RMSE	MAPE	MAE	MaxAPE	BIC normalizado	Estadísticos	DF		Sig.
UNIDADES VENDIDAS-Modelo_1	1	,943	182,932	8,271	123,003	45,449	11,510	3,724	5	,590	1

Figura 41: Resultados de errores arrojados del análisis estadístico tradicional en el producto estrella Perfilería.

Fuente: Autor.

Tabla 13: Evaluación de indicadores de errores para el Producto Perfilería.

Evaluación de errores		
	M.S.E. (0% - ∞)	R ² (0 - 1)
Estadística Tradicional	0,3%	0,94
Red Neuronal Artificial	0,05%	0,99

Fuente: Autor .

Con la evaluación de los errores se puede observar superioridad de las Redes Neuronales Artificiales en el resultado de los errores probados, teniendo una ventaja notoria con una diferencia de 0,25% en el *M.S.E.* y 0,05 en el *R²*.

5.2.3. Comparación Techos

Results			
	Target Values	MSE	R
Training:	54	5614.10896e-0	9.86363e-1
Validation:	3	0.00000e-0	0.00000e-0
Testing:	3	2279.02982e-0	9.99504e-1

Figura 42: Resultados de errores arrojados del análisis de datos por la Red Neuronal Artificial en el producto estrella Techos.

Fuente: Autor.

Modelo	Número de predictores	Estadísticos de ajuste del modelo					Ljung-Box Q(18)			Número de valores atípicos	
		R cuadrado	RMSE	MAPE	MAE	MaxAPE	BIC normalizado	Estadísticos	DF		Sig.
UNIDADES VENDIDAS-Modelo_1	1	,894	171,015	11,026	116,501	66,194	11,307	3,536	5	,618	0

Figura 43: Resultados de errores arrojados del análisis estadístico tradicional en el producto estrella Techos.

Fuente: Autor.

Tabla 14: Evaluación de indicadores de errores para el Producto Techos.

Evaluación de errores		
	M.S.E. (0% - ∞)	R ² (0 - 1)
Estadística Tradicional	0,3%	0,89
Red Neuronal Artificial	0,06%	0,99

Fuente: Autor .

Una vez realizada la evaluación de los errores se puede evidenciar que las Redes Neuronales Artificiales muestran una ventaja considerable en el resultado de los errores probados, teniendo una ventaja notoria con una diferencia de 0,24% en el *M.S.E.* y 0,10 en el *R²*.

CONCLUSIONES

- Con la revisión de las técnicas y algoritmos empleados en el pronóstico de la demanda se obtuvo la fundamentación necesaria para la modelización inicial de la estructura neuronal.
- Con la ayuda de las redes neuronales artificiales se diagnosticó el comportamiento de la demanda de los 3 productos estrellas de la empresa, teniendo como resultado el comportamiento real de la demanda y de la planificación actual.
- Se construyó el modelo de red neuronal artificial para el pronóstico de la demanda de la empresa.
- Con la comparación de la data pronosticada mediante redes neuronales artificiales y estadística tradicional, se demostró la validez mediante indicadores de error y la eficiencia que posee el modelo a la hora de pronosticar mediante redes neuronales artificiales.

RECOMENDACIONES

- Realizar una profunda revisión bibliográfica para una adecuada contextualización y fundamentación del diseño y construcción del modelo.
- Es recomendable partir de un alcance bien definido de evaluación o diagnóstico situacional de la empresa y la solución a brindar.
- Generar variables bien definidas y un exhaustivo entrenamiento de la red neuronal artificial, adecuando la misma hacia la planificación y toma de decisiones.
- Validar los resultados que arroja la red neuronal artificial, se recomienda realizar la comparación de resultados con otra metodología que emplee métodos exactos tradicionales.

REFERENCIAS BIBLIOGRÁFICAS

- Adamowski, J., & Karapataki, C. (2010). Comparison of Multivariate Regression and Artificial Neural Networks for Peak Urban Water-Demand Forecasting: Evaluation of Different ANN Learning Algorithms.
- Aguilar, M. A., & Ríos, M. C. (2007). Pronóstico de Demanda por medio de redes neuronales artificiales. División de Posgrado en Ingeniería de Sistemas, FIME-UANL, 12.
- Aluja, T. (2001). La minería de datos, entre la estadística y la inteligencia artificial. *QUESTIÓ*, p. 479-498.
- Audisio, N. J. (2006). Gestión por beneficios. Editorial Brujas.
- Ballou, R. H. (2004). Logística. Administración de la cadena de suministro. México: Pearson Educación.
- Borrell, G., & al, N. e. (2013). Matemáticas en Ingeniería con Matlaby Octave.
- Cabrera Ríos, M. S. (2010). Artificial Neural Networks for Demand Forecasting. En *Planeación de la Producción*.
- Chen, C.-F., Lai, M.-C., & Yeh, C.-C. (2012). Forecasting tourism demand based on empirical mode decomposition and neural network. *Knowledge-Based Systems*.
- Claveria, O., & Torra, S. (2014). Forecasting tourism demand to Catalonia: Neural networks vs. time series model. *Economic Modelling*.
- Correa, J. V., & Figueroa, P. N. (2016). VALIDACIÓN DE MEDIDAS DE EVALUACIÓN PARA EL PRONÓSTICO DE LA TASA DE CAMBIO EN COLOMBIA. Bogotá:

Colegio de Estudios Superiores de Administración –CESA–Maestría en Finanzas Corporativas.

DIPAC. (2018). DIPAC MANTA S.A. Obtenido de <http://www.dipacmanta.com/>

Durana, J. d. (2004). Introducción a MATLAB.

Ekos, R. (22 de Noviembre de 2018). EKOS NEGOCIOS. Obtenido de <http://www.ekosnegocios.com/empresas/RankingEcuador.aspx>

Eppen. (2015 - 1989). Modelos y Métodos para la Planificación de la Producción de la Cadena de Suministro en un entorno de incertidumbre. Aplicación al sector del automóvil. . Vigo.

Erazo Suárez, J. N. (2015). Manual administrativo para la empresa distribuidora y comercializadora de productos de acerp “DIPAC”, en la ciudad de Ibarra, provincia de Imbabura. Ibarra: Universidad Técnica del Norte.

Etter, D. M. (1997). Soluciones de problemas de ingeniería con MATLAB. Monterrey: Prentice Hall.

Ghiassi, M., Zimbra, D. K., & Saidane, H. (2008). Urban Water Demand Forecasting with a Dynamic Artificial Neural Network Model.

Giraldo, G. A., & Santana, E. R. (2013). Metodología para el pronóstico de la demanda en ambientes multiproducto y de alta variabilidad. Universidad Distrital Francisco José de Caldas.

Hanke, J. E., & Wichern, D. W. (2006). Pronósticos en los negocios. Pearson Educación.

Hyndman. (2006). Another look at forecast: Accuracy Metrics for Intermittent Demand. Australia: Monash University.

- Intriago Gómez, D. M. (2013). Examen de auditoría integral al área administrativa del local Guayaquil norte de la empresa Dipac Manta S.A año 2013. Guayaquil: UTPL.
- J. de J. Rubio, M. I. (2017). A Fuzzy Algorithm for the Prediction of Future Data . IEEE LATIN AMERICA TRANSACTIONS, VOL. 15, NO. 8,.
- Josefa Mula Bru1, R. P. (2004). Aplicaciones de la Teoría de los Conjuntos Difusos en la Planificación de la Producción: Un Estudio de la Literatura. VIII Congreso de Ingeniería de Organización, 9.
- Kass, R. E., & Raftery, A. E. (1995). Bayes Factors. Journal of the American Statistical Association is currently published by American Statistical Association.
- MATHWORKS, & MATLAB. (2015). <https://la.mathworks.com/products/matlab.html>.
Obtenido de <https://la.mathworks.com/products/matlab.html>
- Naranjo, I. L. (2018). “Discomfort lumínico y su incidencia en las afecciones visuales en los puestos de trabajo del área administrativa de la empresa DIPAC MANTA S.A.”. Ambato: Universidad Técnica de Ambato.
- Neto, A. H., & Fiorelli, F. A. (2008). Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. Energy and Buildings.
- Nojek, S., Britos, P., Rossi, B., & R., G. M. (2003). Pronóstico de Ventas: Comparación de Predicción basada en Redes Neuronales versus Método Estadístico. Buenos Aires.
- O´ Hagan, A., & Forster, J. (2004). Bayesian Inference. Kendall’s Advanced Theory of Statistics. . London.

- Pandian, a. e. (2002). Uso de la programación lineal paramétrica en la solución de un problema de planeación de requerimiento de materiales bajo condiciones de incertidumbre. En C. A. Martín Darío Arango Serna¹, Ingeniería e Investigación, Vol 30, No 3 (2010).
- Pruzek. (1997). An introduction to bayesian inference and its applications. En L. L. Harlow, S. A. Mulaik y J. H. Steiger (Eds.). What if there were no significance tests? (pp. 287-318). Mahwah: NJ: Lawrence Erlbaum.
- PWC. (2011). “Optimizar la cadena de abastecimiento y distribución con comunicación y visibilidad”. Obtenido de <https://www.pwc.com/cl/es/eventos/assets/optimizacion-de-la-cadena-con-comuni-y-visi.pdf>
- Ramírez, G., Torné, M., & Cabrera, J. O. (2012). PROGRAMACIÓN DE OPERACIONES PARA EL LLENADO DE TOLVAS DOSIFICADORAS EN UNA EMPRESA DE CONCENTRADOS. Revista Ingenierías Universidad de Medellín.
- Raúl Pino Díez, A. G. (2001). Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva. Universidad de Oviedo.
- Rodríguez, A. M. (2015). “Desarrollo de una interfaz gráfica de redes neuronales usando Matlab”. Madrid.
- Santoyo, E. A., & Laguna, J. A. (2013). Comparación de predicción basada en redes neuronales con métodos estadísticos en el pronóstico de ventas. Ingeniería Industrial. Actualidad y Nuevas Tendencias.
- Shapiro, K. y. (2002). Gestión de la Producción.

Studylib. (2019). www.studylib.es. Obtenido de <https://studylib.es/doc/7992691/modelizaci%C3%B3n-de-un-proceso-setar>.

Tiwari, M. K., & Adamowsk, J. (2013). Urban water demand forecasting and uncertainty assessment using ensemble wavelet-bootstrap-neural network models. *WATER RESOURCES RESEARCH*, VOL. 49,, 6486–6507.

Torres, J. A., & Rivera, J. A. (2007). Entrenamiento de una red neuronal multicapa para la tasa de cambio euro - dólar (EUR/USD). *SCIELO*.

Vallabhaneni, S. R. (2018). *Wiley CIAexcel Exam Review 2018, Part 3: Internal Audit Knowledge Elements, Parte 3*. John Wiley & Sons.

Zabala. (2015). *Pronóstico de demanda desagregado para una empresa de productos de consumo masivo (Tesis pregrado)*. Chile.

Zadeh, B. (2002). Teoría de los conjuntos difusos (fuzzy sets). En *Modelos y Métodos para la Planificación de la Producción de la Cadena de Suministros*.

Zapata, J. A., & Garrido, A. (1996). *MODELO DE PRONÓSTICO DE LA DEMANDA PARA LA UNIDAD DE NEGOCIO LABORATORIO FARMACOOOP*. Ecuación EPM, Fuente Jhon, E. Hanke. Arthur, G. Reitsch. *Pronóstico en los Negocios*, 5ta. Edición,.

ANEXOS

ANEXO 1: Demanda mensual de 5 años del producto estrella Accesorios.

Año \ Mes	MUESTRA INICIAL - DEMANDA ACCESORIOS											
	enero	febrero	marzo	abril	mayo	junio	julio	agosto	septiembre	octubre	noviembre	diciembre
2014	2976	1245	2250	6513	6513	978	1432	6513	963	562	562	562
2015	860	860	1245	3049	3049	1659	943	3049	1247	945	860	860
2016	759	742	945	3035	3035	1163	742	3035	1005	785	1475	742
2017	835	468	295	3032	3032	687	1002	3032	541	235	285	235
2018	398	456	832	923	923	469	451	923	398	398	598	467

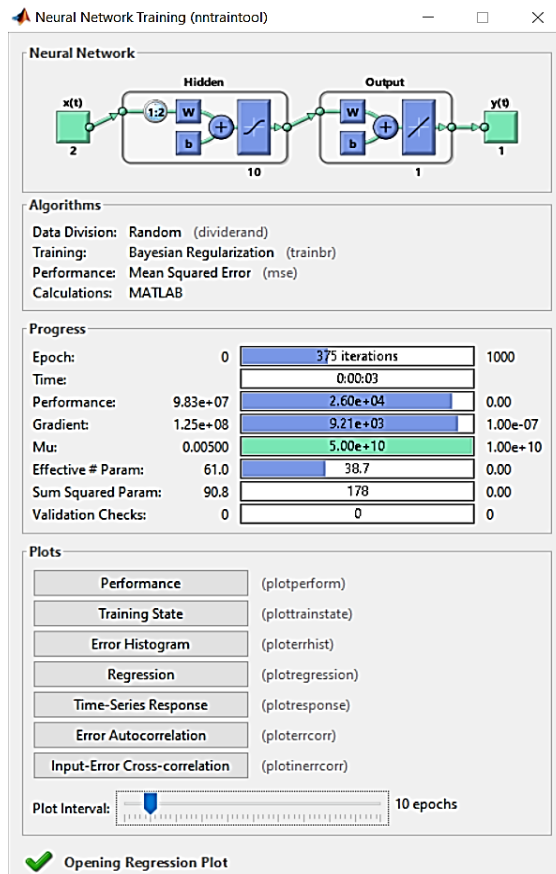
ANEXO 2: Demanda mensual de 5 años del producto estrella Perfilería.

Año \ Mes	MUESTRA INICIAL - DEMANDA PERFILERÍA											
	enero	febrero	marzo	abril	mayo	junio	julio	agosto	septiembre	octubre	noviembre	diciembre
2014	2068	2063	2394	2213	2256	2246	2107	2330	2341	2264	2209	2321
2015	1731	1777	1657	1621	1920	1624	1744	1787	1648	1660	1634	2078
2016	1846	1798	1643	1915	1994	1925	2005	2015	1998	1891	1798	1681
2017	2237	2152	2098	2331	2312	2381	2624	2489	2156	2265	2605	2392
2018	587	496	601	551	524	489	548	579	497	602	583	405

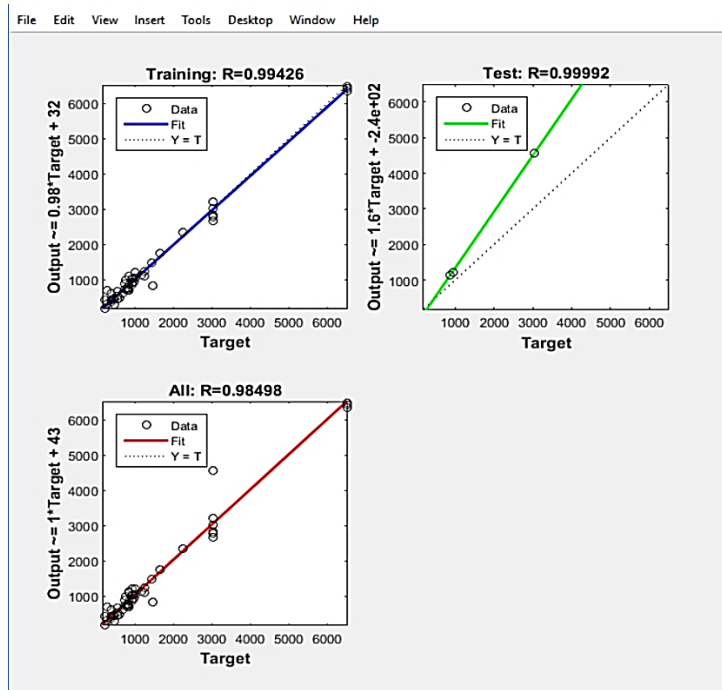
ANEXO 3: Demanda mensual de 5 años del producto estrella Techos.

Año \ Mes	MUESTRA INICIAL - DEMANDA TECHOS											
	enero	febrero	marzo	abril	mayo	junio	julio	agosto	septiembre	octubre	noviembre	diciembre
2014	1864	1772	1861	1870	1624	1601	1812	1899	2016	2011	2123	2073
2015	1244	1388	1225	1442	1194	1541	1533	1340	1496	1564	1182	1425
2016	1189	1245	1108	1139	1157	1302	1297	1460	1369	1458	1294	1349
2017	1036	1089	1167	1217	1094	1176	1099	1284	1005	1187	1108	1126
2018	549	481	505	518	579	399	476	603	548	586	475	403


ANEXO 4: Iteraciones óptimas de entrenamiento del producto estrella Accesorios.



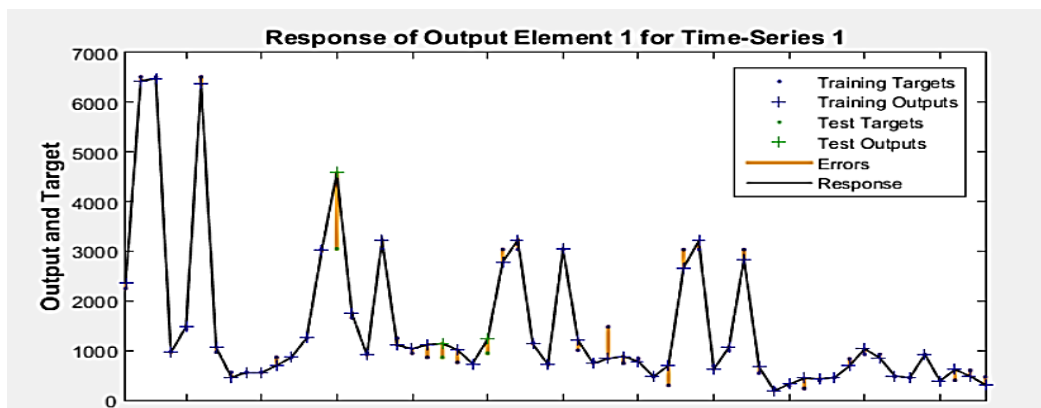
ANEXO 5: Comportamiento del ajuste de los datos del producto estrella Accesorios.



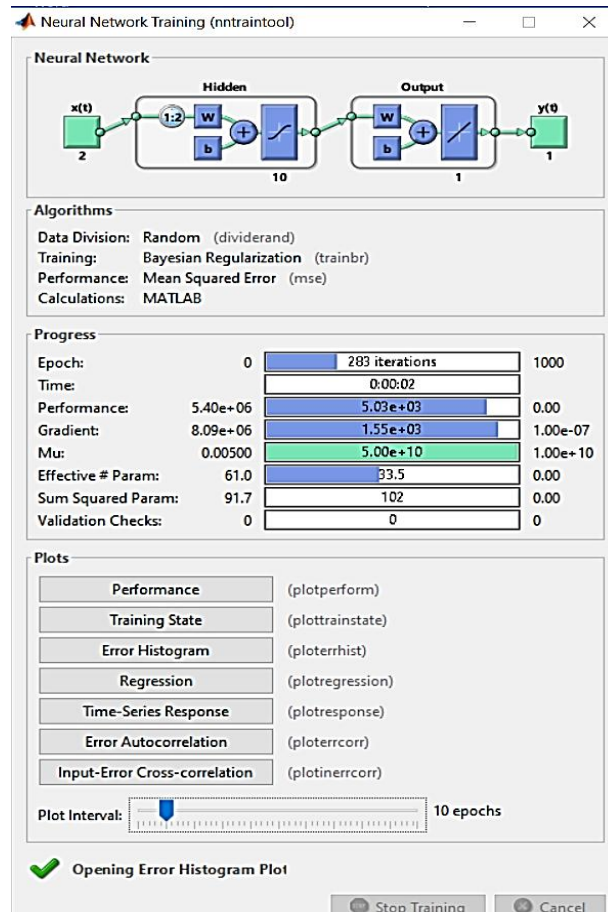
ANEXO 6: Ajuste de los datos en forma de campana al error cero absolutos del producto estrella Accesorios.



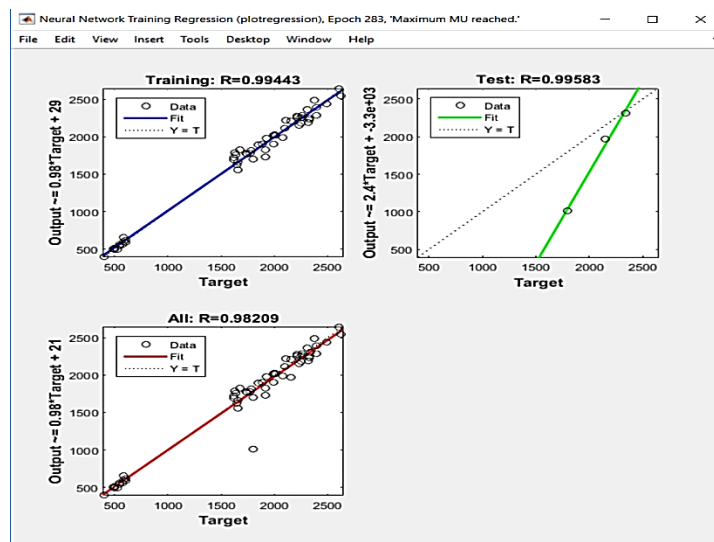
ANEXO 7: Regresión por punto de error y el objetivo entrenado óptimo perseguido del producto estrella Accesorios.




ANEXO 8: Iteraciones óptimas de entrenamiento del producto estrella Perfilería.



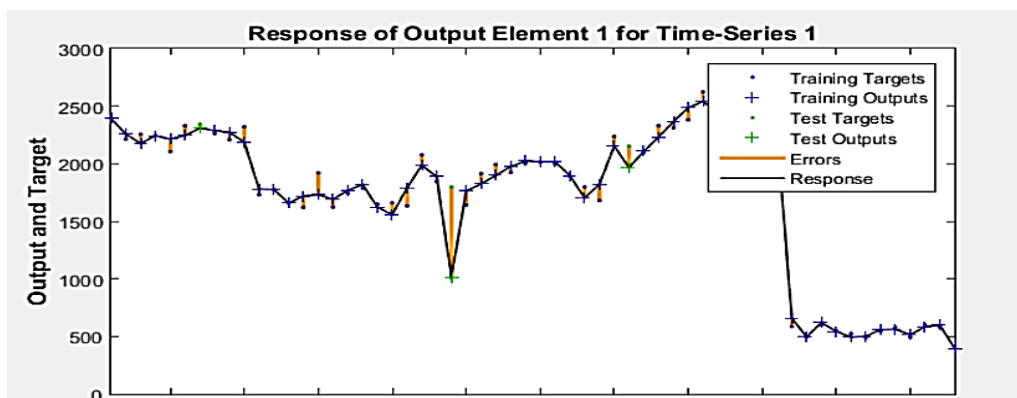
ANEXO 9: Comportamiento del ajuste de los datos del producto estrella Perfilería.



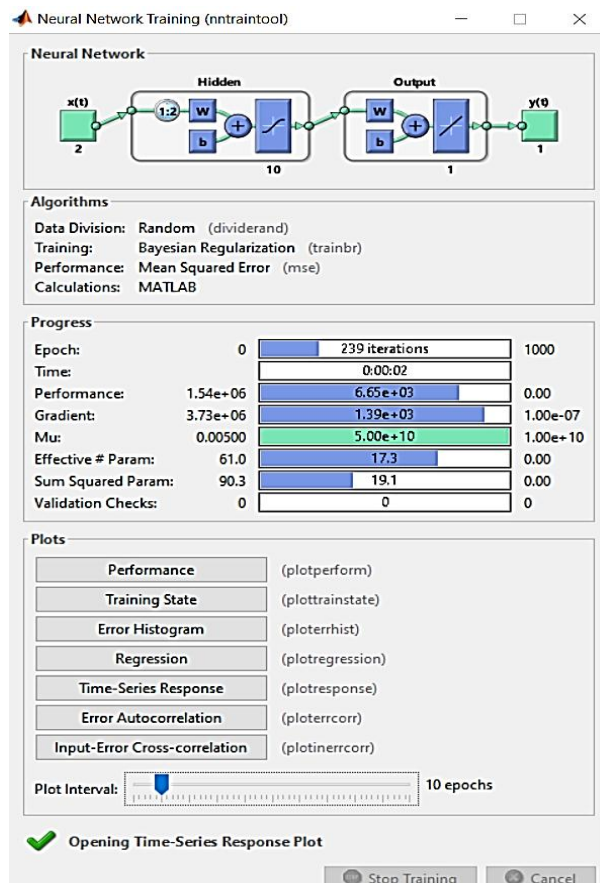
ANEXO 10: Ajuste de los datos en forma de campana al error cero absolutos del producto estrella Perfilería.



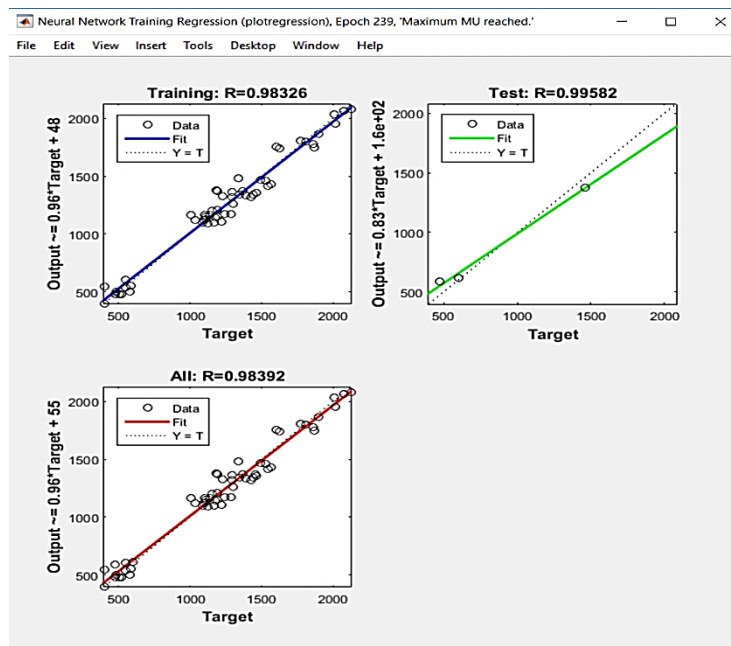
ANEXO 11: Regresión por punto de error y el objetivo entrenado óptimo perseguido del producto estrella Perfilería.




ANEXO 12: Iteraciones óptimas de entrenamiento del producto estrella Techos.



ANEXO 13: Comportamiento del ajuste de los datos del producto estrella Techos.



ANEXO 14: Ajuste de los datos en forma de campana al error cero absolutos del producto estrella Techos.



ANEXO 15: Regresión por punto de error y el objetivo entrenado óptimo perseguido del producto estrella Techos.

